

**Quantitative Bildverarbeitung und ihre
Anwendung auf melanozytäre Hautveränderungen**

René Pompl

Institut für Informatik
Lehrstuhl Univ.-Prof. Dr. Dr.h.c. W. Brauer
der Technischen Universität München

**Quantitative Bildverarbeitung und ihre
Anwendung auf melanozytäre
Hautveränderungen**

René Pompl

Vollständiger Abdruck der von der Fakultät für Informatik der Technischen
Universität München zur Erlangung des akademischen Grades eines

Doktors der Naturwissenschaften (Dr. rer. nat.)

genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Bernd Brügge, Ph.D.

Prüfer der Dissertation:

1. Univ.-Prof. Dr. Dr.h.c. Wilfried Brauer
2. Univ.-Prof. Dr. Bernd Radig
3. Univ.-Prof. Dr. Wilhelm Stolz,
Universität Regensburg

Die Dissertation wurde am 10.7.2000 bei der Technischen Universität München
eingereicht und durch die Fakultät für Informatik am 12.12.2000 angenommen.

Für meinen Vater.

Inhaltsverzeichnis

1	Einleitung	1
2	Nachvollziehbare quantitative Bildanalyse	5
2.1	Begriffsbestimmungen	6
2.2	Schema	6
3	Homogenität und Symmetrie	11
3.1	Bestimmung der Symmetrieachsen	12
3.2	Homogenität	13
3.3	Bestimmung der Symmetrieeigenschaften	16
3.3.1	Pixelbezogene Symmetrie	16
3.3.2	Felderbezogene Symmetrie	17
4	Strukturen	19
4.1	Information und Entropie	20
4.2	Isotrope und anisotrope Skalierungs-Indizes	21
4.2.1	Skalierungs-Index-Methode	21
4.2.2	Anisotrope Skalierungsindizes	25
4.2.3	Beispiel	25
4.3	Rotationsinvariante anisotrope Skalierungsindizes	29
4.4	Fuzzy Skalierungsindizes (fSIM)	33
4.4.1	Motivation und Formalismus	33
4.4.2	fSIM bei Binärbildern	37
4.4.3	Grauwertbilder: Zwei Beispiele	38
4.4.4	Verbesserung des Laufzeitverhaltens	46
4.4.5	Neuronales Analogon von fSIM	47
4.4.6	Ausblick	54
4.5	TDE-SIM	56
5	Randeigenschaften	61
5.1	Randbereich	62
5.1.1	Extraktion des Randbereichs	62
5.1.2	Quantifizierung des Randbereichs	65
5.1.2.1	Beurteilung der strukturellen Zusammensetzung	65

5.1.2.2	Beurteilung der strukturellen Homogenität	66
5.1.3	Beispiel	68
5.2	Konturen	70
6	Farbe	73
6.1	Farbräume	74
6.1.1	RGB-Farbraum	74
6.1.2	HLS-Farbraum	74
6.2	Farbvielfalt	75
6.3	Farbhomogenität	77
6.4	Farbsymmetrie	78
7	Klassifikation	79
7.1	Allgemeines	80
7.2	Klassifikatoren	80
7.2.1	Lineare Diskriminanzanalyse	80
7.2.2	Neuronale Netze	81
7.2.3	Nearest-Neighbor-Algorithmen	82
7.2.4	Entscheidungsbäume	83
7.3	Merkmalsauswahl	83
8	Anwendung: Früherkennung des malignen Melanoms	87
8.1	Überblick: Pigmentierte Hautveränderungen	88
8.2	Das maligne Melanom	88
8.3	Diagnostik: Dermatoskopie	88
8.4	Ansätze zur Bildanalyse in der Melanomdiagnostik	91
8.5	Bildakquisition und Vorverarbeitung	93
8.6	Segmentation	95
8.6.1	Haardetektion	95
8.6.2	Segmentation der Läsion	95
8.7	Merkmalsextraktion	99
8.7.1	Bildmaterial	99
8.7.2	Qualitätsmaße	99
8.7.3	Aufbau der Einzelbeschreibungen	101
8.7.4	Asymmetrie der Läsionsform	103
8.7.5	Konvexität der Läsionsform	106
8.7.6	Farbasymmetrie	109
8.7.7	Asymmetrie der Strukturverteilung	112
8.7.8	Berandung	116
8.7.8.1	Strukturelle Zusammensetzung	117
8.7.8.2	Homogenität der strukturellen Zusammensetzung	120
8.7.9	Krümmung der Kontur	124
8.7.10	Homogenität der Kontur	127
8.7.11	Farbvielfalt	130

8.7.12	Farbhomogenität	133
8.7.13	Strukturvielfalt	136
8.7.14	Homogenität der Strukturverteilung	139
8.7.15	Größe der Läsionen	142
8.8	Merkmalsauswahl und Klassifikation	143
8.8.1	Zusammenfassung der Einzelmerkmale	143
8.8.2	Merkmalsauswahl und Abschätzung der Klassifikationsgenauigkeit . .	146
8.8.3	Bewertung der Klassifikationsergebnisse	149
8.8.4	Reproduzierbarkeit	150
8.9	Zusammenfassung der Ergebnisse	154
9	Zusammenfassung	157
	Literaturverzeichnis	163

Kapitel 1

Einleitung

Der Mensch nimmt seine Umwelt über seine Sinnesorgane wahr und ein wesentlicher Teil dieser Sinneseindrücke besteht aus visueller Information. Das menschliche Auge in Verbindung mit der Bildauswertung durch das Gehirn ist das beste bisher bekannte Bildverarbeitungs- und Mustererkennungssystem [Ste93]. Digitale Rechenanlagen können den Menschen in der Verarbeitung visueller Information unterstützen oder ihm neue Wahrnehmungsmöglichkeiten eröffnen. Daher ist die digitale Bildverarbeitung Schwerpunkt intensiver Forschungsarbeiten und hat, oft unbemerkt, Einzug in unser tägliches Leben gefunden. Die Satellitenbilder, die mit dem täglichen Wetterbericht von den Rundfunkanstalten ausgestrahlt werden, sind auch das Ergebnis einer langen Kette von Bildverarbeitungsalgorithmen.

Da der visuellen Information in sehr vielen Bereichen eine große Bedeutung zufällt, weist das Spektrum der Anwendungsgebiete der Bildverarbeitung eine große Vielfalt auf. So ist man in der Robotik bestrebt, automatisierte Maschinen zu konstruieren, die in der Lage sind, selbstständig in unbekanntem Szenarien zu agieren, wie etwa mobile Robotersonden zur Planetenerkundung. Satelliten zeichnen die Erdoberfläche oder andere Objekte in mehreren Spektralbereichen auf, die durch Techniken der Bildverarbeitung ausgewertet werden können. In der Qualitätssicherung werden Produkte im laufenden Fließband durch Bildverarbeitungsmethoden kontrolliert. Vierdimensionale Daten, wie sie in der Tomographie anfallen, sind dank spezialisierter Softwaresysteme interpretierbar geworden.

Ohne Anspruch auf Vollständigkeit sei ein weiteres Anwendungsfeld genannt, das auf einer Schwäche des menschlichen Sehsystems beruht. In vielen Bereichen ist eine quantitative Beschreibung eines Objekts vonnöten, die über Größe und Fläche hinausgeht. Bei der Beschreibung der Farbvielfalt eines Objekts treten deutlich die Probleme der intra- und inter-Observer-Variabilität zu Tage. Eine Person gelangt, wenn ihr das Objekt in zeitlichen Abständen mehrmals vorgelegt wird, möglicherweise zu verschiedenen Ergebnissen. Ähnlich verhält es sich bei der Beschreibung dieser Eigenschaft durch verschiedene Personen. Problematisch sind also Reproduzierbarkeit und Objektivität der Beobachtung. Ein weiteres Problem liegt in der neurophysiologischen Lichtrezeption des menschlichen optischen Apparats begründet. So steigt die empfundene Helligkeit nicht linear mit der auf der Retina einfallenden Lichtintensität an, vielmehr weist diese Reizstärke-Reaktionsbeziehung eine annähernd logarithmische Abhängigkeit (Weber-Fechner-Beziehung) auf [HLMZ78]. Dies erschwert die

adäquate quantitative Beurteilung visuell aufgenommener Information.

Üblicherweise löst das Ergebnis der Bildanalyse eine Reaktion aus. Dies kann durch eine Aktion bei Überschreitung eines Grenzwertes durch einen oder mehrere Parameter vor sich gehen, oder aber auch durch eine Klassifikation. Diese Reaktion läßt sich in vielen Anwendungen automatisieren, wie zum Beispiel das Entfernen fehlerhafter Leiterplatten in der Qualitätskontrolle. Oftmals ist die Reaktion auf die Ergebnisse der Bildanalyse mit höherer Verantwortung verbunden. In der Medizin kann das Ergebnis der Analyse die Diagnosestellung bestimmen und damit auf die Therapiemaßnahmen und den Heilungsverlauf Einfluß nehmen. In der Kriminalistik wirkt sich das Resultat auf die weitere ermittlerische Tätigkeit und das juristische Verfahren aus. In der Forschung müssen die Ergebnisse dem Wissenschaftler zum tieferen Verständnis anschaulich nähergebracht werden. Diese wenigen Beispiele sollen die Notwendigkeit der Transparenz der Bildverarbeitung für den menschlichen Experten oder die Erfordernis einer Kontrolle durch ihn verdeutlichen.

Aus dieser Problematik leitet sich das Ziel dieser Arbeit ab: die quantitative Charakterisierung von Objekteigenschaften, die sprachlich oft nur schwer zu erfassen sind wie Farbe oder Symmetrie. Diese Merkmalsbeschreibung soll unter den Nebenbedingungen Reproduzierbarkeit, Objektivität und Nachvollziehbarkeit der Ergebnisse vollzogen werden. Dazu werden Algorithmen vorgestellt, die dies für die Objekteigenschaften Berandung, Farbe und Struktur sowie deren Homogenität und Symmetrie bewerkstelligen. Darüberhinaus wird die Problemstellung in ein allgemeines Schema der digitalen Bildverarbeitung eingebettet, das den Prozeß von der Bildakquisition bis zur Klassifikation beschreibt.

Der Autor ist sich bewußt, daß die in dieser Arbeit vorgestellten Merkmalsbeschreibungen und Quantifizierungsalgorithmen weder umfassend noch für jedes Problem passend sind. Einschränkungen der Anwendbarkeit der einzelnen Verfahren werden, soweit allgemeingültig formulierbar, in den einzelnen Abschnitten besprochen. Ausführlich wird die Nützlichkeit der Methoden bei ihrer Anwendung auf die Problematik der Erkennung des malignen Melanoms der Haut untersucht. Diese Arbeit hat in Teilen einen starken medizinischen Hintergrund. Zur Identifizierung des malignen Melanoms werden verschiedene Merkmale quantitativ beschrieben. Anhand dieser Charakterisierungen soll das maligne Melanom von anderen Hautveränderungen unterschieden werden können. Die Merkmalsauswahl zur Lösung dieses speziellen Problems sowie die Analyse der Klassifikationsgenauigkeit schließen die Darstellung des Schemas anhand des Melanomproblems ab.

Diese Arbeit besteht aus einem theoretischen und aus einem anwendungsbezogenen Teil. Schwerpunkt des ersten Bereichs ist die quantitative Merkmalsbestimmung unter der Nebenbedingung der Nachvollziehbarkeit. Im zweiten Teil wird die Anwendung dieser Techniken auf die Problematik der Früherkennung des malignen Melanoms der Haut untersucht. Diese Darstellung folgt den einzelnen, aufeinander abfolgenden Schritten eines digitalen Bildanalyseprozesses.

Im zweiten Kapitel wird der Begriff der nachvollziehbaren quantitativen Bildanalyse zusammen mit ihren Zielen genauer gefaßt. Aus dieser Definition leiten sich verschiedene Randbedingungen ab, die zur Erfüllung der Ziele eingehalten werden müssen. Diese werden anhand eines bekannten Schemas zur digitalen Bildanalyse diskutiert, das diese Aufgabe von

der Bildakquisition bis zur Klassifikation in fünf fundamentale Schritte gruppiert.

Symmetrie- und Homogenitätseigenschaften sind wesentliche Beschreibungsgrößen eines Objekts. Diese werden nicht nur von der äußeren Form geprägt, sondern auch von der inneren Struktur. Im dritten Kapitel werden Verfahren zur Charakterisierung dieser Eigenschaften vorgestellt. Im Hinblick auf das in der Arbeit behandelte Anwendungsgebiet wird der Begriff Symmetrie auf Achsensymmetrie beschränkt. Da die nachfolgenden Kapitel auf diese Methoden Bezug nehmen, ist diese Thematik den anderen vorangestellt.

Das vierte Kapitel behandelt die quantitative Beschreibung von strukturellen Merkmalen. Die Detektion und quantitative Charakterisierung erfolgt anhand struktureller Komplexitätsmaße. Ausgehend von der sogenannten Skalierungs-Index-Methode (SIM) und ihrer anisotropen Variante wird eine Verallgemeinerung des Verfahrens beschrieben und ihre Eigenschaften untersucht. Diese fSIM genannte Methode hat ein Analogon im Bereich der neuronalen Netze. Es wird der Aufbau eines solchen Netzes zusammen mit einem Lernalgorithmus beschrieben. Ein weiteres Thema dieses Kapitels ist eine Variante von SIM, mit der Strukturen quantitativ erfaßt werden können, die sich nur wenig in ihren Grauwerten unterscheiden. Jedes der beschriebenen Verfahren wird eingehend an Beispielen untersucht.

Die quantitative Erfassung von Randeigenschaften eines Objekts ist Gegenstand des fünften Kapitels. Bei vielen Anwendungen erfolgt der Übergang vom untersuchten Objekt zum Hintergrund nicht abrupt, sondern langsam in einem sogenannten Randbereich. Dessen Eigenschaften beinhalten Informationen über die Beschaffenheit des Objekts. Zu ihrer Bestimmung werden zunächst zwei Extraktionsverfahren des Randbereichs mit unterschiedlichen Eigenschaften vorgestellt. Eine quantitative Beschreibung des binär vorliegenden Randbereichs ermöglichen die Komplexitätsmaße aus dem vierten Kapitel. Weiterhin wird auch auf die Charakterisierung der Objektkontur eingegangen.

Inhalt des sechsten Kapitels ist die quantitative Beschreibung der Farbeigenschaften eines Objekts. Nach einem kurzen Überblick über verschiedene Farbräume werden Methoden beschrieben, die eine quantitative Charakterisierung der Farbvielfalt sowie der Homogenität und Symmetrie der Farbverteilung erlauben.

Das siebte Kapitel schließt mit der Behandlung der Klassifikation unter Berücksichtigung der Merkmalsauswahl den theoretischen Teil der Arbeit ab. Diskutiert wird diese Thematik unter Beachtung der Nachvollziehbarkeit des Klassifikationsvorgangs. Dazu werden verschiedene und oft genutzte Klassifikationsverfahren hinsichtlich ihrer Eignung untersucht.

Die Anwendung der vorgestellten Verfahren auf die Problematik der Früherkennung des malignen Melanoms ist Inhalt des achten Kapitels. Nach Erläuterung des medizinischen Hintergrunds wird das gängige klinische Diagnoseverfahren beschrieben. Auf Grund der Natur des Problems und des Diagnosevorgangs eignet sich die nachvollziehbare quantitative Bildanalyse zur Unterstützung des Dermatologen bei der Diagnose des Krankheitsbildes. Der gesamte Bildanalyseprozeß basiert auf den im Kapitel 2 erläuterten Schema und verwendet die in Kapitel 3 bis 7 vorgestellten Verfahren. Schwerpunkt ist die Analyse der Fähigkeit der einzelnen Merkmale, zwischen gutartigen und bösartigen Hautveränderungen zu unterscheiden, sowie Möglichkeiten darzustellen, wie die berechneten Werte für den Dermatologen visuell aufbereitet und somit nachvollziehbar dargestellt werden können. Mit der Analyse der Klassifikationsergebnisse nach vorhergehender Merkmalsauswahl endet dieses Kapitel.

Im letzten Kapitel werden die Ergebnisse dieser Arbeit zusammengefaßt und diskutiert.

Kapitel 2

Nachvollziehbare quantitative Bildanalyse

In vielen Anwendungen der digitalen Bildverarbeitung ist eine quantitative Beschreibung von Objektmerkmalen zu bestimmen. Oft ist die Ausgabe lediglich der quantitativen Werte eines Merkmals nicht ausreichend, sondern das Ergebnis muß auch für den Anwender verständlich sein. In diesem Kapitel wird der Begriff der nachvollziehbaren quantitativen Bildanalyse genauer gefaßt und einige für diese Arbeit wichtige Begriffe definiert. Weiterhin wird ein bekanntes allgemeines Schema zur digitalen Bildverarbeitung beschrieben. Es wird untersucht, an welchen Stellen in diesem Schema zur Erreichung der Ziele einer nachvollziehbaren quantitativen Bildanalyse besondere Maßnahmen ergriffen oder Adaptionen vorgenommen werden müssen.

2.1 Begriffsbestimmungen

Eine Kernaufgabe der Bildanalyse mittels digitaler Rechenanlagen ist die Extraktion relevanter Informationen aus digital vorliegenden Bildern. Ein Bild enthält ein oder mehrere Objekte, wobei ein Objekt als ein meist strukturierter realer Gegenstand [Rad93] definiert ist. Im Sinne der jeweiligen Aufgabenstellung verschiedene Objekte unterscheiden sich anhand ihrer Eigenschaften (Merkmale). Ein Merkmal ist eine das Objekt charakterisierende Eigenschaft, wie zum Beispiel die Farbvielfalt. Wird im Bildanalyseprozeß nicht nur das Vorhandensein eines Merkmals (qualitativ), sondern auch das Ausmaß seiner Ausprägung beurteilt, so spricht man von quantitativer Bildanalyse. Das sprachliche Hilfskonstrukt "Ausprägung eines Merkmals" umfaßt die Abbildung von Objekteigenschaften auf reproduzierbare Parameterskalen. Das Ergebnis dieser Abbildung bezüglich eines Merkmals soll in dieser Arbeit mit dem Terminus "Score" benannt werden.

In vielen Anwendungen, insbesondere in der medizinischen Diagnostik, müssen die Ergebnisse der Bildanalyse für den Experten nachvollziehbar sein, sei es zur Kontrolle oder zum tieferen Verständnis der Analyse. Die Darstellung der Ergebnisse muß also der Wahrnehmung des menschlichen Experten entsprechen, wodurch die Ergebnisse leichter überprüfbar werden. Es gilt also ein Konvergenzprinzip, demzufolge die abgeleiteten quantitativen Maße tendenziell die visuell erfaßbaren und vom Experten formulierbaren Merkmale einsehbar wiedergeben müssen. Eine quantitative Bildanalyse dieser Art soll im folgenden *nachvollziehbare quantitative Bildanalyse* genannt werden.

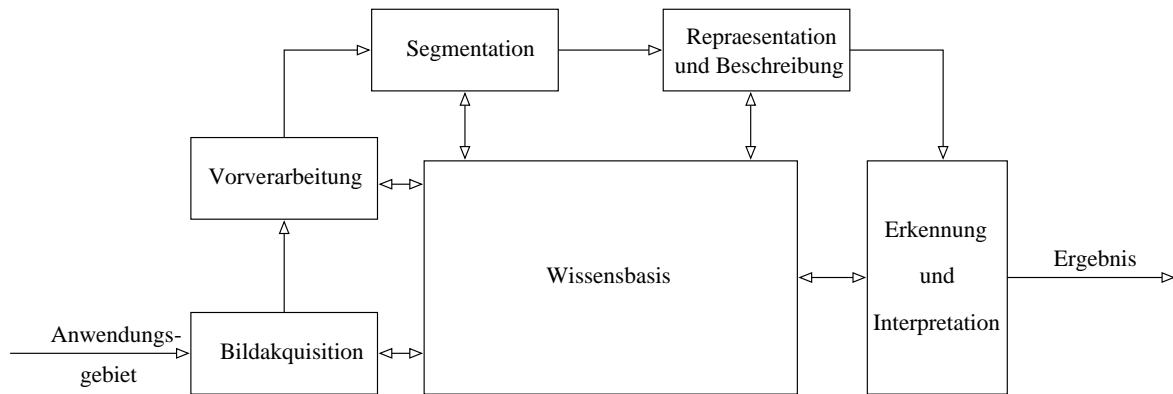
Die in dieser Arbeit beschriebenen Maße zur Merkmalsquantifizierung sind meist dimensionslos. Um sie in ihrer Ausprägung einordnen zu können, sind die Scores von Referenzobjekten heranzuziehen, erlangen also erst in einem Kontext eine Interpretierbarkeit (Kontextualität der Quantifizierungen).

Im Vorfeld der Analyse muß das Objekt erkannt und von seinem Hintergrund getrennt werden (Segmentierung). Die Zuordnung der Bildpixel zum Objekt werden mit dem Wert 1 und zum Hintergrund mit dem Wert 0 angezeigt. Das so gekennzeichnete Objekt soll Binärobjekt genannt werden. Die aus dem Binärobjekt abgeleiteten Größen wie Schwerpunkt oder Symmetrieachse werden geometrischer Schwerpunkt (vgl. Gleichung 3.1, Seite 12) oder geometrische Symmetrieachse genannt (vgl. Abschnitt 3.1).

2.2 Schema

Zur Erreichung der Ziele einer quantitativen Bildanalyse sind besondere Voraussetzungen zu schaffen und gewisse Rahmenbedingungen einzuhalten. Diese lassen sich in einem Schema der digitalen Bildverarbeitung strukturiert darstellen. Dazu wird ein bekanntes Schema zur Bildverarbeitung diskutiert und untersucht, welche Adaptionen erforderlich sind.

Gonzalez und Woods [GW92] gruppieren die Aufgaben der Bildverarbeitung in fünf fundamentale Schritte (Module) (vgl. Abbildung 2.1). Die Akquisition des digitalen Bildmaterials stellt den ersten Schritt dar. Als Aufnahmeeinheit ist beispielsweise eine CCD-Kamera oder ein Scanner denkbar. Das so aufgenommene Rohbild wird anschließend einer Vorverarbeitung unterzogen. Ziel dieses Moduls ist die Bildverbesserung im Sinne der Aufgabenstellung, wie

Abbildung 2.1: *Grundschema der Bildverarbeitung* (nach [GW92])

zum Beispiel Rauschreduktion. Inhalt des nächsten Schritts ist die Segmentierung. Die Autoren definieren Segmentierung als die Zerlegung des Bildes in seine konstituierenden Teile oder Objekte. Die Transformation der noch immer rohen Daten in eine geeignete Form zur Bearbeitung in einer höheren Abstraktionsebene ist die Aufgabe des vierten Schritts. Dazu muß zunächst eine geeignete Wahl der Repräsentierung des Segmentierungsergebnisses, sei es beispielsweise als Kontur oder als Region, getroffen werden. Um die interessierenden Merkmale eines Objekts adäquat beschreiben zu können, müssen geeignete Verfahren gefunden beziehungsweise entwickelt werden. Dieser Teilschritt befaßt sich also mit der Extraktion von Merkmalen, um verschiedene Objektklassen differenzieren zu können. Der letzte Schritt behandelt die Erkennung und Interpretation. Der Terminus *Erkennung* meint den Prozeß der Zuordnung eines Namens anhand der vorher extrahierten Merkmale. Die Interpretation weist den erkannten Objekten eine Bedeutung zu.

Bei jedem dieser fünf Schritte kann eine Interaktion mit einer Wissensbasis stattfinden. Das Wissen kann dabei sehr einfach (z.B. Kenntnis der ungefähren Objektgröße) oder beliebig komplex (z.B. verknüpfte Defektliste bei Inspektionsaufgaben) strukturiert sein. Die Doppelpfeile in Abbildung 2.1 sollen andeuten, daß die Wissensbasis auch die Interaktion zwischen den einzelnen Modulen steuern kann. Ab einer gewissen Komplexität der Einbindung der Wissensbasis spricht man von wissensbasierten Bildverarbeitungssystemen [GB97]. Abschließend soll angemerkt werden, daß nicht alle Anwendungen in der Bildverarbeitung die volle Komplexität dieses Schemas benötigen.

Ausgehend von diesem Schema werden im folgenden die besonderen Schwerpunkte und Adaptionen für die einzelnen Module diskutiert, die den geeigneten Rahmen für eine nachvollziehbare quantitative Charakterisierung von Bildobjekten bilden.

Bildakquisition

Von entscheidender Bedeutung für die Güte eines Analysesystems ist seine Reproduzierbarkeit: eine wiederholte Messung sollte zu den gleichen oder nur wenig differierenden Ergebnissen gelangen. Das Prinzip der Kontextualität und die Forderung nach Reproduzierbarkeit stellen besondere Anforderungen an die Bildakquisition. Die Bilder müssen standardisiert hin-

sichtlich mehrerer Kriterien aufgenommen werden. Angelehnt an [Sch95] und [Haf99] lassen sich die Einflußfaktoren bei der Farbbildaufnahme zu drei Klassen gruppieren:

Kameraparameter Die Notwendigkeit der Standardisierung der Farbwerte verstärkt sich bei Einsatz verschiedener Kameratypen (vgl. [Haf99]). Aber auch bei Verwendung nur eines Kameratyps können gleiche Farbwerte unterschiedlich erfaßt werden. Ursache hierfür können kleine technische Bauunterschiede oder Alterungserscheinungen sein. Um diese Unterschiede auszugleichen ist als technische Lösung beispielsweise die Aufnahme einer Farbreferenzkarte mit standardisierten Farbwerten mit einer darauf basierenden Farbkorrektur zu nennen [KK95]. Zu beachten ist insbesondere, daß bei vielen Kameras eine automatische Anpassung der Bilddaten zur Verbesserung des optischen Eindrucks vorgenommen wird. Dies kann die Reproduzierbarkeit der Bildakquisition erheblich erschweren.

Objektparameter Bei der Bildakquisition ist die Ausrichtung des Objekts zur Kamera zu berücksichtigen. Auch müssen die Objekte mit dem selben Vergrößerungsfaktor erfaßt werden. Diese Forderung kann allerdings abgeschwächt werden, wenn das Objekt durch Skalierung des Bildausschnitts in der Größe standardisiert werden kann oder die verwendeten Algorithmen skaleninvariant sind. Es ist aber im Einzelfall zu prüfen, bei welchen Größenfaktoren noch zufriedenstellende Resultate möglich sind. Relevant ist auch das Reflektionsverhalten des aufzunehmenden Objekts.

Umgebungsparameter Im Rahmen der technischen Möglichkeiten und der Natur des Objekts muß eine möglichst konstante Ausleuchtung gewährleistet sein. Um Inhomogenitäten in der Helligkeit zu vermeiden kann auch algorithmisch eine Hintergrundkompensation durch Helligkeitsausgleich mittels eines Referenzbildes [Abm94] vorgenommen werden. In einem engen Zusammenhang mit dem letztgenannten Punkt steht die Standardisierung der Aufnahmebedingungen. Darunter fällt die Sicherstellung einer konstanten Beleuchtungsintensität, die Vermeidung von Abschattungseffekten sowie der Einfluß äußerer Lichtquellen (z.B. Sonneneinstrahlung).

Vorverarbeitung

Unter diesen Punkt fallen alle Maßnahmen, durch die eine Standardisierung des Aufnahmebildes durch softwaretechnische Bearbeitung erreicht werden kann. Dies schließt die bereits genannte Größenskalierung, Hintergrundkompensation und Farbkorrektur ein.

Segmentation

Gonzalez und Woods schreiben zum Thema Segmentierung [GW92]: "Im Allgemeinen gehört eine autonome Segmentierung zu den schwierigsten Aufgaben der digitalen Bildverarbeitung." Eine zu starke Aufteilung des Bildes in Segmente (Übersegmentation) verursacht den oft mühseligen Prozeß, die einzelnen Teile zu semantisch zusammengehörenden Objekten zusammenzufügen. Eine zu schwache Segmentierung dagegen führt durch die Miteinbeziehung nicht zum Objekt gehörender Bildregionen zu falschen Ergebnissen im Sinne der Aufgabenstellung. Die Segmentierung beeinflusst demnach grundlegend die weitere Analyse. Die Folgen einer fehlerhaften Segmentierung müssen je nach Anwendungsgebiet kritisch beurteilt werden.

In der Medizintechnik beispielsweise kann sie die weitere Behandlung eines Patienten beeinflussen und damit Einfluß auf seine Gesundheit nehmen. Daher ist es in vielen Anwendungen angebracht, einen robusten Segmentierungsalgorithmus zu verwenden und das Ergebnis vom Experten bestätigen oder korrigieren zu lassen. Da bei der nachvollziehbaren quantitativen Bildanalyse eine autonome Reaktion des Bildverarbeitungssystems ohnehin nicht vorgesehen ist, ist dieser Schritt meist mit wenig Aufwand oder Beschränkung der Praktikabilität verbunden.

Repräsentation und Beschreibung

Um eine Nachvollziehbarkeit zu ermöglichen, sollten die zu extrahierenden Größen mit der Vorstellungswelt des Experten zusammenhängen. Ungeeignet sind beispielsweise die Amplitude des Powerspektrums bei der Fouriertransformation oder globale Formmerkmale wie Momente von Binärobjekten. Vorgeschlagen wird eine Abstützung der Bewertungsalgorithmen auf lokale Werte. Die Lokalität kann sich auf Pixelebene oder auf Gruppen von benachbarten Pixeln beziehen. Die lokalen Werte oder Scores können mit geeigneter Farbkodierung eingänglich visualisiert werden. Zur Bildung eines Gesamtwertes können die lokalen Scores beispielsweise anhand der Form ihrer Häufigkeitsverteilung zusammengefaßt werden.

Erkennung und Interpretation

Die Merkmalsauswahl erfolgt üblicherweise anhand eines Trainingsdatensatzes. Im Schema von Gonzalez und Woods findet die Merkmalsauswahl (*feature selection*) im vorhergehenden Modul statt. Es gibt allerdings starke Hinweise, daß sich die Erfolgsrate der Zuordnung des untersuchten Objekts zu einer Klasse bei Kopplung von Merkmalsauswahl und Klassifikator verbessert [SB97a]. Deshalb wird diese Aufgabe *feature selection* in dieses Modul verlegt. Die Wahl des Klassifikators ist einigen Einschränkungen unterworfen. Auch hier gilt das Gebot der Transparenz: der Experte muß nachvollziehen können, weshalb das System zu der Klassenzuordnung gelangt ist. Bei Einsatz von neuronalen Netzen ist dieser Aspekt allerdings problematisch. Trotz der breiten Einsetzbarkeit und der guten Resultate sind sie für diese Zielstellung nicht zu empfehlen. Besser geeignet sind dagegen Nearest-Neighbor-Verfahren, da sie das Anzeigen von Referenzfällen erlauben. Eine ausführliche Beschreibung und Diskussion dieses Themas findet sich in Kapitel 7. Einschränkend ist allerdings anzumerken, daß auch ein weniger transparenter Klassifikationsalgorithmus eingesetzt werden kann, wenn dieser im Anwendungsgebiet von den Experten ohnehin verwendet wird. Dies erhöht im Sinne einer *sanften Migration* [Hor97] (Verlagerung des Analyseprozesses vom Menschen zu einer den Menschen unterstützenden digitalen Anlage) die Akzeptanz des Systems.

Die Interaktion des Systems mit der Wissensbasis kann, wie bereits erwähnt, verschieden komplex ausfallen. Daher ist es schwierig, hier konkrete Anforderungen zu stellen. Es bleibt nur festzuhalten, daß auch an dieser Stelle die Nachvollziehbarkeit gewährleistet sein muß.

Kapitel 3

Homogenität und Symmetrie

Eine Charakterisierung von Objekten schließt die Beurteilung der räumlichen Verteilung eines Merkmals M (z.B. Farbe) mit ein. Mit der Homogenität wird die Gleichmäßigkeit der Verteilung von M über das Objekt hinweg untersucht. Das vorgestellte Verfahren basiert auf einer gitterartigen Aufteilung des zu untersuchenden Objekts. Für jedes Gitterelement wird die Ausprägung des Merkmals M lokal bestimmt. Anhand dieser lokalen Scores wird die Homogenität quantifiziert. Um eine Reproduzierbarkeit des Ergebnisses zu erreichen, wird ein standardisiertes Konstruktionsverfahren des Gitters angegeben. Die Orientierung und Lage des Gitters sind durch Schwerpunkt und geometrische Symmetrieachse des Objekts definiert. Ein weiteres Charakteristikum der räumlichen Verteilung von M ist die Symmetrie hinsichtlich M . Das verwendete Verfahren beruht auf der Untersuchung der Charakterisierungen des Merkmals M bei Pixeln in achsensymmetrischer Lage. Der direkte Pixelvergleich kann in manchen Anwendung unzureichend sein. Daher wird ein alternatives Verfahren angegeben, bei dem die Charakterisierungen größerer Bereiche des Objekts in achsensymmetrischer Lage betrachtet werden. Die hier dargestellten Algorithmen lassen sich auf die Merkmale der weiteren Kapitel anwenden und sind ihnen daher vorangestellt.

3.1 Bestimmung der Symmetrieachsen

Die Beurteilung von Symmetrie ist eine grundlegende Charakterisierungsmöglichkeit von Objekten. In dieser Arbeit wird unter Symmetrie die Achsensymmetrie verstanden. Sie stellt jedoch nur einen Aspekt der Möglichkeiten zur Untersuchung der Symmetrieeigenschaften eines Objekts dar. Alternative Beurteilungen, wie etwa die Rotationssymmetrie, finden sich zum Beispiel in [ZPA95] oder [PBB93]. Diese Wahl ist in der Natur der in dieser Arbeit untersuchten Objekte (melanozytäre Hautveränderungen, siehe Kapitel 8, Seite 87) begründet und läßt sich auch auf andere Fragestellungen wie beispielsweise der quantitativen Untersuchung der Wundheilung übertragen.

Die Beurteilung der Homogenität und der Symmetrie bezüglich eines Merkmals M erfordert zunächst die Bestimmung der Symmetrieachsen eines zu untersuchenden Objekts. Sie werden durch die äußere Form des Objekts bestimmt und verlaufen durch den geometrischen Schwerpunkt des Objekts. Die Symmetrieachsen werden anhand der binären Objektmaske durch Hauptkomponentenanalyse ([Ste93], [LOPR97]) bestimmt.

Die Position eines Pixels i in einem digitalen Bild ist durch seine Koordinate (x_i, y_i) definiert. Die Koordinaten aller n Objektpixel lassen sich durch die geordneten Mengen X und Y darstellen, die jeweils die x - bzw. die y -Komponente der Koordinaten enthalten. Aus dieser Darstellung wird der Mittelwert der x -Komponenten \bar{x} , sowie der Mittelwert der y -Komponenten \bar{y} errechnet, die zusammen den geometrischen Schwerpunkt des Objekts (\bar{x}, \bar{y}) bilden:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (3.1)$$

Mit der empirischen Kovarianz $Cov(X, Y)$

$$Cov(X, Y) = \frac{1}{n} \sum_i (x_i - \bar{x})(y_i - \bar{y}) \quad (3.2)$$

wird die Kovarianzmatrix C bestimmt:

$$C = \begin{pmatrix} Cov(X, X) & Cov(X, Y) \\ Cov(Y, X) & Cov(Y, Y) \end{pmatrix} \quad (3.3)$$

Nun sind die Eigenwerte λ_i und die Eigenvektoren \vec{v}_i so zu bestimmen, daß folgende Bedingung erfüllt wird:

$$C\vec{v}_i = \lambda_i\vec{v}_i \quad (3.4)$$

Eine Aufgabenstellung dieser Art wird als spezielles Eigenwertproblem [BSMM95] bezeichnet. Da die Kovarianzmatrix C eine reelle symmetrische (da $Cov(X, Y) = Cov(Y, X)$) 2×2 -Matrix ist, hat sie genau 2 Eigenwerte [Koe85]. Numerische Lösungen für das spezielle Eigenwertproblem finden sich zum Beispiel in [PFTV92]. Der Eigenvektor mit dem größten Eigenwert beschreibt die Richtung der größten Varianz der Objektpixel. Der zweite Eigenvektor liegt senkrecht zur Hauptrichtung (Orthogonalitätseigenschaft). Die Eigenvektoren können somit als die Symmetrieachsen der Objektmaske betrachtet werden, wobei mit g_1 die Hauptsymmetrieachse und mit g_2 die dazu orthogonale Achse bezeichnet werden soll. Die Symmetrieachsen schneiden sich im geometrischen Schwerpunkt (\bar{x}, \bar{y}) des Binärobjekts.



Abbildung 3.1: *Bestimmung der Symmetrieachsen*: Die Hauptsymmetrieachse ist dunkel eingezeichnet. Die hellere Linie markiert die orthogonale zweite Symmetrieachse. Die linke Abbildung zeigt eine einfache symmetrische Figur; rechts ist die Hauptinsel Großbritanniens dargestellt.

Mit dem beschriebenen Algorithmus lassen sich die geometrischen Symmetrieachsen eines Objekts bestimmen. Bei einem idealen Kreis jedoch ist jede Linie, die durch den Mittelpunkt verläuft, eine Symmetrieachse. In der Kovarianzmatrix haben in diesem Fall die Diagonalelemente einen von 0 verschiedenen Wert und die Nicht-Diagonalelemente den Wert 0. Die dazugehörigen Eigenvektoren sind $(0, 1)$ und $(1, 0)$, d.h. die Symmetrieachsen des Objekts verlaufen parallel zu den Koordinatenachsen. Das Verfahren liefert also eine eindeutige Lösung, auch wenn sie in diesem Fall nicht die einzig mögliche ist. Probleme treten bei singulärer Kovarianzmatrix auf. Dies ist der Fall, wenn das Objekt aus einer koordinatenachsenparallelen Linie besteht, da nur entweder die Kovarianz $Cov(X, X)$ oder $Cov(Y, Y)$ ungleich 0 ist. Dieser triviale Fall kann allerdings von den Betrachtungen ausgeschlossen werden, da dies nicht ein Objekt im Sinne dieser Arbeit darstellt.

Abbildung 3.1 zeigt das Ergebnis der Achsenbestimmung zweier Figuren. Links ist ein einfaches ellipsenförmiges Objekt abgebildet, das so konstruiert wurde, daß seine Symmetrieachse einen Winkel von 45° bezüglich der x -Achse hat. Die Bestimmung der Symmetrieachsen nach oben angegebenen Algorithmus liefert einen Winkel der Hauptachse (dunkle Linie) von 45.0029° . Die Nebenachse ist im Bild hell eingezeichnet. Die rechte Abbildung zeigt das Ergebnis der Bestimmung der Symmetrieachsen der Hauptinsel Großbritanniens nach diesem Verfahren.

3.2 Homogenität

Die Beschreibung der Verteilung von lokalen Werten (Scores) innerhalb des Objekts bezüglich einer bestimmten Eigenschaft M (z.B. Farb- oder Grauwert) wird hier unter dem Begriff Homogenität von M gefaßt. Grundidee des vorgeschlagenen Verfahrens zur Charakterisierung dieser Eigenschaft ist die Aufteilung des Objekts in einem Gitter, die lokale Charakterisierung der Gitterelemente hinsichtlich M und die zusammenfassende Bewertung dieser Charakterisierungen mittels eines globalen Maßes.

Die Konstruktion des Gitters muß in einer standardisierten Weise erfolgen. Liegen zu ei-

nem Objekt mehrere Aufnahmen vor, haben diese im Allgemeinen nicht dieselbe Lage und Orientierung im Bild. Eine Standardisierung der Gitterkonstruktion ist somit im Sinne der Reproduzierbarkeit des Quantifizierungsergebnisses notwendig. Zur Sicherstellung der Translationsinvarianz des Verfahrens wird das Gitter um den geometrischen Schwerpunkt (\bar{x}, \bar{y}) (vgl. Gleichung 3.1) des Objekts aufgebaut. Um eine Rotationsinvarianz zu erhalten, wird das Gitter in Richtung der geometrischen Symmetrieachse nach dem Verfahren aus Abschnitt 3.1 aufgebaut. Mit diesen zwei Maßnahmen ist eine eindeutige Fixierung des Gitters am Objekt gewährleistet. Abbildung 3.2 verdeutlicht exemplarisch den Aufbau des Gitters.




Abbildung 3.2: Aufbau des Gitters zur Bestimmung der Homogenität eines Merkmals M anhand des Bildes aus Abbildung 3.1 (Seite 13): Der Schwerpunkt des Objekts ist rot, die Symmetrieachsen sind blau eingezeichnet. Um den Schwerpunkt und entlang der Symmetrieachsen wird das Gitter aufgebaut (im Beispiel beträgt die Gitterkonstante $g_x = g_y = 25$ Pixel und der Überlappungsfaktor $f = 1$). Die Färbung der einzelnen Elemente entspricht ihrem prozentualen Füllungsgrad. Die Farbpalette reicht von grün (Gitterelement ist vollständig mit Objektpixeln gefüllt) bis rot (Gitterelement enthält nur ein Objektpixel).

Die Gittereigenschaften werden von vier Parametern beeinflusst:

Gitterkonstante g_x und g_y : Der Gitterkonstante (Abstand der Gitterelementmittelpunkte) in x -Richtung wird mit dem Parameter g_x , die in y -Richtung mit g_y bezeichnet. Die Gitterkonstanten können absolut oder relativ zur Objektgröße gewählt werden. Letzteres ist sinnvoll, um den Einfluß der Objektgröße auf den zu bildenden Score zu minimieren. Als Beispiel sei die Identifikation des malignen Melanoms genannt. Benigne wie maligne melanozytäre Hautveränderungen weisen Areale mit gewissen Strukturen auf (z.B. Netze, Streifen). Die Größe von verschiedenen melanozytären Hautveränderungen schwankt beträchtlich. Mit einer zu kleinen Gitterkonstante kann die Größe der Strukturen nicht mehr richtig erfaßt werden. Ist andererseits die Gitterkonstante zu groß, werden bei kleinen Hautveränderungen zu wenig Gitter generiert um die Läsion adäquat abzudecken. Eine Anpassung der Gitterkonstanten an die Objektgröße ist in diesem Fall sinnvoll (vgl. Abschnitt 8.7.14, Seite 139).

Überlappungsfaktor f : Dieser Parameter beeinflusst die Kantenlänge der einzelnen Gitterzellen. Die Kantenlänge eines Gitterelements wird durch $f \cdot g$ ($f > 0$) bestimmt. Gilt $f < 1$, so wird das zu untersuchende Objekt nicht vollständig durch das Gitter überdeckt. Die Quantifizierung anhand dieser Parameterwahl hat einen Stichprobencharakter und kann insbesondere bei großen Objekten zur Reduzierung der Rechenzeit verwendet werden. Die Wahl $f = 1$ resultiert in Gitterelementen, die das Objekt in disjunkte Bereiche aufteilen. Für $f > 1$ überlappen sich die einzelnen Gitterelemente.

Geometrie der Gitterelemente Die Gitterelemente haben naheliegenderweise eine quadratische Form. Möglich sind auch andere Geometrien wie zum Beispiel Rechtecke oder Ellipsen. Auch eine adaptive Aufteilung nach einem Homogenitätskriterium ist möglich. Dann muß allerdings die Eindeutigkeit der Aufteilung im Sinne der Reproduzierbarkeit des Ergebnisses gewährleistet sein.

Jedes Gitterelement bedeckt einen gewissen Bereich des Objekts. Für dieses Gebiet wird nun lokal die Ausprägung der zu untersuchenden Eigenschaft M bestimmt. Um die Pixel in den einzelnen Gitterelementen hinsichtlich Merkmal M zu charakterisieren, sollte in der Regel dieselbe Vorschrift verwendet werden, die auch zur Quantifizierung der Eigenschaft M für das gesamte Objekt benutzt wird. Zur quantitativen Charakterisierung der Homogenität bezüglich Merkmal M wird die Verwendung der Standardabweichung der lokalen Gitterscores vorgeschlagen. Diese Wahl ist darin begründet, daß sich mit abnehmender Homogenität die Gitterscores zunehmend unterscheiden und damit die Standardabweichung steigt. Mit diesem Vorgehen wird die Homogenität der Häufigkeitsverteilung charakterisiert. Die räumliche Beziehung der Gitterscores untereinander findet keine Berücksichtigung.

Es ist möglich, daß manche Gitterelemente nur mit sehr wenigen Objektpixeln gefüllt sind. Die Beurteilung des Merkmals M in einem Gitterelement anhand im Extremfall nur eines Objektpixels kann statistisch nicht mit der Beurteilung des Merkmals in einem vollständig gefüllten Gitterelement verglichen werden. Daher wird jedem Gitterelement i ein Gewicht w_i zugeordnet, daß dem "Füllungsgrad" des Gitterelements mit Objektpixeln entspricht. In dieser Arbeit wurde zur Bestimmung der Gewichte ein Verfahren gewählt, in dem die Gewichte linear von der Anzahl der im Gitter i vorhandenen Objektpixel l_i abhängen:

$$w_i = \frac{l_i}{g_x \cdot g_y} \quad (3.5)$$

Der Nenner von Gleichung 3.5 gibt die Anzahl der maximal möglichen Objektpixel wieder, die durch das Gitterelement abgedeckt werden können.

Zur Berechnung der Standardabweichung muß zunächst der gewichtete Mittelwert μ_M^w [BSMM95] der Gitterscores berechnet werden. Dabei bezeichne v_M^i den das Gitterelement i hinsichtlich M charakterisierenden Score:

$$\mu_M^w = \frac{\sum_i w_i \cdot v_M^i}{\sum_i w_i} \quad (3.6)$$

Wird mit n die Anzahl der Gitter bezeichnet, dann ergibt sich das Gesamtmaß M_H für

die Homogenität der Eigenschaft M zu:

$$M_H = \sqrt{\frac{1}{n-1} \sum_i w_i (\mu_M^w - v_M^i)^2} \quad (3.7)$$

Abbildung 3.2 zeigt an einem Beispiel die Aufteilung eines Objekts in Gitterelemente. Die Gitterkonstante beträgt $g_x = g_y = 25$ Pixel bei einem Überlappungsfaktor $f = 1$. Der Schwerpunkt des Objekts ist mit einem roten Kreis und die geometrischen Symmetrieachsen des Objekts mit blauen Linien gekennzeichnet. Die Färbung der Gitterelemente entspricht dem jeweiligen Füllungsgrad. Grün signalisiert eine vollständige Füllung des Gitterelements mit Objektpixeln. Mit abnehmendem Füllungsgrad drifft der Farbton zunehmend ins Rötliche.

3.3 Bestimmung der Symmetrieeigenschaften

Neben der Bestimmung der Homogenität der Verteilung eines Merkmals M ist auch die Frage nach der Beurteilung der symmetrischen Verteilung von M bezüglich der Objektsymmetrieachsen zu beantworten. Dazu werden zwei verschiedene Vorgehensweisen vorgeschlagen. Gemeinsam ist beiden die Bezugnahme auf die geometrischen Symmetrieachsen des Objekts. Die Verfahren unterscheiden sich jedoch in ihrem Skalenbezug. Während die eine Ausführung die lokalen Charakterisierungen (Scores) von Pixeln in achsensymmetrischer Lage vergleicht, wird bei der zweiten das Objekt ähnlich wie bei der Bestimmung der Homogenität gitterartig aufgeteilt. Jedem der Gitterelemente wird ein eigener Score basierend auf den in ihm enthaltenen Pixelscores zugewiesen. Die Quantifizierung der Symmetrie bezüglich M vergleicht dann die Scores von Gitterelementen in achsensymmetrischer Lage.

Dieses Vorgehen ist nur bei einer speziellen Klasse von Objekten anwendbar. Diese Objekte lassen sich dadurch charakterisieren, daß die äußere Form des Objekts relativ einfach strukturiert sein muß (beispielsweise kreis- oder ellipsenförmig). Weiterhin darf das zu untersuchende Merkmal über das Objekt hinweg nur geringe und gewisserweise auch stetige Veränderungen aufweisen. Abrupte Änderungen in der Ausprägung des Merkmals, wie sie etwa bei einem schachbrettähnlichen Objekt oder einem stark strukturierten technischen Bauteil vorkommen, führen zu unbefriedigenden Ergebnissen. Anwendungsbeispiele für die nachfolgend beschriebenen Methoden zur Symmetriebeurteilung eines Merkmals M sind die Klassifikation pigmentierter Hautveränderungen (Kapitel 8, Seite 87) oder die Beurteilung des Heilungsprozesses offener Wunden.

3.3.1 Pixelbezogene Symmetrie

Grundidee dieser Variante ist der direkte Vergleich der Charakterisierungen von Pixeln in achsensymmetrischer Lage, wie sie ähnlich in [SLM92] beschrieben wird. Dazu werden zunächst die Symmetrieachsen g_1 und g_2 gemäß Abschnitt 3.1 berechnet. Durch jede der beiden Symmetrieachsen g_i ($i = 1, 2$) wird das Objekt in zwei Hälften geteilt. Für jedes Pixel p einer Objekthälfte wird festgestellt, ob es ein achsensymmetrisches Pendant p' hat. Dies ist der Fall, wenn im Binärbild das Pixel an der achsensymmetrischen Position bezüglich der Symmetrieachse g_i den Wert 1 aufweist. Durch die diskrete Struktur eines digitalen Bildes ist

die Bestimmung der achsensymmetrischen Position oft nicht direkt möglich. Daher werden beispielsweise Nearest-Neighbor-Algorithmen verwendet, um die reellwertigen Positionskordinaten an das diskrete Koordinatensystem anzupassen.

Diejenigen Pixel p einer Objekthälfte, zu denen ein achsensymmetrisches Pendant p' bezüglich Achse g_1 existiert, werden in der Menge \mathcal{P}^1 zusammengefaßt. Die Menge \mathcal{P}^2 wird analog gebildet. Um die Scores $f(p)$ und $f(p')$ bezüglich M der Pixel p und p' vergleichen zu können, wird eine Ähnlichkeitsfunktion $s(f(p), f(p'))$ definiert, die die Eigenschaften einer Metrik erfüllen muß:

- $s(x, y) = 0 \Leftrightarrow x = y$
- $s(x, y) = s(y, x)$
- $s(x, z) \leq s(x, y) + s(y, z)$

Für beide Symmetrieachsen g_1 und g_2 wird der Mittelwert des Ähnlichkeitsmaßes für alle Pixel aus \mathcal{P}^1 bzw. \mathcal{P}^2 bestimmt:

$$M_{S_P}^i = \frac{1}{|\mathcal{P}^i|} \sum_{p \in \mathcal{P}^i} s(f(p), f(p')) \quad i = 1, 2 \quad (3.8)$$

$M_{S_P}^1$ ist also ein Maß der Symmetrie des Merkmals M bezüglich Achse g_1 ($M_{S_P}^2$ analog). Der Index P soll an die Pixelbezogenheit des Verfahrens erinnern. Anhand der beiden Werte $M_{S_P}^1$ und $M_{S_P}^2$ wird der Gesamtscore M_{S_P} für die pixelbezogene Symmetrie des Merkmals M bestimmt. Die genaue Vorschrift zur Bestimmung von M_{S_P} kann aufgabenspezifisch verschieden sein. Im Allgemeinen charakterisiert der größere Wert von $M_{S_P}^i$ das Objekt treffender, da sich Objekte meist anhand der höheren Asymmetrie leichter differenzieren lassen als mit der niedrigeren. Daher wird vorgeschlagen, den Gesamtscore M_{S_P} folgendermaßen zu bilden:

$$M_{S_P} = \max(\{M_{S_P}^1, M_{S_P}^2\}) \quad (3.9)$$

3.3.2 Felderbezogene Symmetrie

In manchen Anwendungen ist der direkte Vergleich von pixelbezogenen Scores in achsensymmetrischer Lage nicht sinnvoll. Als Beispiel mag die Symmetrie von Strukturelementen bei melanozytären Hautveränderungen dienen (vgl. Abschnitt 8.3, Seite 88). Linien, die zusammen netzartige Strukturen formen, sind meist nur wenige Pixel breit. Daher wäre es oft nur Zufall, wenn das achsensymmetrische Pendant eines Linienpixels ebenfalls Bestandteil einer Linie wäre. In solchen Fällen wird zur Beurteilung der Symmetrie eines Merkmals M das Objekt gitterartig aufgeteilt und die Ausprägung von M gitterspezifisch bestimmt. Jedem Gitterelement ist somit ein eigener Score zugeteilt. Durch Vergleich dieser Scores von Gitterelementen in achsensymmetrischer Lage läßt sich die Symmetrie bezüglich des Merkmals M beurteilen.

Dazu wird wie in Abschnitt 3.2 das Objekt, ausgehend von seinem Schwerpunkt (\bar{x}, \bar{y}) und entlang seiner Symmetrieachsen (vgl. Abschnitt 3.1), mit einem regelmäßigen Gitter überzogen. Für jedes einzelne Gitterelement G_i wird ein lokales, die Eigenschaft M beschreibendes

Maß v_M^i errechnet. Als Maß für die felderbezogene Symmetrie wird die mittlere Scoredifferenz von Gittern in achsensymmetrischer Lage verwendet.

Analog zum Vorgehen bei dem pixelweisen Vergleich werden dazu die Mengen \mathcal{G}^1 und \mathcal{G}^2 bestimmt. \mathcal{G}^1 enthält diejenigen Gitterelemente einer Objekthälfte, zu denen bezüglich der Symmetrieachse g_1 ein achsensymmetrisches Pendant existiert. Dies ist dann der Fall, wenn das Gitterelement in achsensymmetrischer Lage mindestens ein Objektpixel enthält. \mathcal{G}^2 wird analog gebildet. Um einem unterschiedlichen Füllungsgrad der zu vergleichenden Gitter Rechnung zu tragen, werden ähnlich wie in Abschnitt 3.2 die Scoredifferenzen gewichtet. Gitter in achsensymmetrischer Lage, die nur wenig Objektpixel enthalten, sollen ein niedriges Gewicht erhalten. Dazu wird jedem Gitter ein Gewicht nach Gleichung 3.5 zugeteilt. Die zu bildende Scoredifferenz aus den lokalen Scores der Gitter in achsensymmetrischer Lage wird mit dem Minimum der zugehörigen Gewichte multipliziert. Aus den Differenzen wird wie bei der pixelbezogenen Variante (Gleichung 3.8) mittels einer Ähnlichkeitsfunktion $s(v_M^i, v_M^{i'})$ ein achsenspezifischer Score gebildet. In der folgenden Gleichung werden mit w_i und $w_{i'}$ die Gewichte von Gittern in achsensymmetrischer Lage symbolisiert:

$$M_{S_G}^i = \frac{1}{w_i^+} \sum_{j \in \mathcal{G}^i} \min(\{w_i, w_{i'}\}) \cdot s(v_M^j, v_M^{j'}) \quad i = 1, 2 \quad (3.10)$$

Der Index G bezeichnet die Abstützung des Verfahrens auf Gitter. Der Term w_i^+ symbolisiert die Summe der verwendeten Gewichte:

$$w_i^+ = \sum_{j \in \mathcal{G}^i} \min(\{w_i, w_{i'}\}) \quad i = 1, 2 \quad (3.11)$$

Ähnlich wie in Gleichung 3.9 wird aus diesen Werten der Gesamtscore M_{S_G} gebildet:

$$M_{S_G} = \max(\{M_{S_G}^1, M_{S_G}^2\}) \quad (3.12)$$

Kapitel 4

Strukturen

Grauwertunterschiede oder die Dynamik der Farbwerte sind grundlegende Beschreibungsgrößen eines Objekts. Der Aspekt der Vielfalt oder Homogenität der Farben wird in Kapitel 6 untersucht. Strukturen sind konstituierende Bestandteile von Bildobjekten und sie manifestieren sich ebenfalls in Grauwert- oder Farbdifferenzen. Es werden Verfahren vorgestellt, die es erlauben, Strukturen in Bildern sowohl zu detektieren als auch quantitativ zu charakterisieren. Sie basieren auf strukturellen Komplexitätsmaßen und finden ihre Realisation in der Skalierungs-Index-Methode (SIM), ihrer anisotropen Variante (der Skalierungs-Vektor-Methode) und in daraus abgeleiteten Verfahren, die in dieser Arbeit erstmals vorgestellt, angewendet und diskutiert werden. Mit Hilfe der rotationsinvarianten anisotropen Skalierungsindizes werden Pixel richtungsabhängig bezüglich der sie umgebenden Struktur charakterisiert. Eine Verallgemeinerung von SIM stellt der fuzzy SIM-Ansatz (fSIM) dar. Er liefert in den untersuchten Beispielen eine genauere Beschreibung von Strukturen und ermöglicht damit eine bessere Detektionsrate verrauschter Strukturen. Neben der analytischen Definition von fSIM wird eine analoge neuronale Architektur sowie ein dazugehöriges Lernverfahren beschrieben. Zur Unterscheidung von Strukturen, die nur gering in ihren Grauwerten differieren, wird das TDE-SIM-Verfahren vorgestellt. Jede Methode wird an einem oder mehreren Beispielen bezüglich ihrer strukturcharakterisierenden Eigenschaften untersucht.

Einleitend wird auf den Begriff der Entropie eingegangen, der in dieser Arbeit an vielen Stellen Verwendung findet. Anhand dieses Informationsmaßes lassen sich weitere strukturelle Komplexitätsmaße definieren und stehen damit im Zusammenhang mit der Skalierungs-Index-Methode und den in diesem Kapitel beschriebenen Derivaten.

4.1 Information und Entropie

Da in dieser Arbeit an vielen Stellen Entropiemaße bei der Merkmalsquantifizierung Verwendung finden, soll an dieser Stelle dieses Informationsmaß diskutiert werden. Im Zentrum der Betrachtungen steht der Begriff *Information*. In der Literatur existieren verschiedene Charakterisierungen des Informationsbegriffs (ein Überblick ist in [EFS98] zu finden). Ebeling et al. [EFS98] beschreiben Information als “die Verminderung der Unbestimmtheit des Zustandes eines Systems”.

Eng verbunden mit der Information ist der Begriff der Nachricht. Bei syntaktischer Betrachtungsweise besteht eine Nachricht aus einer Symbolfolge, wobei die einzelnen Symbole aus einem Alphabet mit r Elementen stammen. Das Shannonsche Informationsmaß H beschreibt den mittleren Informationsgehalt eines Symbols (die *Entropie*) anhand der auftretenden Wahrscheinlichkeiten p_i der einzelnen Symbole i (Voraussetzung ist allerdings die statistische Unabhängigkeit der Wahrscheinlichkeiten untereinander):

$$H = - \sum_{i=1}^r p_i \log_2 p_i \quad (4.1)$$

Dieses Maß hat eine anschauliche Interpretation. Aus der Kenntnis der Wahrscheinlichkeiten p_i kann man eine optimale Strategie entwickeln, um mit einer Folge von Ja-Nein-Fragen das beobachtete Symbol i zu erfahren¹. Beträgt im Trivialfall die Wahrscheinlichkeit eines Symbols 1, so gilt $H = -1 \cdot \log_2 1 = 0$. Es wird beim sicheren Ereignis keine Frage benötigt, um das aktuelle Symbol zu identifizieren. Sind dagegen alle Symbole gleich wahrscheinlich ($p_i = \frac{1}{r}$), benötigt man die meisten Fragen, um zum korrekten Ergebnis zu gelangen: $H = - \sum_{i=1}^r \frac{1}{r} \cdot \log_2 \frac{1}{r} = \log_2(r)$. Die Shannon-Entropie gibt also die minimale Anzahl von Entscheidungsfragen wieder, die man im Mittel benötigt, um ein aufgetretenes Symbol zu identifizieren [LKP94]. Da der Logarithmus in Gleichung 4.1 die Basis 2 hat, wird diese Größe in *bit* erfaßt. Im Sinne des oben angesprochenen Bildes der Information als Verringerung der Unsicherheit läßt sich die Shannon-Information als mittlerer Entscheidungsgehalt pro beliebig herausgegriffenen Zeichen interpretieren.

Den Term $p_i \log_2 p_i$ in Gleichung 4.1 läßt sich auch als Gewichtung der einzelnen Wahrscheinlichkeiten interpretieren. Im linken Teil von Abbildung 4.1 ist die Funktion $f(p) = -p \cdot \log_2 p$ dargestellt. Es wird ersichtlich, daß sehr geringe und sehr hohe Wahrscheinlichkeiten in kleinen Funktionswerten resultieren. Dies bedeutet, daß die Shannon-Information bei der Summation über diese Bereiche wenig sensitiv ist. Mit der Rényi-Information q ter Ordnung [LKP94] [EFS98] steht ein verallgemeinertes Informationsmaß zur Verfügung, das

¹Zur Entwicklung dieser Strategie werden die bekannten Wahrscheinlichkeiten zum Aufbau eines Binärbaumes genutzt. Bei häufigen Symbolen ist man bestrebt, die Anzahl der Entscheidungen gering zu halten, für seltenere Symbole dagegen nimmt man mehr Entscheidungsfragen in Kauf. Daher wird der binäre Entscheidungsbaum so aufgebaut, daß die verbleibende Symbolmenge in den Knoten in zwei möglichst gleich wahrscheinliche Mengen aufgeteilt wird. Geht man von einer exakten Gleichwahrscheinlichkeit der Untermengen in den zwei Söhnen jedes Knotens aus und ist nach k Entscheidungen das Symbol i identifiziert, so beträgt seine Wahrscheinlichkeit $p_i = (\frac{1}{2})^k$. k läßt sich somit anhand der Wahrscheinlichkeit ausdrücken: $k = -\log_2 p_i$ [BG82].

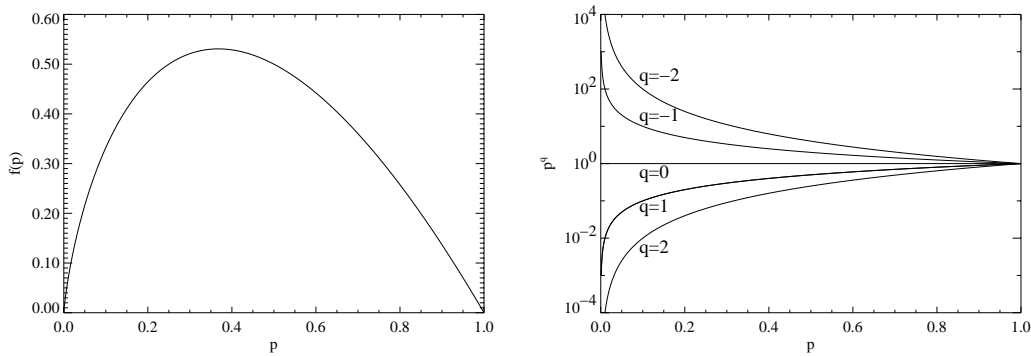


Abbildung 4.1: Illustration zu den Informationsmaßen: *Links*: Beitrag der einzelnen Wahrscheinlichkeiten p zur Bildung der Shannon-Information durch die Funktion $f(p) = -p \cdot \log_2 p$. *Rechts*: Betonung der einzelnen Wahrscheinlichkeitsbereiche bei der Bildung der Rényi-Information q ter Ordnung (nach [EFS98]).

eine selektive Betonung verschiedener Wahrscheinlichkeitsbereiche erlaubt:

$$H^q = \frac{1}{1-q} \log_2 \sum_{i=1}^r p_i^q \quad q \in \mathbb{R} \quad (4.2)$$

Im rechten Teil der Abbildung 4.1 ist der Einfluß unterschiedlicher q -Werte auf die Gewichtung der Wahrscheinlichkeit p dargestellt. Für $q > 0$ werden die hohen Wahrscheinlichkeiten zunehmend betont. Die Situation verkehrt sich für $q < 0$: geringe Wahrscheinlichkeiten erhalten ein höheres Gewicht. Interessant sind zwei Spezialfälle der Rényi-Information. Im Grenzwert für $q = 1$ geht die Rényi-Information in die Shannon-Information über: $\lim_{q \rightarrow 1} H^q = H$. Für $q = 0$ und mit der Definition $0^0 := 0$ bezeichnet H^0 die logarithmierte Anzahl der von 0 verschiedenen Wahrscheinlichkeiten.

Anhand der Shannon bzw. Rényi-Information lassen sich quantitative strukturelle Komplexitätsmaße ableiten [Wac95]. In diesem Zusammenhang ist auch die Skalierungs-Index-Methode (Kapitel 4.2 bis 4.5) und ihre Derivate zu sehen.

4.2 Isotrope und anisotrope Skalierungs-Indizes

Zur strukturellen Charakterisierung der lokalen Umgebung, in die ein Pixel eingebettet ist, stützen sich die Verfahren in diesem Kapitel auf strukturelle Komplexitätsmaße. Maße dieser Art lassen Aussagen über die Komplexität von Strukturen zu, die auf der Verteilung von Punkten in gegebenen Räumen beruhen [Wac95]. Die Skalierungs-Index-Methode und ihre anisotrope Variante sind Vertreter dieser Klasse. Diese beiden Verfahren werden zunächst vorgestellt und ihre Eigenschaften an einem einfachen Beispiel erläutert.

4.2.1 Skalierungs-Index-Methode

Die Skalierungs-Index-Methode (SIM) [WSV97], [Rät97], eine Realisation zur Bestimmung der Verteilung der punktweisen Dimension, erlaubt eine quantitative Beschreibung von Punkt-

verteilungen in beliebig dimensionierten Räumen. Für jedes Element der zu untersuchenden Punktmenge wird der sogenannte Skalierungsindex α , ein strukturelles Komplexitätsmaß, berechnet. Mit dem Skalierungsindex α wird der Punkt in Bezug zur lokalen Struktur, in die er eingebettet ist, charakterisiert.

Eine Punktverteilung X im d -dimensionalen Raum sei durch die Vektoren $\vec{x}_i = (x_i^1, x_i^2, \dots, x_i^d)$, $i = 1, \dots, k$ gegeben. Zur Berechnung von α bezüglich \vec{x}_i wird für verschiedene Radien r die Anzahl $N(\vec{x}_i, r)$ (*lokale Masse*) der Punkte \vec{x}_j bestimmt, die in seiner Umgebung mit Radius r liegen, wobei als Metrik in dieser Arbeit, soweit nicht explizit anders erwähnt, die Maximumsnorm ($p = \infty$) verwendet wird:

$$N(\vec{x}_i, r) = \sum_{j=1}^k \Theta(r - \|\vec{x}_i - \vec{x}_j\|_p) \quad (4.3)$$

Dabei ist Θ die sogenannte Heaviside-Funktion:

$$\Theta(x) = \begin{cases} 0 & \text{für } x \leq 0 \\ 1 & \text{für } x > 0 \end{cases} \quad (4.4)$$

Es wird nun angenommen, daß in einem bestimmten Intervall $[r_1, r_2]$, dem sogenannten Skalierungsbereich, die funktionale Abhängigkeit der lokalen Masse N von Radius r durch ein Potenzgesetz approximiert werden kann:

$$N(\vec{x}_i, r) \sim r^\alpha, \quad r \in [r_1, r_2] \quad (4.5)$$

Der Exponent α wird Skalierungsindex genannt. Diese Annahme soll an der in Abbildung 4.2 gezeigten Punktverteilung illustriert werden. Sie enthält eine punktartige und eine linienartige Struktur vor verrauschtem Hintergrund. Zur besseren Unterscheidbarkeit ist die Strukturzugehörigkeit der einzelnen Punkte in der Darstellung farbkodiert: das zufällig verteilte Hintergrundrauschen ist blau, die punktartige Struktur (Durchmesser: 30 Einheiten) braun und die linienartige Struktur (Breite: 30 Einheiten) grün markiert. Aus jeder dieser drei unterschiedlichen Strukturen wurde ein Punkt (im Bild rot gekennzeichnet) ausgewählt und die Anzahl der Punkte N in seiner lokalen Umgebung in Abhängigkeit vom Radius r bestimmt, wobei r von 1 bis 50 variiert wurde. Die großen Kästchen in Abbildung 4.2 markieren den maximalen Radius $r = 50$. Die resultierenden Kurven sind im rechten Teil der Abbildung 4.2 logarithmisch aufgetragen und tragen dieselbe Farbe wie die jeweiligen Strukturen im linken Teil der Abbildung. Beim Punkt aus der punktartigen Struktur (braun) zeigt sich bis zu Radius 15 ein starker Anstieg von $N(r)$. Die Kurve wird dann aber sehr flach: weitere Punkte kommen nur noch durch das Hintergrundrauschen hinzu. Übersteigt r also den Radius der punktartigen Struktur, so ist die Steigung der Kurve $N(r)$ in diesem Bereich 0. Die Charakteristik der Kennlinie des Punkts aus der linienartigen Struktur weist bis zu Radius 15 eine ähnlich starke Zunahme an Umgebungspunkten auf wie beim Punkt aus der punktartigen Struktur. Mit weiter zunehmenden Radius wird der Kurvenverlauf etwas flacher, aber wegen der Linienstruktur liegen immer noch viele Punkte in der lokalen Umgebung des untersuchten Punkts. Die Steigung der Kurve beträgt dort in etwa 1. Die Kennlinie des Punkts aus dem Hintergrundrauschen weist ab einem Radius von ungefähr 10 den stärksten

Anstieg auf. Aus diesem Beispiel wird deutlich, daß die Kennlinien von Punkten aus unterschiedlichen Strukturen in einem bestimmten Radienintervall einen die lokale Umgebung charakterisierenden Verlauf nehmen.

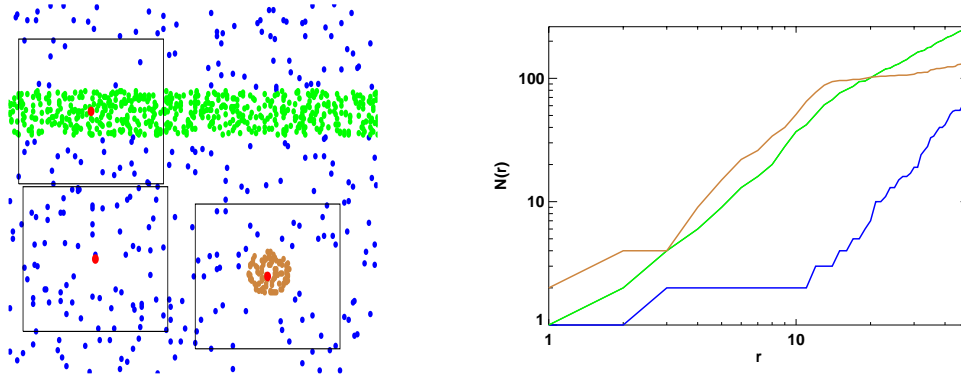


Abbildung 4.2: *Illustration zur strukturbeschreibenden Eigenschaft von SIM*: Links ist eine zweidimensionale Punkteverteilung dargestellt, in der zur besseren Übersicht die Strukturzugehörigkeit der Punkte farbkodiert ist. Zufällig verteilte Hintergrundpunkte sind blau, die Punkte der punktierten Struktur braun und die der linienhaften Struktur grün markiert. Zu je einem Punkt jeder Struktur (durch rote Farbe hervorgehoben) wird die Anzahl der Punkte N in seiner Umgebung in Abhängigkeit vom Radius r bestimmt. r wurde von 1 bis 50 variiert. Der maximale Radius ist im linken Bild jeweils durch ein Kästchen gekennzeichnet. Im rechten Bild ist die Anzahl der Nachbarnpunkte in Abhängigkeit von r dargestellt. Die Linien sind farblich wie die Strukturen im linken Bild gezeichnet. Deutlich werden die unterschiedlichen Charakteristika der einzelnen Kurven.

Eine lineare Näherung von α erhält man durch Berechnung des Differenzenquotienten der lokalen Massen bei r_1 und r_2 ($r_1 < r_2$) im log / log-Diagramm:

$$\alpha(\vec{x}_i, r_1, r_2) = \frac{\log N(\vec{x}_i, r_2) - \log N(\vec{x}_i, r_1)}{\log r_2 - \log r_1} \quad (4.6)$$

Gleichung 4.6 kann auch als lokaler isotroper Dichtegradient der Umgebung des Punktes \vec{x}_i gelesen werden. Dies verdeutlicht den strukturbeschreibenden Charakter der Skalierungs-Index-Methode, wie er sich auch in Abbildung 4.2 beobachten läßt. Bei punktierten Strukturen ist ab einem gewissen Radius kein weiterer Punktezuwachs mehr zu verzeichnen: der Skalierungsindex α beträgt 0. Bei linienartiger Struktur erhält man einen Skalierungsindex von 1, usw. Für zufällig verteilte Punkte im betrachteten d -dimensionalen Raum ist $\alpha \approx d$. Diese Aussagen für einen Punkt \vec{x}_i sind allerdings nur innerhalb des durch die Radien r_1 und r_2 gewählten Skalierungsbereiches gültig. Bei genügend großem Radius sind alle Punkte der untersuchten Punkteverteilung in der lokalen Umgebung von \vec{x}_i enthalten.

Die Wahl der Radien r_1 und r_2 bestimmt die Größenskala, auf der Strukturen charakterisiert werden. So liegen beispielsweise in der Umgebung eines Punktes \vec{x}_i bei einem zu kleinen Radiensatz r_1 und r_2 keine weiteren Punkte in der durch r_2 definierten Umgebung. Der Skalierungsindex beträgt 0, \vec{x}_i gehört demnach also einer punktierten Struktur an. Bei einem sehr großen Radius liegen fast alle Punkte in der durch r_2 definierten Umgebung. Die Radien sollten also so gewählt werden, daß die Größenskala der gesuchten Strukturen durch die Radien erfaßt werden können.

Die Skalierungs-Index-Methode läßt sich direkt auf Probleme der Bildverarbeitung übertragen. In einem Binärbild ist ein Punkt durch 2 Koordinaten (x - und y -Koordinate) definiert, im Grauwertbild durch 3 Koordinaten (x -, y -Koordinate und Grauwert g), im Farbbild durch 5 Koordinaten, etc. Ein Pixel ist somit als Punkt in einem d -dimensionalen Raum interpretierbar.

Bei Betrachtung des Punktes \vec{x}_i legen die beiden Radien r_1 und r_2 sowohl die lokale Umgebung im diskreten Bildgitter (x - und y -Koordinate) fest als auch, im Falle eines Grauwertbildes, die lokale Umgebung bezüglich des Grauwertes. Statt dieser festen Radienzuordnung für die Koordinatenachsen "Position" und "Grauwert" des Pixels kann es bei manchen Anwendungen von Vorteil sein, Alternativen zu verwenden. Ohne Anspruch auf Vollständigkeit werden im folgenden vier mögliche Verfahren beschrieben, wobei auf Grauwertbilder Bezug genommen wird. Die Verallgemeinerung auf mehrkanalige Bilder ergibt sich aus den Beschreibungen. Die im folgenden dargestellten Verfahren verwenden die Radien r_1 und r_2 für das diskrete Bildgitter und r_1^g bzw. r_2^g für die Bestimmung der lokalen Umgebung bezüglich der Grauwertachse.

Lineare Skalierung Die Grauwerte werden mit einem Faktor $f > 0$ skaliert. Dies entspricht einer Radienwahl für die Grauwerte von $r_1^g = f \cdot r_1$ und $r_2^g = f \cdot r_2$. Dieses Vorgehen ist angebracht, wenn mit r_1 und r_2 die vorhandene Grauwertdynamik nur ungenügend erfaßt werden kann.

Nichtlineare Skalierung Bei dieser Vorgehensweise werden die Grauwerte mit einer nicht-linearen Funktion wie beispielsweise der Logarithmus-Funktion transformiert.

Radienspezifische Skalierung Hier erfolgt die Skalierung der Grauwerte unterschiedlich für r_1 und r_2 . Im linearen Fall ergeben sich die Grauwerradien aus $r_1^g = f_1 \cdot r_1$ und $r_2^g = f_2 \cdot r_2$. Um zu gewährleisten, daß $r_1^g < r_2^g$ gilt, müssen folgende Einschränkungen gemacht werden: $f_i > 0$ ($i = 1, 2$) und $f_1 < f_2$. Diese Technik findet zum Beispiel bei TDE-SIM (Abschnitt 4.5, Seite 56) Anwendung.

Grauwertäqualisation Die Grauwerte des zu untersuchenden Bildes werden so verändert, daß die einzelnen Grauwertstufen in vorgegebenen Intervallen gleichhäufig verteilt sind. Diese Technik hat den Vorteil, daß die vorhandene Grauwertskala durch die Gleichverteilung der Grauwerte voll genutzt wird. Auch hier empfiehlt es sich, gesonderte Radien r_1^g und r_2^g zu verwenden.

In dieser Arbeit werden, soweit nicht gesondert vermerkt, r_1 und r_2 sowohl für die x - und y -Achse als auch für die Grauwertachse verwendet.

Bei digitalen Bildern ergibt sich durch die Anordnung der Pixel in einer matrixartigen Struktur folgendes Problem am Bildrand. Die lokale Umgebung von Pixeln am Bildrand erstreckt sich im x - y -Gitter teilweise über das Bild hinaus, ist aber dort nicht definiert. Zur Lösung dieses Problems kann das Bild beispielsweise periodisch fortgesetzt oder der Randbereich gespiegelt werden. In Ermangelung genauerer Informationen über das untersuchte Bild wird in dieser Arbeit die lokale Umgebung so verkleinert, daß sie noch innerhalb des Bildes liegt. Dieses Vorgehen führt allerdings zu dem sogenannten Randeffect. Der Punktezuwachs

in der durch r_2 definierten und am Bildrand verkleinerten Umgebung ist relativ gering. Als Folge ist im Allgemeinen ein geringerer Skalierungsindex zu beobachten.

4.2.2 Anisotrope Skalierungsindizes

Eine Erweiterung der Skalierungs-Index-Methode stellen die anisotropen Skalierungsindizes [Rät97] [RM97] dar. Durch Projektion der lokalen Massen auf eine der d Koordinatenachsen wird eine Richtungsabhängigkeit erreicht (t symbolisiert die untersuchte Koordinatenachse):

$$N_t(\vec{x}_i, r_1, r_2) = \sum_{j=1}^k \Theta(r_1 - \|x_i^t - x_j^t\|_p) \Theta(r_2 - \|\vec{x}_i - \vec{x}_j\|_p), \quad t = 1, \dots, d \quad (4.7)$$

Im ersten Term dieser Gleichung findet die Projektion von \vec{x}_i auf die t -te Koordinatenachse statt; die zweite stellt sicher, daß Punkte nur aus der lokalen Umgebung (definiert durch r_2) ausgewählt werden.

Wie bei den isotropen Skalierungsindizes wird der Zuwachs von N_t durch ein Potenzgesetz approximiert:

$$N_t \sim r^{\alpha_t(\vec{x}_i)} \quad (4.8)$$

Der anisotrope Skalierungsindex α_t wird wieder über den logarithmierten Differenzenquotienten der projizierten Massen bestimmt:

$$\alpha_t(\vec{x}_i, r_1, r_2) = \frac{\log N_t(\vec{x}_i, r_2, r_2) - \log N_t(\vec{x}_i, r_1, r_2)}{\log r_2 - \log r_1} \quad (4.9)$$

Neben der Information über die Art der Punktverteilung enthält der anisotrope Skalierungsindex auch Informationen über deren Lage bezüglich der Koordinatenachsen. So hat eine linienartige Struktur, die in einem zweidimensionalen Raum senkrecht zur x-Achse steht, die Skalierungsindizes $\alpha_x \approx 0$ und $\alpha_y \approx 1$. Anwendungsabhängig kann man auch an einer anisotropen Charakterisierung der Punkteverteilung interessiert sein, die unabhängig von der Orientierung der Struktur zu den Koordinatenachsen ist. Ein solches rotationsinvariantes Verfahren wird in Abschnitt 4.3 (Seite 29) vorgestellt.

4.2.3 Beispiel

Zur Veranschaulichung der Eigenschaften isotroper und anisotroper Skalierungsindizes dient das in Abbildung 4.3 gezeigte Binärbild (256×256 Pixel). Es zeigt eine waagrechte und eine senkrechte Linie, die jeweils eine Breite von 20 Pixeln aufweisen, sowie eine kreisförmige Struktur mit einem Durchmesser von 15 Pixeln. Zur Erzeugung des Rauschens wurden Punkte mit einem Zufallsalgorithmus räumlich gleich verteilt.

Das Testbild wurde zunächst mit der Skalierungs-Index-Methode unter Verwendung der Maximumsnorm (vgl. Gleichung 4.3) analysiert. Als Parameter wurden $r_1 = 10$ und $r_2 = 20$ verwendet. Diese Wahl liegt in der Größe der Bildobjekte begründet, da sich damit die Größenskala der vorhandenen Objekte erfassen läßt. Es sei noch einmal betont, daß die Wahl der Radien die Skala bestimmt, auf der die lokalen Umgebungen der Pixel charakterisiert werden.




Abbildung 4.3: Binäres Testbild (256×256 Pixel) mit zwei Linien (Breite: 20 Pixel) unterschiedlicher Ausrichtung und einer kreisförmigen Struktur (Durchmesser: 15 Pixel).

Das sogenannte $P(\alpha)$ -Spektrum, die relative Häufigkeitsverteilung der Skalierungsindizes aller Punkte, ist in der linken Hälfte der Abbildung 4.4 zu sehen; rechts daneben ist das Ausgangsbild dargestellt. Die Farben der einzelnen Punkte im rechten Teil der Abbildung referieren auf die Farbkodierung im $P(\alpha)$ -Spektrum. Deutlich wird die strukturcharakterisierende Eigenschaft von SIM: Pixel der kreisförmigen Struktur sind schwarz ($\alpha \approx 0$), die linienhaften Strukturen ($\alpha \approx 1$) blau gekennzeichnet. Diese Eigenschaft läßt sich beispielsweise zur Separierung der unterschiedlichen Strukturen im Bild nutzen. So werden zur Erkennung von Linien diejenigen Pixel selektiert, die einen Skalierungsindex von ungefähr eins aufweisen. Prototypische Strukturen wie Punkte oder Linien liegen also in definierten Bändern des $P(\alpha)$ -Spektrums.

Durch die Zuweisung eines Skalierungsindex nahe 0 zu punktartigen Strukturen, von ungefähr 1 zu linienartigen Strukturen, usw. zeigt sich die strukturordnende Eigenschaft von SIM.

Im $P(\alpha)$ -Spektrum sind Punkte mit hohen Skalierungsindizes ($\alpha > 3$.) zu erkennen. Diese finden sich im farbkodierten Bild in der Umgebung der linienhaften und kreisförmigen Strukturen wieder. Dieser Effekt ist dadurch zu erklären, daß in der unmittelbaren Umgebung (definiert durch r_1) der Hintergrundpixel \vec{x}_i nur wenige weitere Pixel zu finden sind und damit $N(\vec{x}_i, r_1)$ einen relativ kleinen Wert hat. Die Anzahl der Punkte in der von r_2 definierten Umgebung erhöht sich drastisch durch die Pixel der großen Linien- oder Punktstrukturen. Bei Bildung des Differenzenquotienten (Gleichung 4.6) ergibt sich damit ein hoher Skalierungsindex. Dieses Phänomen soll in Analogie zur Beobachtung heller Ringe um astronomische Objekte wie Sonne oder Mond Halo-Effekt genannt werden.

Die Ergebnisse der Analyse des Testbilds mit den anisotropen Skalierungsindizes bei gleichem Skalierungsbereich zeigt Abbildung 4.5. Dargestellt ist jeweils das $P(\alpha_t)$ -Spektrum und das Ausgangsbild (t steht für die Koordinatenachse x oder y). Wie in der grafischen Aufbe-




Abbildung 4.4: *Analyse mit isotropen Skalierungsindizes.* Links: Das $P(\alpha)$ -Spektrum zum Binärbild aus Abbildung 4.3. Der Skalierungsbereich ist $r_1 = 10$ und $r_2 = 20$. Rechts: Die Farbwerte der Pixel des Ausgangsbildes kodieren den jeweiligen Skalierungsindex entsprechend der im $P(\alpha)$ -Spektrum definierten Farbtabelle. Deutlich wird die strukturcharakterisierende Eigenschaft von SIM.

reitung der Analyse mit der isotropen Skalierungs-Index-Methode ist der Skalierungsindex jedes Pixels durch die im $P(\alpha_t)$ -Spektrum definierte Farbtabelle kodiert. Die unterschiedlichen Ausrichtungen der linienhaften Strukturen lassen sich in den Spektren erkennen. Die Pixel der senkrechten Struktur besitzen einen anisotropen Skalierungsindex $\alpha_x \approx 0$, bei der waagrechten Struktur gilt $\alpha_x \approx 1$ (obere Reihe von Abbildung 4.5). Betrachtet man die anisotropen Skalierungsindizes in y-Richtung, drehen sich die Verhältnisse um (untere Reihe). Wie auch im isotropen Fall bilden sich Halo-Effekte (hohe Skalierungsindizes) in der Umgebung der Strukturen.




Abbildung 4.5: *Analyse mit anisotropen Skalierungsindizes*. Obere Reihe: $P(\alpha_x)$ -Spektrum (links) zum Binärbild aus Abbildung 4.3 ($r_1 = 10$, $r_2 = 20$). Rechts sind die Pixel durch die im $P(\alpha_x)$ -Spektrum definierte Farbtabelle entsprechend ihres Skalierungsindex markiert. Untere Reihe: $P(\alpha_y)$ -Spektrum (links). Im Ausgangsbild sind die Pixel durch den ihnen zugewiesenen Skalierungsindex farbkodiert (rechts).

4.3 Rotationsinvariante anisotrope Skalierungsindizes

Mit Hilfe der anisotropen Skalierungsindizes kann eine genauere Charakterisierung von Punktverteilungen vorgenommen werden, da die strukturellen Eigenschaften bezüglich der Lage zu den Koordinatenachsen quantifiziert werden. Schwierigkeiten ergeben sich allerdings bei nicht-achsenparallelen Strukturen. Diagonal verlaufende Linien werden nicht mehr korrekt bezüglich ihrer eigentlichen Ausdehnung erfaßt, wie dies oft erforderlich ist. Wie in Abschnitt 4.2.2 (Seite 25) beschrieben, ist dieses Verfahren nicht rotationsinvariant. Im folgenden wird eine Variante der anisotropen Skalierungs-Index-Methode vorgestellt, die Strukturen bezüglich ihrer Orientierung im untersuchten Raum anisotrop charakterisiert. Diese Skalierungsindizes sollen *rotationsinvariante anisotrope Skalierungsindizes* α_i^{rot} genannt werden. Aus Darstellungsgründen wird das Verfahren am Beispiel einer zu analysierenden linienartigen Struktur erläutert.

Um einen Punkt \vec{x}_i , der im Beispiel Teil einer Linienstruktur ist, bezüglich der Orientierung seiner lokalen Umgebung anisotrop zu charakterisieren, wird die lokale Umgebung von \vec{x}_i so gedreht, daß der Linienausschnitt parallel zur x -Achse verläuft. Anschließend wird der anisotrope Skalierungsindex von \vec{x}_i bezüglich des gedrehten Koordinatensystems berechnet.

Die Menge der Punkte $\vec{x}_j \in X_i^{\text{rot}}$, die in die Drehung bei der Untersuchung des Punktes \vec{x}_i miteinbezogen werden, ist durch r_2 definiert:

$$X_i^{\text{rot}} = \{\vec{x}_j \mid (x_i^x - r_2 \leq x_j^x \leq x_i^x + r_2) \wedge (x_i^y - r_2 \leq x_j^y \leq x_i^y + r_2)\} \quad (4.10)$$

x^x bezeichnet die x -Koordinate des Punktes \vec{x} (x^y analog). Die Bestimmung des lokalen Koordinatensystems zu \vec{x}_i erfolgt durch Hauptkomponentenanalyse (vgl. Abschnitt 3.1, Seite 12). Das j -te Element aus X_i^{rot} soll mit $\vec{x}_j^{\text{rot}_i}$ bezeichnet werden. Die rotationsinvarianten anisotropen Skalierungsindizes α_i^{rot} sind analog Gleichung 4.9 definiert:

$$\alpha_i^{\text{rot}}(\vec{x}_i^{\text{rot}_i}, r_1, r_2) = \frac{\log N_t(\vec{x}_i^{\text{rot}_i}, r_2, r_2) - \log N_t(\vec{x}_i^{\text{rot}_i}, r_1, r_2)}{\log r_2 - \log r_1} \quad (4.11)$$

Neben der strukturellen Charakterisierung der lokalen Umgebung eines Punktes \vec{x}_i erhält man als weitere Information die Orientierung seiner lokalen Umgebung in Bezug zur x -Achse.

Abbildung 4.6 zeigt ein Beispiel, an dem die Eigenschaften der rotationsinvarianten anisotropen Skalierungsindizes dargestellt werden. Die Abbildung (256×256 Pixel) zeigt eine S-förmige Struktur vor verrauschtem Hintergrund. Diese Figur soll nun hinsichtlich der strukturellen Eigenschaften in ihrer x - und y -Richtung analysiert werden. Dieses Bild wird mit der anisotropen Skalierungs-Index-Methode aus Abschnitt 4.2.2 mit Radien $r_1 = 12$ und $r_2 = 25$ analysiert. Die Wahl dieser Radien ist in der vorab bekannten Breite der Struktur (etwa 15 Pixel) begründet. Das Ergebnis der Analyse ist in Abbildung 4.7 zu sehen. Die achsenparallelen Elemente der Struktur sind eindeutig charakterisiert. Durch die gewundene Form werden aber die strukturellen Eigenschaften des "S" bei den nicht-achsenparallelen Abschnitten im Sinne der Aufgabenstellung nicht korrekt erfaßt.

Das Bild wird nun mit Hilfe der rotationsinvarianten anisotropen Skalierungsindizes bei gleicher Radienwahl analysiert. Die dazugehörigen Spektren sind in Abbildung 4.8 zu sehen. Im $P(\alpha_y^{\text{rot}})$ -Spektrum liegen die Skalierungsindizes der Pixel der "S"-Struktur wie erwartet




Abbildung 4.6: Testbild (256×256 Pixel) zur Untersuchung der rotationsinvarianten anisotropen Skalierungsindizes. Die Breite der S-förmigen Struktur beträgt ca. 15 Pixel.

nahe an 0. Die α_x^{rot} -Werte sind dagegen um den Wert 1 verteilt. Jedes Pixel wird damit bezüglich der es umgebenden Struktur adäquat quantifiziert. Dies spiegelt sich auch in der Form der $P(\alpha_i^{\text{rot}})$ -Spektren wider. Die Spektren der rotationsinvarianten anisotropen Skalierungsindizes sind wesentlich akzentuierter als die der anisotropen Charakterisierung.




Abbildung 4.7: *Analyse mit anisotropen Skalierungsindizes*. Obere Reihe: Links ist das $P(\alpha_x)$ -Spektrum zum Binärbild aus Abbildung 4.6 ($r_1 = 12$, $r_2 = 25$) dargestellt. In der rechten Darstellung kodieren die Farbwerte der Pixel des Ausgangsbildes den jeweiligen Skalierungsindex entsprechend der im $P(\alpha_x)$ -Spektrum definierten Farbtabelle. Untere Reihe: $P(\alpha_y)$ -Spektrum zum Binärbild aus Abbildung 4.6 ($r_1 = 12$, $r_2 = 25$). Rechts: Die Farben kodieren die Skalierungsindizes.

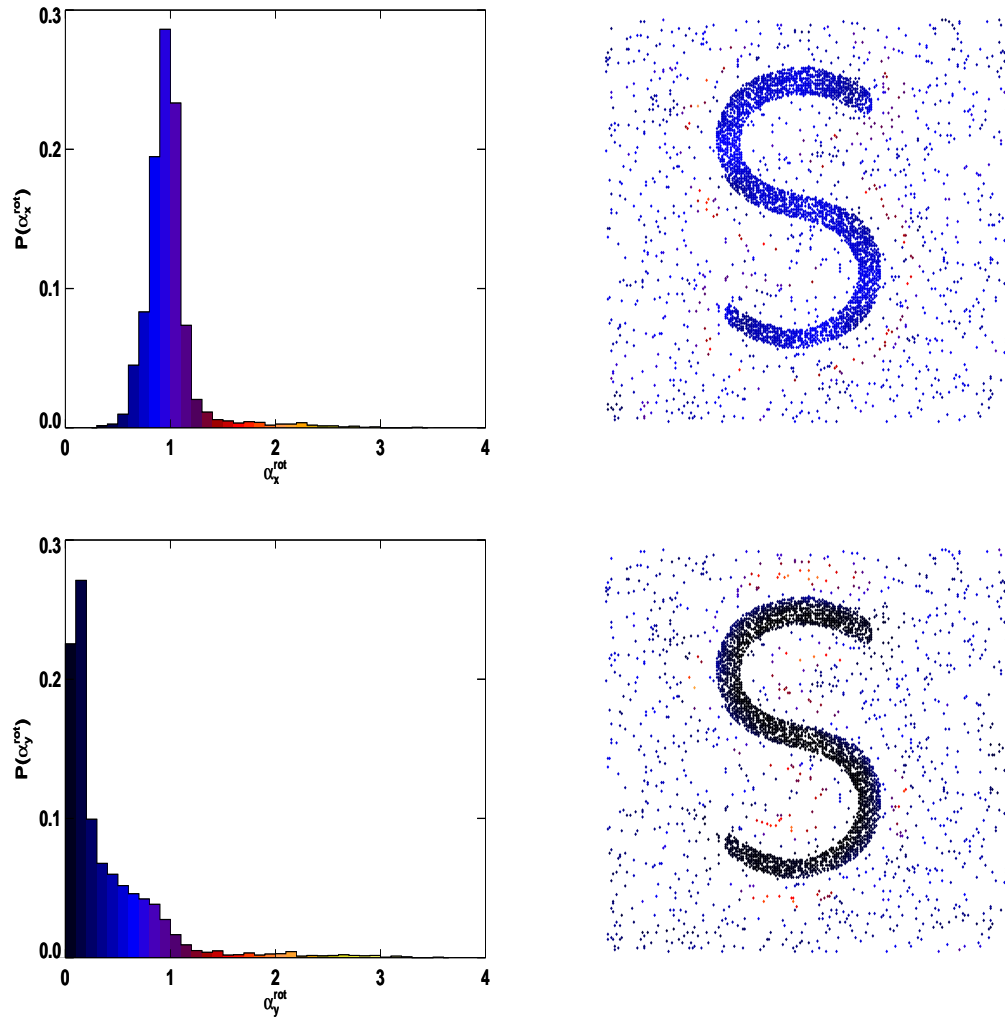


Abbildung 4.8: *Analyse mit rotationsinvarianten anisotropen Skalierungsindizes*. Obere Reihe: Links ist das $P(\alpha_x^{\text{rot}})$ -Spektrum zum Binärbild aus Abbildung 4.6 ($r_1 = 12$, $r_2 = 25$) dargestellt. In der rechten Darstellung kodieren die Farbwerte der Pixel des Ausgangsbildes den jeweiligen Skalierungsindex entsprechend der im $P(\alpha_x^{\text{rot}})$ -Spektrum definierten Farbtabelle. Untere Reihe: $P(\alpha_y^{\text{rot}})$ -Spektrum zum Binärbild aus Abbildung 4.6 ($r_1 = 12$, $r_2 = 25$). Rechts: Die Farben kodieren die Skalierungsindizes.

4.4 Fuzzy Skalierungsindizes (fSIM)

In den nachfolgenden Abschnitten wird eine Verallgemeinerung von SIM durch Fuzzifizierung der Zugehörigkeitsfunktion $\Theta(\vec{x})$ eingeführt. Dieses Verfahren wird mit fSIM bezeichnet. Es werden die Eigenschaften dieser Methode auf Binärbilder, das Detektionsverhalten auf veräuschte Grauwertbilder und eine Möglichkeit der Laufzeitverbesserung untersucht. fSIM hat eine neuronale Formulierung, die zusammen mit einem Lernalgorithmus beschrieben wird. Eine Diskussion vorhandener Probleme und Möglichkeiten schließt dieses Thema ab.

4.4.1 Motivation und Formalismus

Bei näherer Betrachtung von Gleichung 4.3 wird deutlich, daß das Zugehörigkeitskriterium zur Umgebung des Punktes \vec{x}_i binärer Natur ist. Mit der Funktion $\Theta(x)$ (Gleichung 4.4) wird überprüft, ob ein Punkt der lokalen Umgebung von \vec{x}_i angehört. Ein \vec{x}_i nahe gelegener Punkt wird gleichermaßen gewertet wie ein Punkt, der gerade noch innerhalb der lokalen Umgebung bezüglich Radius r liegt. Eine bessere strukturelle Charakterisierung der lokalen Umgebung eines Punktes \vec{x}_i wird von einer Gewichtung der Umgebungspunkte anhand der Abstände zu \vec{x}_i erwartet. Daher wird die "scharfe" Entscheidung durch eine "unscharfe" (*fuzzy*) Funktion ersetzt. Dies korrespondiert mit der Erfassung von Meßwerten in der Praxis. Meßwerte sind meist mit einem Fehler behaftet und liegen mit einer gewissen Wahrscheinlichkeit in der Umgebung des tatsächlichen Werts. Anstatt der binären Zugehörigkeitsfunktion der Form

$$\Theta : \mathbb{R} \rightarrow \{0, 1\} \quad (4.12)$$

wird eine fuzzy Zugehörigkeitsfunktion folgender Form verwendet, in die der Abstand eines Punktes \vec{x}_j zu \vec{x}_i , sowie der Parameter r zur Bestimmung der Größe der lokalen Umgebung eingeht:

$$m : \mathbb{R} \times \mathbb{R} \rightarrow [0, 1] \quad (4.13)$$

Da der Wertebereich von $\Theta(x)$ im Wertebereich von $m(x, r)$ enthalten ist, ist die binäre Zugehörigkeitsfunktion ein Spezialfall der unscharfen Abbildung.

Zur Modellierung von m stehen verschiedene Funktionen zur Verfügung [Gra95]. Da ein Umgebungspunkt mit zunehmender Nähe zu \vec{x}_i höher bewertet werden soll, werden zwei Eigenschaften für $m(x, r)$ vorausgesetzt: Die Zugehörigkeitsfunktion soll bei minimalen Abstand eines Punktes zu \vec{x}_i ihr Maximum annehmen und mit zunehmenden Abstand von \vec{x}_i monoton fallen. Stellvertretend seien zwei Funktionen genannt, die diese Eigenschaften besitzen und in Abbildung 4.9 (bei $r = 1$) zu sehen sind. Beiden Funktionen ist die Größe b gemeinsam, mit der die Breite des Bereichs hoher Funktionswerte beeinflusst und die Steilheit des Abfalls im Ansprechverhalten geregelt wird (vgl. Abbildung 4.9). b wird aus Gründen der Übersichtlichkeit nicht als Parameter geführt. Damit die Funktionen den geforderten Verlauf einer Zugehörigkeitsfunktion annehmen, muß $b \in \mathbb{N}^+$ gelten. Üblicherweise gilt $b = 1$ und wird nur in Sonderfällen mit einem anderen Wert belegt (siehe Seite 36).

Gaußsche Zugehörigkeitsfunktion:

$$m(x, r) = \exp\left(-\left(\frac{x}{r}\right)^{2b}\right) \quad (4.14)$$

Power Zugehörigkeitsfunktion:

$$m(x, r) = \frac{1}{1 + \left(\frac{x}{r}\right)^{2b}} \quad (4.15)$$

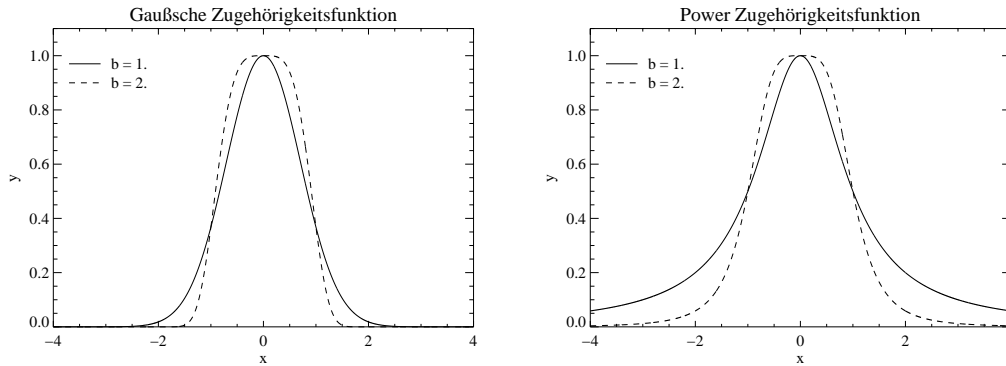


Abbildung 4.9: *Modellierung von Zugehörigkeitsfunktionen*: links: Gauß-Funktion, rechts: Power-Funktion. Der Parameter r ist jeweils 1.

Beide Funktionen nehmen bei $x = 0$ ihr Maximum von 1 an und fallen mit zunehmenden Abstand von x symmetrisch monoton ab. Sie unterscheiden sich darin, daß die Funktionswerte der Power-Funktion im Vergleich zur Gaußschen Zugehörigkeitsfunktion mit steigendem x langsamer abfallen. Dieses Verhalten bleibt auch bei einer Erhöhung von b erhalten. Für fSIM bedeutet dies, daß mit der Power-Funktion weiter von \vec{x}_i entfernt liegende Punkte stärker gewertet werden.

Abbildung 4.10 soll den Unterschied zwischen binärer und unscharfer Zugehörigkeitsfunktion verdeutlichen. Im linken Teil der Abbildung sind die zwei binären Zugehörigkeitsfunktionen bezüglich eines Punktes $x = 0$ dargestellt. Die erste abgebildete Funktion (durchgezogene Linie) markiert den Zugehörigkeitsbereich für $r_1 = 1$, die zweite (gestrichelte Linie) gilt für $r_2 = 2$. Die rechte Abbildung zeigt die fuzzy Zugehörigkeitsfunktionen (hier: Gaußsche) bei gleichem Parametersatz.

In vielen Anwendungen (z.B. *remote sensing*) werden die zu untersuchenden Objekte multispektral erfaßt. Dabei können die verschiedenen Aufnahmemodi unterschiedliche Rauschempfindlichkeiten aufweisen. Um dem Verfahren die Möglichkeit zu geben, die Koordinatenachsen hinsichtlich ihrer Bedeutung oder Zuverlässigkeit zu differenzieren, werden in den fSIM-Formalismus Gewichte eingeführt. Die Gewichtung der Grauwerte entspricht einer linearen Skalierung der Grauwertachsen entsprechend Abschnitt 4.2.1 (Seite 24). Durch den hier beschriebenen Mechanismus ist es darüberhinaus möglich, auch die diskreten x - und y -Koordinaten zu skalieren. Damit läßt sich beispielsweise die Bedeutung der Grauwerte gegenüber der Ortsinformation durch stärkere Gewichtung hervorheben. Zur Berechnung des Abstandes eines Punktes \vec{x}_j zu \vec{x}_i wird der Gewichtsvektor $\vec{w} = (w_1, \dots, w_d)$ verwendet. Mit w_l wird der Einfluß der Koordinatenachse l auf die Bildung des Skalierungsindex bewertet. Der minimale Einfluß einer Koordinatenachse ist 0: $w_l \geq 0$ ($l = 1, \dots, d$).




Abbildung 4.10: *Binäre und fuzzy Zugehörigkeitsfunktionen*: Links sind die binären Zugehörigkeitsfunktionen für $r_1 = 1$ (durchgezogene Linie) und $r_2 = 2$ (gestrichelte Linie) dargestellt. Rechts die fuzzy-Variante bei gleichem Parametersatz (es wurde die Gaußsche Zugehörigkeitsfunktionen verwendet).

Damit ergibt sich zur Berechnung der fuzzy Skalierungsindizes α^f folgender Formalismus. Die lokale Masse mit fuzzifizierter Zugehörigkeitsfunktion N^f ist analog zu Gleichung 4.3 definiert:

$$N^f(\vec{x}_i, r) = \sum_{j=1}^k m(\text{dist}_p^w(\vec{x}_i, \vec{x}_j), r) \quad (4.16)$$

Mit der Funktion $\text{dist}_p^w(\vec{x}_i, \vec{x}_j)$ wird der Abstand zwischen den Punkten \vec{x}_i und \vec{x}_j bestimmt:

$$\text{dist}_p^w(\vec{x}_i, \vec{x}_j) = \left(\sum_{l=1}^d w_l |x_i^l - x_j^l|^p \right)^{1/p}, \quad w_l \geq 0 \text{ für } l = 1, \dots, d \quad (4.17)$$

Falls die Funktion m erst für $x \rightarrow \infty$ gegen 0 konvergiert (wie es in den obigen zwei Beispielen der Fall ist), kann die Menge der möglichen Umgebungspunkte zu \vec{x}_i aus Rechenzeitgründen auf die lokale Umgebung, zum Beispiel definiert durch r_2 auf dem x - y -Gitter beschränkt werden. In dieser Arbeit wurde dieses Vorgehen bei allen Analysen mit fSIM gewählt. Weiterhin wurde, soweit nicht gesondert vermerkt, die Power-Zugehörigkeitsfunktion (Gleichung 4.15) verwendet und für alle Gewichte gilt $w_l = 1$.

Die Bestimmung des fuzzy Skalierungsindex α^f läßt sich somit zusammenfassen zu:

$$\alpha^f(\vec{x}_i, r_1, r_2) = \frac{\log N^f(\vec{x}_i, r_2) - \log N^f(\vec{x}_i, r_1)}{\log r_2 - \log r_1} \quad (4.18)$$

Kann nun bei diesem verallgemeinerten Formalismus auch ein Skalierungsverhalten angenommen werden? Im linken Teil von Abbildung 4.11 ist ein künstlich erzeugtes Bild zu sehen, an dem diese Frage untersucht werden soll. Das Bild (256×256 Pixel) enthält dieselben Strukturen wie das Beispiel aus Kapitel 4.2.3 (Seite 25, Breite der Linien: 20 Pixel, Durchmesser der punkartigen Struktur: 15 Pixel), ist aber ein Grauwertbild, das mit gaußförmigen Rauschen versehen wurde. Beispielhaft wurde je ein Pixel aus der linienhaften und der punkartigen Struktur untersucht. Für beide Punkte wurden die Funktionen $N(r)$

und $N^f(r)$ für $r = 1, \dots, 20$ für die binäre und die *fuzzy* Zugehörigkeitsfunktion berechnet. Die untersuchten Pixel sind im Bild durch den maximalen Skalierungsbereich in x - und y -Richtung gekennzeichnet. Als Zugehörigkeitsfunktion wurde die Gaußsche Funktion verwendet, wobei die möglichen Umgebungspunkte durch den Radius $r = 20$ begrenzt wurde. Im rechten Teil der Abbildung 4.11 ist die Funktion $N(r)$ für die Skalierungs-Index-Methode (schwarz) und für fSIM (rot) aufgetragen. Bei der Kennlinie des Pixels aus der linienhaften Struktur (durchgezogene Linien) ist bei beiden Verfahren eine Steigung von ca. 1 zu beobachten. Bei dem Pixel der punktartigen Struktur (gestrichelte Linien) ist bei beiden Kurven zunächst ein Ansteigen der Kennlinie zu erkennen. Wird mit Radius r die Ausdehnung der Struktur überschritten, fallen die Kurven in einen Sättigungsbereich. Interessant ist das Verhalten von fSIM bei maximalen Radius $r = 20$. Bei dem Pixel der punktartigen Struktur ist ein Ansteigen aus dem Sättigungsbereich zu erkennen. Dies läßt sich mit der Form der Zugehörigkeitsfunktion erklären. Im Beispiel wurde die Gaußsche Funktion verwendet. Da der Parameter $r = 20$ hier als σ der Gaußfunktion verwendet wird, zeigt die Funktion auch für weit entfernt liegende Punkte eine hohe Zugehörigkeit an. Dies führt zu der beobachteten Erhöhung von $N^f(r)$. Sucht man Strukturen auf diesen relativ großen Skalen, empfiehlt es sich daher, einen größeren Breitenparameter b (Gleichung 4.14 und 4.15) zu wählen. Dadurch wird eine erhöhte Aktivierung für nahe Punkte und steiler abfallende Flanken der Zugehörigkeitsfunktion erreicht. Insgesamt ist ein Skalierungsverhalten bei fuzzifizierter Zugehörigkeitsfunktion wie bei der binären Variante zu beobachten.


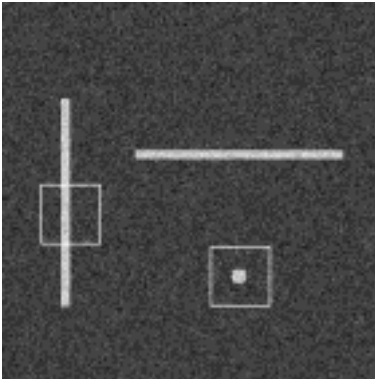


Abbildung 4.11: *Skalierungsverhalten von fSIM*: Links: Grauwertbild mit zwei linienhaften und einer punktartigen Struktur. Die zwei untersuchten Punkte sind durch den maximalen Skalierungsbereich in x - und y -Richtung markiert. Rechts: Die Funktion $N(r)$ bzw. $N^f(r)$ ($r = 1, \dots, 20$) für das Pixel aus der punktartigen Struktur (gestrichelte Linie) und für das Pixel aus der linienartigen Struktur (durchgezogene Linie). Die Kennlinien für SIM sind schwarz, die für fSIM sind rot eingezeichnet.

Anisotrope Variante

Mit dieser Verallgemeinerung lassen sich auch die anisotropen Skalierungsindizes mit fuzzy Zugehörigkeitsfunktion formulieren. Zu diesem Zweck wird die Funktion N_t^f analog zu

Gleichung 4.7 (Seite 25) definiert:

$$N_t^f(\vec{x}_i, r) = \sum_{j=1}^k m(w_t | x_i^t - x_j^t |, r) \quad (4.19)$$

Damit ergeben sich die fuzzy anisotropen Skalierungsindizes zu:

$$\alpha_t^f(\vec{x}_i, r_1, r_2) = \frac{\log N_t^f(\vec{x}_i, r_2) - \log N_t^f(\vec{x}_i, r_1)}{\log r_2 - \log r_1} \quad (4.20)$$

Auch hier kann zur Reduzierung der Rechenzeit der maximale Gültigkeitsbereich der Aktivierungsfunktion beispielsweise durch r_2 eingeschränkt werden.




Abbildung 4.12: Binäres Testbild mit zehn Linien unterschiedlicher Breite.

4.4.2 fSIM bei Binärbildern

Eine besondere Eigenschaft von fSIM läßt sich bei der Anwendung auf Binärbilder beobachten. Neben der quantitativen strukturellen Charakterisierung lassen sich auch Objekte gleicher Struktur aber verschiedener Größe unterscheiden. Dieser Effekt basiert auf der Abstands-Gewichtung der Objektpixel in der Umgebung zu Punkt \vec{x}_i .

An einem Beispiel soll diese Eigenschaft illustriert werden. Abbildung 4.12 zeigt zehn linienhafte Strukturen, deren Breite von einem bis zu zehn Pixel variiert. Dieses Bild wurde mit SIM und fSIM mit den Parametern $r_1 = 7$ und $r_2 = 12$ analysiert. Durch diese Parameterwahl lassen sich die Breiten der zu untersuchenden Objekte erfassen. Aus den resultierenden Bildern, deren Grauwerte die Skalierungsindizes repräsentieren, wird jeweils eine Zeile untersucht. Das Profil einer mit beiden Verfahren analysierten Zeile ist in Abbildung 4.13 dargestellt. Links sind die Skalierungsindizes einer Zeile bezüglich SIM und rechts bezüglich fSIM aufgetragen. Mit SIM lassen sich die ersten sechs Linien nicht unterscheiden; bei den

restlichen Linien zeigen sich Effekte am Linienrand, die Linienkerne allerdings haben denselben α -Wert wie die vorhergehenden sechs. Diese Effekte bei Pixeln an den Linienrändern lassen sich dadurch erklären, daß die durch r_1 definierte Umgebung den Linienabschnitt nicht vollständig erfaßt und daher relativ wenig Pixel enthält. In der durch r_2 bestimmten Umgebung dagegen ist der Linienabschnitt völlig enthalten. Aus dieser Diskrepanz (wenige Pixel in der r_1 -Umgebung, viele Pixel in der r_2 -Umgebung) resultiert der erhöhte Skalierungsindex am Linienrand.

Die unterschiedlich breiten Linien lassen sich mit fSIM dagegen differenzieren. Zwar treten hier früher Effekte am Linienrand auf, die Linien haben aber insgesamt (auch in den Linienkernen) unterschiedliche Skalierungsindizes.




Abbildung 4.13: Vergleich SIM und fSIM bei Binärbildern bzgl. Skalierungsindizes einer Zeile bei Analyse mit SIM. Rechts: Analyse mit fSIM.

4.4.3 Grauwertbilder: Zwei Beispiele

Die Detektionseigenschaften von SIM und fSIM werden in diesem Abschnitt an zwei künstlichen Beispielen verglichen. Im ersten Beispielsbild sind einfache geometrische Objekte zu detektieren, die eine relativ große Breite von fünf Pixeln haben. Das Bild wird künstlich verrauscht, wobei der Rauschanteil der Objektpixel konstant belassen wird, während er für die Hintergrundpixel variiert wird. Die Detektionsgüte von SIM und fSIM wird für verschieden stark verrauschte Bilder mittels eines Qualitätsmaßes beurteilt. Im zweiten Beispiel wird die Detektionsgüte von SIM und fSIM an einer ein Pixel breiten Spirale diskutiert.

Das Qualitätsmaß

Die zu untersuchenden Bilder werden mit SIM und fSIM analysiert. Die Trennung in Objekt- und Hintergrundpixel erfolgt durch Schwellwertbildung: diejenigen Pixel, deren Skalierungsindex kleiner als ein Schwellwert t ist, werden als Objektpixel klassifiziert. In den folgenden Zeilen wird beschrieben, wie die Detektionsgüte in den Beispielen gemessen wird. Dazu wird zunächst das Qualitätsmaß q_t für einen Schwellwert t definiert. Anschließend wird aus den schwellwertspezifischen und in diesem Sinne lokalen Werten ein globales Qualitätsmaß q bestimmt.

Durch Verwendung eines Schwellwerts t werden die Pixel als zum Objekt oder zum Hintergrund gehörig unterschieden. Die Anzahl der Pixel, die richtigerweise als dem Objekt (es bestehe aus N Pixeln) zugehörig erkannt wurden, wird mit RP (richtig positiv) bezeichnet. Die Anzahl der Pixel, die fälschlicherweise als Bestandteil der Objekte detektiert wurden, wird mit FP (falsch positiv) benannt. Um die Güte der Strukturerkennung bei Schwellwert t zu quantifizieren, wird folgendes Maß verwendet:

$$q_t = \frac{RP - FP}{N} \quad (4.21)$$

Mit diesem Maß wird die Genauigkeit der Objektdetektion gemessen, da die Anzahl der Fehlklassifikationen der Hintergrundpixel von der Anzahl richtig erkannter Objektpixel subtrahiert wird. Im Idealfall hat q_t den Wert 1: alle Objektpixel werden korrekt detektiert ($RP = N$), ohne daß ein Hintergrundpixel falsch klassifiziert wurde ($FP = 0$). Gilt $q_t > 0$, so werden mehr Objektpixel korrekt identifiziert als Hintergrundpixel falsch zugeordnet werden. In den hier untersuchten Bildern sind weit mehr Hintergrund- als Objektpixel vorhanden. Da diese Relation nicht in die Berechnung des Qualitätsmaßes eingeht, ist ein Wert $q_t > 0$ schwerer zu erreichen. Gleichzeitig bedeutet dies aber, daß dieses Qualitätsmaß nur angewendet werden kann, um die Detektionsgüte verschiedener Analysealgorithmen bei demselben Bild zu vergleichen.

Mit Hilfe des Häufigkeitsdiagramms der Skalierungsindizes werden systematisch für verschiedene Schwellwerte die dazugehörigen Maße q_t berechnet. Die Menge der Schwellwerte sei mit T bezeichnet. Um den Einfluß unterschiedlich dichter Belegungen im Häufigkeitsdiagramm der Skalierungsindizes auf das Qualitätsmaß zu verhindern, wird zuvor eine Äquivalenz [Abm94] der Häufigkeitsverteilung der Skalierungsindizes durchgeführt, so daß das kumulative Häufigkeitsdiagramm einen linearen Verlauf nimmt. Für diese so modifizierten α -Werte wird das normierte Häufigkeitshistogramm, das $P(\alpha)$ -Spektrum, berechnet, anhand dessen die Menge der zu untersuchenden Schwellwerte $t \in T$ bestimmt wird. Die Binsgröße des Histogramms beträgt $1/1000$ der Differenz zwischen maximalen und minimalen α -Wert. Die zu den einzelnen Bins gehörenden α -Werte werden als Schwellwerte t zur Berechnung des lokalen Qualitätsmaßes q_t nach Gleichung 4.21 verwendet. Als Maß für die Detektionsgüte q wird das maximale q_t angesehen:

$$q = \max(\{q_t | t \in T\}) \quad (4.22)$$

Wie bereits beschrieben beträgt der Maximalwert von $q = 1$. Nach unten wird q durch den Wert 0 beschränkt. Denn durch das systematische Testen der Schwellwerte wird der Schwellwert t auch mit dem Minimum der Skalierungsindizes belegt. In diesem Fall wird kein Pixel als dem Objekt zugehörig erkannt ($RP = 0$), aber auch kein Hintergrundpixel falsch klassifiziert ($FP = 0$). Damit gilt $q \in [0, 1]$.

Die Radienkombination, bei der sich in der Analyse eines Bildes der optimale Wert q findet, muß bei SIM und bei fSIM nicht identisch sein. Um eine Vergleichbarkeit der Ergebnisse zu erreichen, wird r_2 von 1 bis zu einem Maximalwert variiert und die Detektionsgüte q wird bei jedem zulässigen Radienpaar (r_1, r_2) gesondert gemessen. Die beiden Verfahren werden anhand des maximalen Wertes von q , der Robustheit von q gegenüber der Radienwahl sowie des Radienpaars, mit dem der Maximalwert von q erreicht wird, verglichen.

Zur Vermeidung von Falschklassifikationen in Folge von Randeffekten (vgl. Abschnitt 4.2.1, Seite 24) werden die Bildbereiche, die näher als r_2 Pixel am Bildrand liegen, bei der Berechnung von q nicht berücksichtigt.




Abbildung 4.14: Testbild mit zwei Linien unterschiedlicher Ausrichtung und einer kreisförmigen Struktur (Größe: 280×280 Pixel, Breite der Strukturen: 5 Pixel).

Beispiel 1

Die im ersten Bild vorhandenen Objekte sind in Abbildung 4.14 dargestellt. Das Bild ist 280×280 Pixel groß und die Strukturen haben eine Breite von 5 Pixeln. Insgesamt sind 2552 Objektpixel und 75848 Hintergrundpixel vorhanden, das Verhältnis entspricht also etwa $1 : 30$. Die Grauwerte der Objektpixel werden mit normalverteiltem Rauschen versehen, wobei der Mittelwert 100 und die Standardabweichung $\sigma_{obj} = 1$ beträgt. Auch die Grauwerte des Hintergrunds werden verrauscht und haben ebenfalls einen Mittelwert von 100, für die Standardabweichung σ_b gilt allerdings $\sigma_b > \sigma_{obj}$. Damit unterscheiden sich die Grauwerte von Objekt und Hintergrund nur durch die Standardabweichung. Während σ_{obj} konstant bleibt, wird σ_b variiert und das Qualitätsmaß q wird in Abhängigkeit von σ_b gemessen. Mit steigendem σ_b wird es zunehmend leichter, die Pixel korrekt zu klassifizieren.

Für $r_2 = 1, \dots, 31$ und die dazugehörigen Radienkombinationen r_1 und r_2 wurde das Qualitätsmaß q für das Bild mit Hintergrundrauschen $\sigma_b = 2$ bestimmt. In linken Teil von Abbildung 4.15 ist das Qualitätsmaß für SIM in Abhängigkeit von r_1 und r_2 aufgetragen. Rechts daneben ist die entsprechende Graphik für fSIM dargestellt. Bei Betrachtung der beiden Abbildungen sind zwei Umstände auffällig. Das Qualitätsmaß ist für fSIM deutlich höher, das Maximum beträgt $q = 0.45$, während es bei SIM einen Wert von $q = 0.23$ hat. Vergleicht man in beiden Abbildungen die Bereiche, in denen das Qualitätsmaß von 0 verschieden ist, so ist festzustellen, daß dieser bei fSIM ungleich höher ist als bei SIM. Dies deutet darauf hin, daß die Detektionsfähigkeit von fSIM nicht so stark von der Radienwahl abhängig ist wie SIM. Diese Annahme vorausgesetzt, würde dies bedeuten, daß bei fSIM eine genauere Kenntnis der Größe der im Bild vorhandenen Strukturen weniger wichtig ist. Diese Robustheit der Detektierfähigkeit gegenüber der Radienwahl wird im folgenden durch die Summe

der q -Werte über alle Radienpaare quantifiziert und mit $area(q)$ symbolisiert. Sie beträgt bei fSIM 112.0 und bei SIM 8.4.




Abbildung 4.15: Beurteilung der Detektionsgüte zu dem Bild aus Abbildung 4.14 bei $\sigma_b = 2$: Das Qualitätsmaß q in Abhängigkeit der Radien r_1 und r_2 für SIM ist links und für fSIM rechts dargestellt.

In gleicher Weise wurde nun das Maximum von q für die Bilder mit $\sigma_b \in \{1.25, 1.5, 2, 3, 4, \dots, 10\}$ bestimmt. Das Verhältnis des Rauschanteils der Objektpixel zum Rauschanteil der Hintergrundpixel soll *Signal- zu Hintergrundrauschverhältnis* (SR-HR) genannt werden. In den Beispielen dieser Arbeit ist das Hintergrundrauschen höher als das Rauschen der Grauwerte der Objektpixel. Daher wird SR-HR hier nach oben durch den Wert 1 beschränkt. Mit steigendem SR-HR nähern sich die Rauschanteile von Objekt und Hintergrund an und es wird zunehmend schwieriger, die Pixel korrekt zuzuordnen. In Abbildung 4.16 sind die Werte für q gegen SR-HR für SIM als gestrichelte Linie und für fSIM als durchgezogene Linie aufgetragen. Rechts daneben ist die Differenz der beiden Reihen dargestellt. Bei der Analyse dieser Ergebnisse kann man feststellen, daß das Qualitätsmaß q mit steigendem SR-HR bei SIM dem Wert 0 schneller zustrebt als bei fSIM. fSIM konnte also in den Beispielen die vorhandenen Strukturen auch bei relativ geringen Unterschieden in den Rauschanteilen von Objekt und Hintergrund besser detektieren als SIM. Sogar bei dem Bild mit dem größten SR-HR ist das Qualitätsmaß bei fSIM im Unterschied zu SIM größer als 0. In den Bereichen niedriger Werte von SR-HR, also relativ einfacher Detektierbarkeit der Objekte, ist das Qualitätsmaß annähernd gleich, für SIM sogar etwas besser. Der Vergleich der Summen der q -Werte $area(q)$ über die Radienkombinationen als Maß für die Robustheit der Detektion gegenüber der Radienwahl ist im linken Teil von Abbildung 4.17 dargestellt. Der deutlich höhere Wert von fSIM ist klar ersichtlich. Diese Beobachtung unterstützt die These, daß die genaue Kenntnis der Objektgröße bei fSIM weniger wichtig ist.

Interessant ist auch der Vergleich, bei welchen Radienkombinationen unter Variierung von σ_b der maximale Wert von q auftritt. Da die Größe der Objekte in x - und y -Richtung konstant bleibt, sollten sich die Radienkombination möglichst wenig unterscheiden. Die absolute Häufigkeitsverteilung der Radienkombinationen ist im rechten Teil der Abbildung 4.17 dargestellt. Die Häufigkeitsverteilung für SIM wird mit hellen Säulen und die für fSIM mit dunklen




Abbildung 4.16: *Detektionseigenschaften von SIM und fSIM in Abhängigkeit des Signal- zu Hintergrundrauschverhältnis SR-HR zu dem Bild aus Abbildung 4.14.* Links: Das Qualitätsmaß q für SIM (gestrichelte Linie) und für fSIM (durchgezogene Linie). Rechts: Differenz der Detektionsmaße für SIM und fSIM.

Säulen markiert. Es wird deutlich, daß die Radienkombination für fSIM weniger variiert als für SIM. Da bei Anwendung von SIM auf das Bild mit $\sigma_b = 1.25$ der maximale q -Wert 0 beträgt, ist dieser Wert in der Abbildung symbolisch bei $r_1 = 0$ und $r_2 = 0$ eingetragen.




Abbildung 4.17: *Vergleich von SIM und fSIM, angewandt auf das Bild aus Abbildung 4.14.* Links: Als Maß für die Robustheit der Detektion gegenüber der Radienwahl ist die Summe $area(q)$ der q -Werte über alle Radienkombinationen für SIM als gestrichelte Linie und für fSIM als durchgezogene Linie dargestellt. Rechts: Die absolute Häufigkeitsverteilung der Radienkombination bei maximalen q zeigt bei fSIM (dunkle Säulen) eine geringere Varianz als bei SIM (helle Säulen).

Beispiel 2

Im ersten Beispiel sind die Strukturen mit einer Breite von fünf Pixeln relativ groß. In dem hier zu behandelnden Beispiel besteht das zu detektierende Objekt aus einer ein Pixel breiten Linie, die spiralförmig gewunden ist. Auch hier sind sowohl die Objektpixel als auch die Hintergrundpixel mit normalverteiltem Rauschen versehen ($\sigma_{obj} = 1$, $\sigma_b = 15$), wobei alle Pixel denselben Grauwertmittelwert von 100 haben. Wiederum unterscheiden sich Objekt und




Abbildung 4.18: *Testbild*: links: zugrundeliegendes binäres Muster, rechts: Testbild mit normalverteiltem Rauschen. Die Grauwerte der Struktur und des Hintergrunds haben den selben Mittelwert.

Hintergrund nur durch die Standardabweichung. Die Spirale ist als Binärojekt im linken Teil von Abbildung 4.18 dargestellt, im rechten Teil ist das verrauschte zu analysierende Bild zu sehen. Das Bild ist 256×256 Pixel groß, wobei das Spiralobjekt aus 735 Pixeln besteht. Das Verhältnis zwischen Objekt- und Hintergrundpixel beträgt also etwa 1 : 90.

Für die zulässigen Radienkombinationen bis $r_2 = 25$ wurde wie im obigen Beispiel das Qualitätsmaß gemessen und das Ergebnis ist in Abbildung 4.19 dargestellt. Die Verbesserung der Detektionsfähigkeit durch fSIM gegenüber SIM bei verrauschten Strukturen ist dabei deutlich. Das Qualitätsmaß hat bei fSIM den maximalen Wert von $q = 0.1$, während es bei SIM nur $q = 0.001$ beträgt. Auch bei der Beurteilung der Robustheit der Detektion gegenüber der Radienwahl hat fSIM mit $area(q) = 7.5$ einen deutlich besseren Wert als SIM mit $area(q) = 0.01$.

Die Ergebnisse der Spiraldetektion sind exemplarisch in Abbildung 4.20 dargestellt. Als Ergänzung ist in der oberen Reihe das Resultat abgebildet, wenn die Detektion der Spiralexel anhand eines bestimmten Grauwertintervalls vorgenommen wird. In der linken Spalte ist die relative Häufigkeitsverteilung der Grauwerte zu sehen. Die Pixel, deren Grauwerte in das schwarz markierte Intervall des Histogramms fallen, sind im rechten Teil der Abbildung dargestellt. Mit diesem Vorgehen kann zwar die Spirale gut detektiert werden, aber gleichzeitig werden zahlreiche Hintergrundpixel mit ausgewählt. Von Struktureerkennung kann dabei nicht gesprochen werden. Mit SIM ($r_1 = 3$, $r_2 = 8$) werden zwar weniger Hintergrundpixel als zur Spirale zugehörig erkannt, gleichzeitig werden relativ wenig Spiralexel entdeckt (mittlere Reihe). In der unteren Reihe ist das Ergebnis mit fSIM ($r_1 = 3$, $r_2 = 8$) zu sehen. Deutlich ist zu erkennen, daß viele Spiralexel bei wenig falsch zugeordneten Hintergrundpixel detektiert werden. Weiterhin liegen viele der falsch detektierten Hintergrundpixel in unmittelbarer Nähe zu Spiralexeln. Ein Vergleich der mit gestrichelter Linie eingezeichneten relativen Häufigkeitsverteilungen der Skalierungsindizes der Spiralexel bei SIM und fSIM erklärt das bessere Detektionsergebnis: die beiden Verteilungen sind bei fSIM besser voneinander getrennt.




Abbildung 4.19: *Beurteilung der Detektionsgüte zu dem Bild aus Abbildung 4.18:* Das Qualitätsmaß q in Abhängigkeit der Radien r_1 und r_2 für SIM ist links und für fSIM rechts dargestellt.

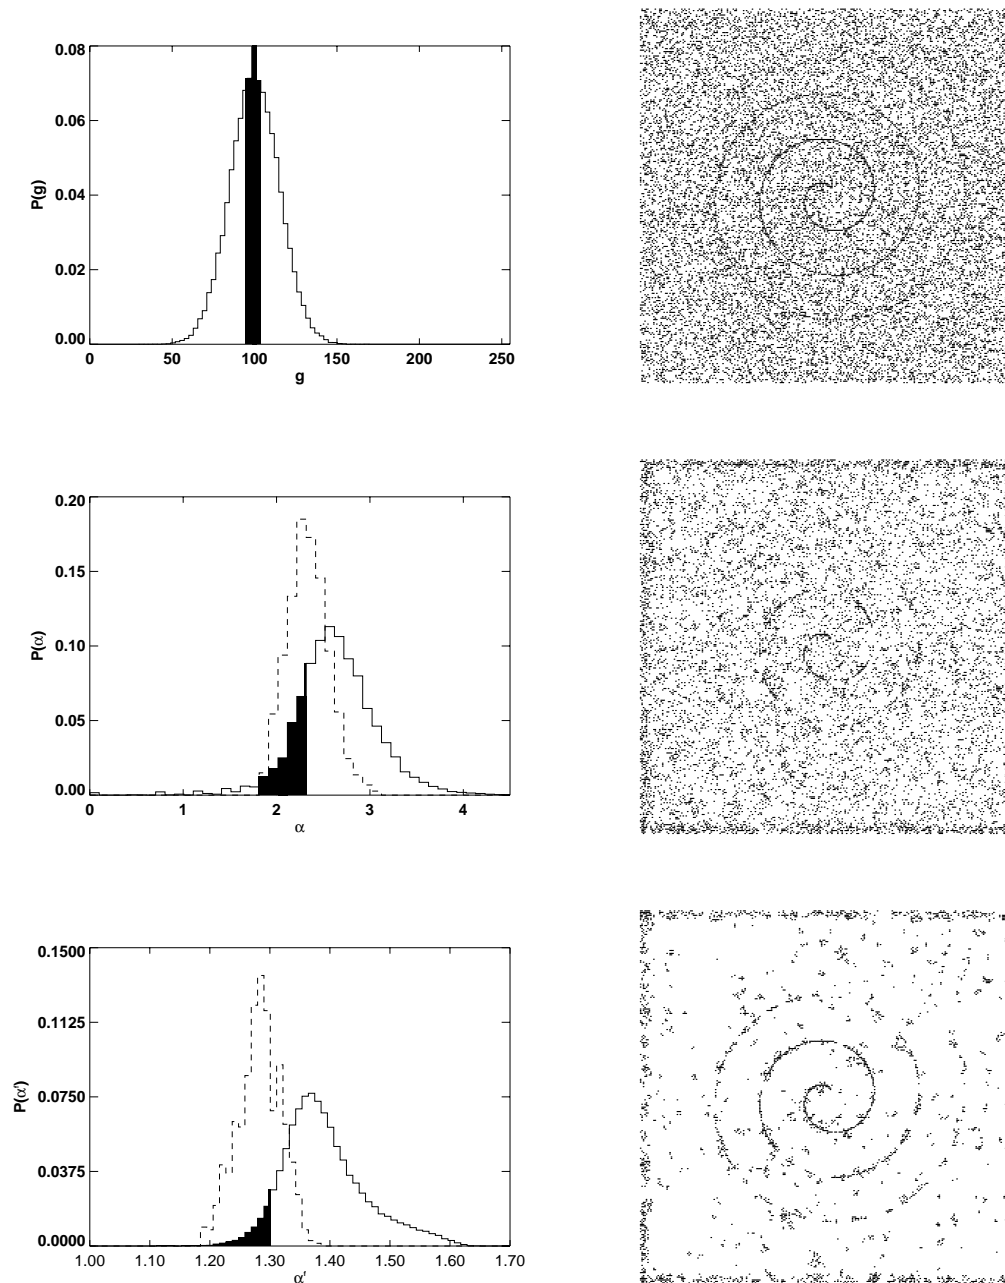


Abbildung 4.20: Beispiel zur Spiraldetektion. *Obere Reihe:* Ergebnis bei Extraktion eines Grauwertintervalls. Links ist die relative Häufigkeitsverteilung der Grauwerte dargestellt. Der dunkle Bereich markiert die extrahierten Pixel. *Mittlere Reihe:* Ergebnis mit SIM ($r_1 = 3$, $r_2 = 8$). Links ist das $P(\alpha)$ -Spektrum dargestellt. Mit gestrichelter Linie ist die relative Häufigkeitsverteilung der Skalierungsindizes der Spirale eingezeichnet. Rechts sind die Pixel mit Skalierungsindizes aus dem hervorgehobenen Bereich des $P(\alpha)$ -Spektrums abgebildet. *Untere Reihe:* Ergebnis mit fSIM ($r_1 = 3$, $r_2 = 8$).

4.4.4 Verbesserung des Laufzeitverhaltens

Die Verbesserung der Detektionsrate, die in den obigen Beispielen erreicht wurde, geht überproportional zu Lasten der Rechenzeit. Zu einem großen Teil ist dieser Effekt auf die rechenintensive Auswertung der Zugehörigkeitsfunktion zurückzuführen. Mit Hilfe einer *look-up*-Tabelle (LUT), in der die Funktionswerte der Zugehörigkeitsfunktion abgelegt sind, kann die Rechenzeit deutlich reduziert werden. Die Granularität der LUT soll eine ausreichende Genauigkeit der Ergebnisse gewährleisten.

Zur Untersuchung der notwendigen Granularität der LUT wurde ein 512×512 Pixel großes Bild mit fSIM ($r_1 = 5$, $r_2 = 15$) unter Verwendung verschieden großer LUT's analysiert und die jeweils erreichte Genauigkeit gemessen. Genauigkeit ist hier als gemittelter quadratischer Abstand (*mean squared error*, MSE) vom korrekten Skalierungsindex aller Bildpixel definiert. Folgende Tabelle stellt die Größe der LUT der Genauigkeit des Algorithmus gegenüber:

Größe LUT	10^1	10^2	10^3	10^4	10^5	10^6
MSE	2.03690	1.21586	0.00254848	2.25159e-06	2.13253e-08	2.17063e-10

Die Ergebnisse zeigen, daß schon bei einer LUT-Größe von 10^4 ein *mean squared error* von weniger als $2.3e-06$ erreicht wird. Das heißt, daß schon bei einer moderaten Granularität der Fehler gering ist und gute Ergebnisse erreicht werden können.

Anhand verschieden großer Radien kann nun untersucht werden, wie hoch die Beschleunigungsraten bei Verwendung von LUT's sind. Die Zahlen wurden an einer Hewlett Packard Workstation J210/9000 ermittelt und die LUT hat eine Größe von 10^4 Zellen. Tabelle 4.1

r_1	r_2	fSIM	fSIM _{LUT}	SIM	SU ₁	SU ₂
8	15	478	75	31	6.34	2.42
7	14	418	65	27	6.43	2.41
7	13	365	58	24	6.29	2.42
6	12	313	50	19	6.26	2.63
6	11	264	40	16	6.60	2.50
5	10	221	33	13	6.70	2.54
5	9	181	27	11	6.70	2.45
4	8	144	22	9	6.55	2.44
4	7	113	18	7	6.28	2.57
3	6	84	15	6	6.60	2.50
3	5	61	10	5	6.10	2.00
2	4	41	7	4	5.86	1.75

Tabelle 4.1: *Rechendauer von fSIM, fSIM mit LUT und SIM bei verschiedenen Radien r_1 und r_2 in Sekunden: SU₁ ist der erreichte speed-up von fSIM_{LUT} gegenüber fSIM. Der Beschleunigungsfaktor von SIM vs. fSIM_{LUT} ist in der Spalte SU₂ angezeigt.*

zeigt die gemessene Rechenzeiten in Sekunden. Der Beschleunigungsfaktor von fSIM mit LUT gegenüber fSIM hat, gemessen über alle Radienpaare, einen Mittelwert von 6.3 ($\sigma = 0.3$), ist

also sehr hoch. Die binäre SIM ist gegenüber fSIM mit LUT immer noch mehr als doppelt so schnell ($\mu = 2.4, \sigma = 0.3$). Der absolute Rechenzeitunterschied bei mittleren Radien ist jedoch nicht mehr so gravierend.

Die Kodierung von fSIM mit *look-up*-Tabelle zeigt also einerseits geringe Fehlerraten und andererseits eine deutliche Rechenzeitreduzierung gegenüber fSIM ohne LUT. Der Unterschied in den Ausführungszeiten gegenüber binärer SIM wird mit schnelleren Maschinen und vor allem durch die Parallelisierbarkeit des Algorithmus bei Multi-Prozessor-Systemen noch weniger ins Gewicht fallen.

4.4.5 Neuronales Analogon von fSIM

Neuronale Netze sind für Forschung und Entwicklung interessant, weil sie einen alternativen Zugang zur Berechnung von Funktionen (Funktionsapproximation, Clustering, Klassifikation) darstellen und ihre Motivation in der biologischen Signalverarbeitung haben. Die intensive Forschung auf diesem Gebiet hat in den letzten Jahren eine Vielzahl von Netzwerktypen entstehen lassen [Roj93] [Bra97].

Neuronale Netze passen sich in einer selbstorganisierenden Weise an ein zu lösendes Problem an. Es wird nicht die exakte Rechenvorschrift für das konkrete Problem formuliert, sondern mit einem Lernalgorithmus ein allgemeines Lösungsverfahren vorgegeben. Gerade wegen dieser Eigenschaft werden neuronale Netze in vielen Bereichen eingesetzt. Zu fSIM gibt es auch eine analoge neuronale Formulierung, die auf Netze mit radialen Basisfunktionen [MD88] [MD89] zurückgreift. Nach einem kurzen Überblick über neuronale Netze werden im Folgenden Radiale Basis Netzwerke vorgestellt und darauf abgestützt die neuronale Architektur von fSIM beschrieben. Zu diesem neuen Netzwerk-Typ wird ein Lernalgorithmus vorgestellt, der auf der Methode der Minimierung einer Fehlerfunktion mittels Gradientenabstieg beruht. Dieser Abschnitt wird mit einer Diskussion der Probleme und Möglichkeiten der neuronalen Formulierung abgeschlossen.

Neuronale Netze

Ein Netzwerk besteht aus einer Menge von Knoten (Neuronen) und gerichteten Kanten (Synapsen), die die Knoten verbinden [Roj93]. Die Art der Verbindung bestimmt die Topologie des künstlichen neuronalen Netzwerks. In dieser Arbeit ist insbesondere das vollständig verbundene geschichtete *feed-forward*-Netzwerk von Interesse. In dieser Architektur sind die Neuronen in Schichten angeordnet, wobei jedes Neuron einer Schicht mit jedem Neuron der nächsthöheren Schicht verbunden ist. Jeder Kante ist ein Gewicht zugeordnet, mit dem das entsprechende Signal skaliert wird.

Ein Neuron ist die elementare Verarbeitungseinheit in einem neuronalen Netz. Es kann aus beliebig vielen Eingangsleitungen Signale empfangen, die zu einem Ausgangssignal (der Aktivierung) verarbeitet werden. Die Berechnung der Aktivierung eines Neurons erfolgt in zwei Schritten. Zunächst werden die Eingangssignale mittels einer Integrationsfunktion zu einem Argument zusammengefaßt. Der Wert dieser Funktion wird auch als die Erregung *err* des Neurons bezeichnet. Sie dient im zweiten Schritt als Parameter für die sogenannte Aktivierungsfunktion; ihr Ergebnis wird als Aktivierung bezeichnet und durch *act* symbolisiert. Die Aktivierung dient den Neuronen der nächsthöheren Schicht als Eingangssignal. Ein

Eingabevektor wird auf diese Weise über die gewichteten Kanten über die Neuronen von der Eingabeschicht durch das Netz zur Ausgabeschicht propagiert. Positive Gewichte modellieren exzitatorische (erregende), negative Gewichte inhibitorische (hemmende) Effekte.

RBF-Netze

Eine spezielle Klasse der *feed-forward*-Netzwerke sind Netze mit radialen Basisfunktionen (*radial basis function nets*, RBF-Netze) [MD88] [MD89]. RBF-Netze sind aus drei Schichten aufgebaut: der Eingabeschicht, der versteckten Schicht mit den radialen Basisfunktionen und der Ausgabeschicht. In der Eingabeschicht werden die Daten zur versteckten Schicht weitergeleitet. Dort werden die Aktivierungen der radialen Basisfunktionen berechnet. Eine radiale Basisfunktion ist dadurch charakterisiert, daß ihre Aktivierung mit wachsendem Abstand zu einem der Funktion zugeordneten Zentralpunkt monoton fällt (z.B. Gauß-Funktion). Dadurch wird ein lokalisiertes Ansprechverhalten dieser Neuronen gewährleistet. Neuronen der Ausgabeschicht fassen die Aktivierungen der radialen Basisfunktionen in einer Linearkombination zusammen. Das RBF-Modell umfaßt also zwei verschiedene Neuronentypen, die sich formell wie folgt darstellen:

Die k Neuronen der versteckten Schicht werden charakterisiert durch:

- Die Erregung des Neurons i wird durch eine Gauß-Funktion modelliert (der Index h kennzeichnet den Wert als einem Neuron der versteckten Schicht zugehörig):

$$err_i^h(\vec{x}) = \exp(-(\|\vec{x} - \vec{\mu}_i\|^2)/\sigma_i^2) \quad (4.23)$$

$\vec{\mu}_i$ symbolisiert den Ort der i -ten radialen Basisfunktion, σ_i seine Streuung.

- Die Aktivierung der radialen Basisfunktionen ist die Identität:

$$act_i^h(x) = x \quad (4.24)$$

Die Neuronen der Ausgabeschicht werden charakterisiert durch:

- k Gewichte, die den Kanten von den Neuronen der versteckten Schicht zu einem Ausgabeneuron zugeordnet sind. k ist die Anzahl der Neuronen der vorhergehenden Schicht, entspricht also der Anzahl der radialen Basisfunktionen. Die Gewichte werden durch w_{ij} symbolisiert, wobei i das Ausgabeneuron und j das Neuron der versteckten Schicht identifiziert.
- Die Erregung des Ausgabeneurons i ist eine gewichtete Linearkombination (Index o symbolisiert die Zugehörigkeit zu einem Ausgabeneuron), normalisiert durch die Summe der Aktivationen der radialen Basisfunktionen:

$$err_i^o = \frac{\sum_j w_{ij} \cdot act_j^h(\vec{x})}{\sum_j act_j^h(\vec{x})} \quad (4.25)$$

- Die Aktivierung des Ausgabeneurons ist die Identität:

$$act_i^o(x) = x \quad (4.26)$$

Das Einbringen von Information in das RBF-Netzwerk, also der Lernvorgang, erfolgt in einem zweistufigen hybriden Prozeß [MD88]. In der ersten Phase werden die Orte und Breiten der radialen Basisfunktionen festgelegt. Die Autoren empfehlen, zuerst die Orte der rezeptiven Felder durch *k-means-Clustering* zu bestimmen. Als Alternative werden in der Literatur zum Beispiel selbstorganisierende Karten [Roj93] vorgeschlagen. Daran schließt sich die Bestimmung der Breiten (im Falle von Gaußfunktionen die Streuungen) der Funktionen an. In der zweiten Phase werden die Gewichte durch Minimierung einer Fehlerfunktion adaptiert.

fSIM: Neuronale Architektur

Bei fSIM ist die Berechnung der lokalen Masse N^f (Gleichung 4.16, Seite 35) zu einem Punkt \vec{x}_i mit fuzzifizierter Zugehörigkeitsfunktion bei Radius r definiert durch:

$$N^f(\vec{x}_i, r) = \sum_{j=1}^k m(dist_p^w(\vec{x}_i, \vec{x}_j), r)$$

Da auch die Zugehörigkeitsfunktion $m(x, r)$ ihr Maximum bei $x = 0$ annimmt und mit zunehmenden Abstand monoton fällt, läßt sie sich als radiale Basisfunktion auffassen. N^f ist dann die kumulative Aktivierung einer radialen Basisfunktion: Die Aktivierungen durch die Vektoren \vec{x}_j in der lokalen Umgebung zu \vec{x}_i werden in der Variablen N^f aufaddiert. Darauf aufbauend wird die neuronale Architektur von fSIM als Differenzenquotient der kumulativen Aktivierungen zweier RBF-Einheiten modelliert. Der im folgenden dargestellte Aufbau eines solchen neuronalen Netzes ist in Abbildung 4.21 (Seite 52) symbolisch dargestellt. Das neuronale fSIM-Modell besteht demnach aus vier Schichten: der Eingabeschicht, der Kodierungsschicht zur Berechnung der Abstände $dist_p^w(\vec{x}_i, \vec{x}_j)$, der Schicht mit den radialen Basisfunktionen $m(x, r)$ und der Ausgabeschicht.

Zur besseren Verständlichkeit wird der Punkt, zu dem der Skalierungsindex α berechnet werden soll, in diesem Abschnitt mit $\vec{\mu}$ bezeichnet.

Erste Schicht:

Zur Berechnung von N^f müssen vorbereitend die Abstände $dist_p^w(\vec{\mu}, \vec{x}_j)$ der Punkte \vec{x}_j zu $\vec{\mu}$ berechnet werden. Daher wird das RBF-Modell um eine Neuronenart erweitert, die diese Operationen vornimmt. Da in diesen Neuronen die Abstände der Umgebungspunkte zu $\vec{\mu}$ kodiert werden, sollen sie Kodierungsneurone und diese Schicht Kodierungsschicht genannt werden. Die Anzahl der Kodierungsneurone entspricht der Anzahl der Umgebungspixel, die zur lokalen Umgebung von $\vec{\mu}$ gehören. Ein Kodierungsneuron läßt sich wie folgt beschreiben:

- Jedem Neuron i sind d Gewichte w_{il}^1 ($l = 1, \dots, d$) zugeordnet (d ist die Dimension der Eingabevektoren). w_{il}^1 ist dem Neuron i der Schicht 1 zugeordnet und gewichtet die l te Komponente des Eingabevektors. Da die Gewichte die Bedeutung der einzelnen Koordinaten signalisieren sollen, wird der Wertebereich der Gewichte auf \mathbb{R}_0^+ beschränkt.

- Das gewichtete Abstandsmaß zwischen einem Eingabepunkt \vec{x} und dem Zentrum der radialen Basisfunktion $\vec{\mu}$ stellt die Erregung des Kodierungsneurons dar:

$$err_i^1 = \sum_{j=1}^d w_{ij}^1 |\mu_j - x_j|^p \quad (4.27)$$

Das Zentrum des Aktivationszentrums $\vec{\mu}$ ist der Punkt, zu dem der Skalierungsindex berechnet werden soll.

- Mit der Aktivierung wird die Berechnung der verwendeten Abstandsnorm abgeschlossen:

$$act_i^1 = err_i^1{}^{\frac{1}{p}} \quad (4.28)$$

Zweite Schicht:

Die Neuronen der nächsten Schicht entsprechen jenen der versteckten Schicht im RBF-Modell. Hier werden die kumulativen Aktivationen der radialen Basisfunktionen (in fSIM: Summation der Werte der Zugehörigkeitsfunktion zu N^f) bei zwei verschiedenen Radien berechnet. Daher sind exakt zwei dieser Neuronen in einem fSIM-Netz vorhanden. In der Definition von N^f (Gleichung 4.16, Seite 35) werden aus Gründen der Übersichtlichkeit die Funktionswerte der Zugehörigkeitsfunktion $m(x, r)$ nicht gewichtet. In der neuronalen Formulierung lassen sich Gewichte an dieser Stelle bequem einfügen, um die Information über den Ort des Signals bezüglich des Zentrums der Aktivierungsfunktion $\vec{\mu}$ einzeln zu gewichten. Das Gewicht zur Kante von Neuron j der vorhergehenden Schicht zu Neuron i dieser Schicht wird mit w_{ij}^2 bezeichnet.

Die Radien r_k ($k = 1, 2$) finden in zwei verschiedenen Schichten Verwendung: in dieser und in der übergeordneten Schicht. Sie werden daher in verschiedene Parameter zerlegt: r_k^2 für die Neuronen dieser Schicht und r_k^3 für das Ausgabeneuron (eine als *weight sharing* bekannte Alternative dazu ist in Abschnitt 4.4.6 beschrieben).

Somit läßt sich ein Neuron dieser Schicht charakterisieren durch:

- Jedem Neuron i dieser Schicht sind l Gewichte zugeordnet (l ist die Anzahl der Neuronen der vorhergehenden Schicht und entspricht der Anzahl der Umgebungspunkte zu $\vec{\mu}$). Das Gewicht w_{ij}^2 ist der Kante von Neuron j der vorhergehenden Schicht zu Neuron i der zweiten Schicht zugeordnet.
- Die Erregung dieses Neurons wird aus der gewichteten Summe der Aktivationen der radialen Basisfunktion (in fSIM: Zugehörigkeitsfunktion) gebildet:

$$err_i^2 = \sum_j w_{ij}^2 m(act_j^1, r_i^2) \quad (4.29)$$

- Die Aktivation des Neurons i dieser Schicht ist die Identität:

$$act_i^2 = err_i^2 \quad (4.30)$$

Dritte Schicht:

Die kumulativen Aktivationen $act_i^2 = N^f(\vec{\mu}, r_i^2)$ ($i = 1, 2$) der beiden RBF-Neuronen wird im dritten Neuronentypus durch Bildung des Differenzenquotienten zum Skalierungsindex α zusammengefaßt. Die Schicht besteht daher aus nur einem Neuron, dessen Aufgabe sich wie folgt darstellt:

$$\alpha = \frac{\log(N^f(\vec{\mu}, r_2^3)) - \log(N^f(\vec{\mu}, r_1^3))}{\log(r_2^3) - \log(r_1^3)}$$

Damit läßt sich diese Neuronenart wie folgt beschreiben:

- Dem Neuron sind zwei Gewichte w_i^3 zugeordnet. Zur Bildung der kumulativen Aktivationsdifferenz (Zähler des Differenzenquotienten) wird das Gewicht für die Aktivierung des r_1^2 enthaltenden Neurons mit $w_1^3 = -1$ und das des r_2^2 enthaltenden Neurons mit $w_2^3 = +1$ initialisiert.
- Die Erregung des Neurons ist die gewichtete Summe der logarithmierten Aktivationen der Neuronen der tieferliegenden Schicht:

$$err_1^3 = \sum_i w_i^3 \log(act_i^2) \quad (4.31)$$

- Die Aktivationsfunktion führt die Normierung der Erregung anhand der Parameter r_1^3 und r_2^3 durch:

$$act_1^3 = \frac{err_1^3}{\log(r_2^3) - \log(r_1^3)} \quad (4.32)$$

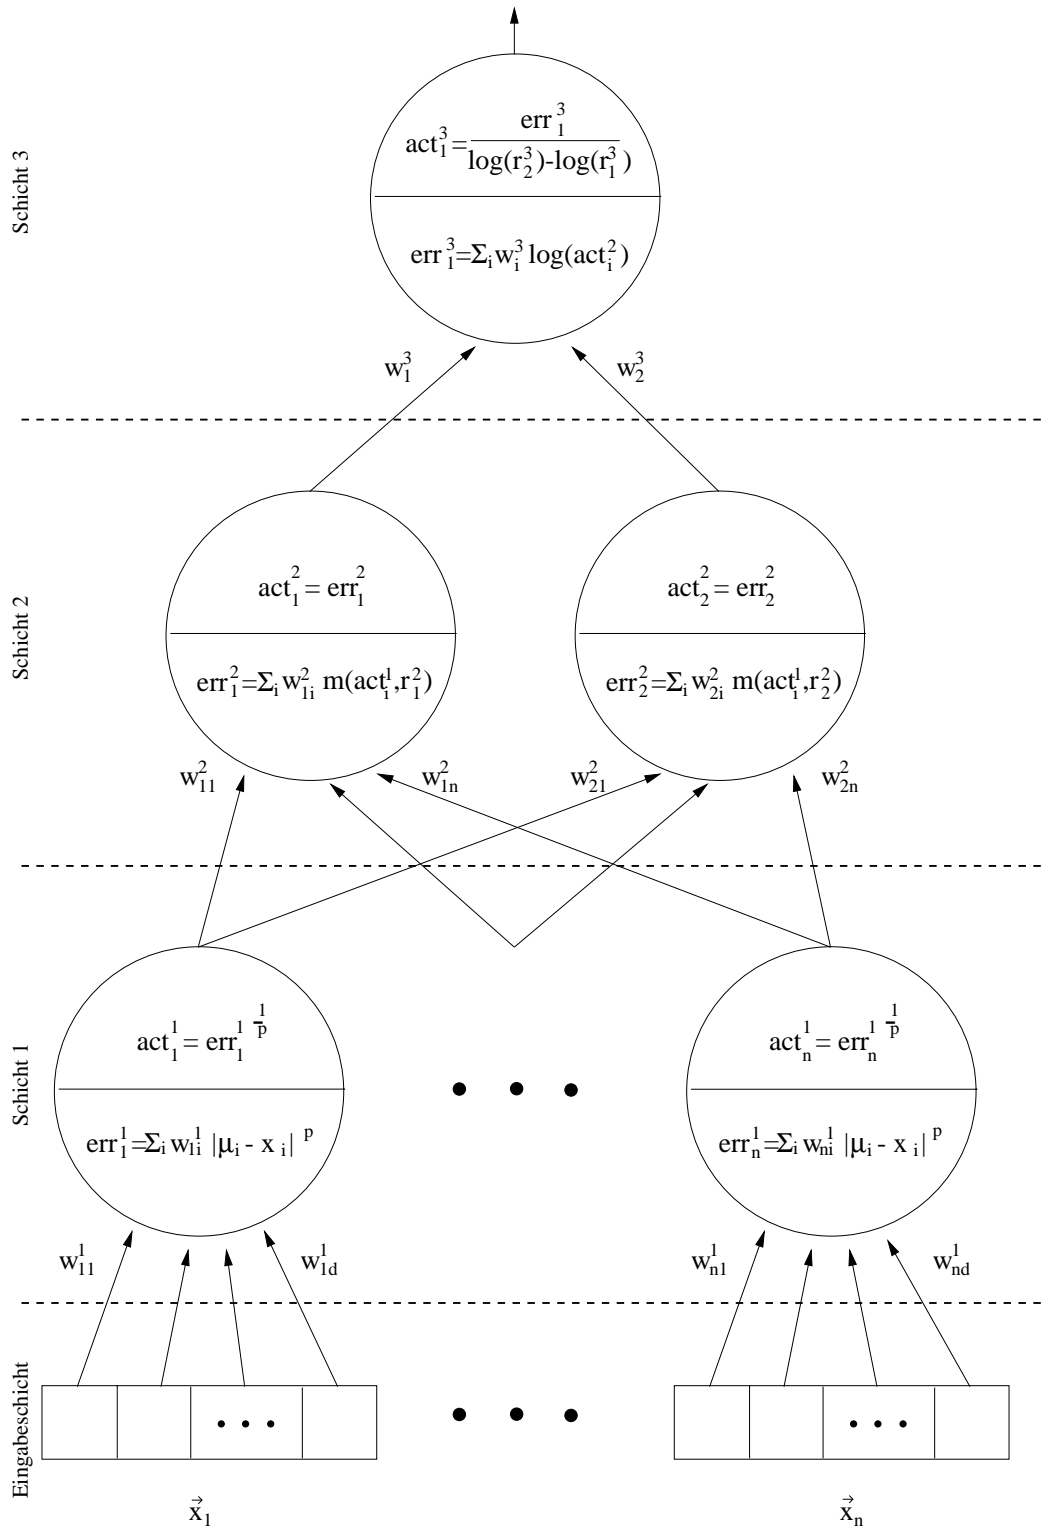


Abbildung 4.21: *Symbolischer Aufbau der neuronalen Architektur von fsIM*: Der Eingabevektor wird zunächst in einer Kodierungsschicht verarbeitet und schrittweise durch das Netz nach oben propagiert.

Lernverfahren für neuronales fSIM

Wesentliches Element von neuronalen Netzen ist ihre Plastizität, d.h. es kann adaptiv in einer selbstorganisierenden Weise Wissen in das Netz eingebracht werden. Für das vorgestellte neuronale fSIM-Modell soll ein überwachtes Lernverfahren entwickelt werden. Überwacht bedeutet in diesem Zusammenhang, daß eine Trainingsmenge verfügbar ist, die dadurch charakterisiert ist, daß zu jedem Muster \vec{x}_i (Eingabevektor) aus der Trainingsmenge die Klasseninformation t_i bekannt ist. In einer Trainingsphase werden die freien Parameter des Netzes anhand eines Datensatzes so angepaßt, daß die Funktion $f(\vec{x}_i) = t_i$ möglichst gut approximiert wird. Dadurch soll das Netz in die Lage versetzt werden, unbekannte Muster korrekt zu klassifizieren.

Von Rumelhart [RM86] wurde das Backpropagation-Verfahren vorgestellt, das zu dem am meisten verbreiteten Lernmodell geworden ist und auch in diesem Fall Anwendung finden soll. Es basiert auf der Minimierung einer Fehlerfunktion durch Gradientenabstieg. Diese Funktion wird als Summe der quadratischen Fehler zwischen dem Ausgabewert des Netzes und dem Zielwert definiert:

$$E = \frac{1}{2} \sum_i (act_1^3(\vec{x}_i) - t_i)^2 \quad (4.33)$$

Anhand der partiellen Ableitungen der freien Parameter des Netzes wird E durch Gradientenabstieg minimiert. Der Term $\frac{1}{2}$ in Gleichung 4.33 vereinfacht die Bildung der partiellen Ableitungen. Die freien Parameter eines fSIM-Netzes sind nun die Gewichte der einzelnen Schichten w_{kl}^1 , w_{kl}^2 und w_k^3 , sowie die Parameter r_k^i , die das Aktivierungsverhalten der Zugehörigkeitsfunktionen beeinflussen. Während bei der Berechnung von $\alpha^f = act_1^3$ der Eingabevektor von unten nach oben durch das Netz propagiert wird, so finden beim Lernprozeß ein Zurückpropagieren des Fehlers von oben nach unten statt. Ähnlich wie bei Moody und Darken [MD88] wird ein zweistufiges Trainingsmodell vorgeschlagen. In der ersten Phase werden die r_k^i trainiert. Im zweiten Schritt werden die Gewichte adaptiert, während die r_k^i nicht mehr verändert werden. Die nachfolgend beschriebenen Gleichungen wurden bei Verwendung der ln-Funktion (Logarithmierung der N^f und r_i^3 zur Bildung des Skalierungsindex) und der Gaußschen Glockenkurve als Zugehörigkeitsfunktion entwickelt. Werden andere Funktionen verwendet, so sind Gleichungen 4.34 bis 4.38 entsprechend anzugleichen.

Die partiellen Ableitungen für die Gewichte der einzelnen Schichten lauten nun:

$$\frac{\partial E}{\partial w_k^3} = \frac{1}{\ln(r_2^3) - \ln(r_1^3)} \cdot \sum_i (act_1^3 - t_i) \cdot \ln(act_k^2) \quad (4.34)$$

$$\frac{\partial E}{\partial w_{kl}^2} = \frac{1}{\ln(r_2^3) - \ln(r_1^3)} \cdot \sum_i (act_1^3 - t_i) \cdot \frac{w_k^3}{act_k^2} \cdot m(act_l^1, r_k^2) \quad (4.35)$$

$$\begin{aligned} \frac{\partial E}{\partial w_{kl}^1} = & \frac{-2b}{p(\ln(r_2^3) - \ln(r_1^3))} \cdot \sum_i (act_1^3 - t_i) \cdot \\ & \left(\sum_j w_j^3 \cdot \frac{w_{jk}^2}{act_j^2} \cdot m(act_k^1, r_j^2) \cdot \frac{(act_k^1)^{2b-1}}{(r_j^2)^{2b}} \cdot (err_k^1)^{\frac{1-p}{p}} \cdot |\mu_l - x_l|^p \right) \end{aligned} \quad (4.36)$$

Die partiellen Ableitungen für die freien Parameter r_k^i ($i = 2, 3$) ergeben sich zu:

$$\frac{\partial E}{\partial r_k^3} = \text{sgn}(1.5 - k) \cdot \sum_i (act_1^3 - t_i) \cdot \frac{err_1^3}{r_k^3 \cdot (\ln(r_2^3) - \ln(r_1^3))^2} \quad (4.37)$$

$$\frac{\partial E}{\partial r_k^2} = \frac{2b}{\ln(r_2^3) - \ln(r_1^3)} \cdot \sum_i (act_1^3 - t_i) \cdot \frac{w_k^3}{act_k^2} \cdot \sum_j w_{kj}^2 \cdot m(act_j^1, r_k^2) \cdot \frac{(act_j^1)^{2b}}{(r_k^2)^{2b+1}} \quad (4.38)$$

In einem iterativen Prozeß werden die einzelnen Vektoren aus dem Trainingsdatensatz durch das Netz propagiert, mit dem Zielwert verglichen und der entstandene Fehler auf Grundlage der partiellen Ableitungen (Gleichungen 4.34 bis 4.38) durch das Netz zurückpropagiert. Die freien Parameter werden entsprechend ihres Beitrags zum Fehler adaptiert. Im allgemeinen wird dabei eine sogenannte Lernrate η ($0 < \eta < 1$) verwendet, mit dem die Schrittweite der Adaption festgelegt wird. Ein zu verändernder Parameter x wird in Iteration i nach folgendem Muster angepaßt:

$$x^i = x^{i-1} - \eta \cdot \frac{\partial E}{\partial x} \quad (4.39)$$

η kann im weiteren Verlauf des Trainings schrittweise verkleinert werden, um dem Netz eine Feinjustierung der freien Parameter zu erleichtern.

4.4.6 Ausblick

Das hier behandelte neuronale fSIM-Modell kann im Rahmen dieser Arbeit nicht umfassend behandelt werden. Dennoch sollen Möglichkeiten und Probleme kurz diskutiert werden. Ein konzeptionelles Problem ist das Auftreten der ursprünglich globalen Variablen r_1 und r_2 in zwei verschiedenen Neuronenschichten. Eine Optimierung dieser Parameter kann durchaus zu verschiedenen Radien (Größe der lokalen Umgebung der Zugehörigkeitsfunktionen) führen. Es wäre zu untersuchen, ob diese Variablen tendenziell dem gleichen Wert zustreben oder ob sich zumindest Problemklassen definieren lassen, bei denen sich ein solches konvergentes Verhalten beobachten läßt. Eine Trennung der einzelnen Radien in zwei verschiedene freie Parameter kann durch das sogenannte *weight sharing* vermieden werden. Dabei werden r_1 und r_2 als Gewichte zweier weiterer Neuronen modelliert. Diese Neuronen haben eine konstante Aktivierung mit dem Wert 1. Sie sind mit den jeweiligen Neuronen der zweiten und dritten Schicht verbunden und leiten über die Gewichte die Radienwerte weiter. Zu klären ist allerdings, ob beim Zurückpropagieren der Fehler aus den Neuronen der beiden verschiedenen Schichten zu den Gewichten (= Radien) ein konvergierendes Verhalten zu beobachten ist.

Problematisch sind weiterhin die Gewichte der ersten Schicht. Sie reflektieren die Bedeutung der einzelnen Komponenten eines Eingabevektors \vec{x} und daher ist ihr Wertebereich auf \mathbb{R}_0^+ beschränkt. Ein weiterer Grund für diese Beschränkung ist mathematischer Natur: bei negativen Gewichten können negative Operanden in der Wurzelfunktion (Gleichung 4.17 bei $p = 2$) auftreten. Auch hier sind Anwendungsklassen zu finden, deren Behandlung durch fSIM zu negativen Gewichten in der ersten Schicht führt. Die einfachste Möglichkeit, dieses Problem zu umgehen, ist die Entkopplung der Kodierungsschicht vom Adaptionprozeß. Dem Anwender bliebe es dann überlassen, die Gewichte zu bestimmen und die Aufgabe dieser Schicht wäre dann als Vorverarbeitungsschritt zu betrachten. Eine ebenfalls nicht ganz

befriedigende Lösungsalternative ist, die Gewichte durch einen einfachen Kontrollmechanismus nicht kleiner als 0 werden zu lassen. Ein eleganteres Verfahren ist die Modellierung der Gewichte als Funktion: $w_{kl}^1 = f(\hat{w}_{kl}^1)$. Die Funktion $f(x)$ läßt sich wie folgt charakterisieren. Sie ist eine Abbildung der Art $f: \mathbb{R} \rightarrow \mathbb{R}_0^+$ und soll monoton steigend sein. Für $x < 0$ soll sie einen Wert nahe 0 aufweisen und für $x \rightarrow -\infty$ gegen 0 konvergieren. Da diese Funktion den Definitionsbereich \mathbb{R} hat, können die Gewichte \hat{w}_{kl}^1 negativ werden. Problematisch kann sich jedoch folgender Effekt auswirken. Liegt der Funktionswert von $f(\hat{w}_{kl}^1)$ in einem Bereich sehr geringer Steigung, so kann es unter Umständen lange dauern, bis das Gewicht durch Gradientenabstiegsverfahren merklich verändert werden kann.

Durch die Plastizität des neuronalen Ansatzes und damit einer verbesserten Anpassung an das zu lösende Problem ist eine niedrigere Rauschempfindlichkeit zu erwarten. Aber auch hier sind systematische Untersuchungen notwendig.

Eine sehr interessante Frage ist, ob sich durch die Einführung der Gewichte in der zweiten Schicht auch komplexere Strukturen unterscheiden lassen. Diese Erwartung ist dadurch begründet, daß jeder Position im Bereich der Zugehörigkeitsfunktion zwei Gewichte zugeordnet sind (je eines für die beiden radialen Basisfunktionen). Damit ließe sich der Anwendungsbereich dieses Modells erheblich erweitern.

In weiteren Untersuchungen sind auch die Fragen nach einer sinnvollen Initialisierung der freien Parameter, der Lerndauer und der angemessenen Lernrate zu klären. Auch der Einfluß der Größe des Trainingsdatensatzes auf die Klassifikationsrate ist im Hinblick auf die Anzahl an freien Parametern von Interesse. Im Vordergrund der Untersuchungen muß auch die Frage stehen, wie das Training der Radien r_k^i vor sich gehen soll. Vorgeschlagen wurde ein zweistufiges Verfahren, bei dem zunächst die Radien und anschließend die Gewichte adaptiert werden. Dazu müssen sinnvolle Abbruchkriterien für die erste Stufe gefunden werden. Aber auch Alternativen wie zum Beispiel ein kombiniertes oder alternierendes Anpassen der Radien und der Gewichte sollen nicht außer Acht gelassen werden. Weiterhin sollte das Modell auch auf Probleme außerhalb der Bildverarbeitung angewandt und dort seine Möglichkeiten untersucht werden.

4.5 TDE-SIM

Strukturen, die sich in ihren Grauwerten nur gering von ihrer Umgebung unterscheiden, können mit SIM oder fSIM nur durch vorherige, unter Umständen aufwendige Bildaufbereitung detektiert werden. Das Vorhandensein solch schwach kontrastierter Strukturen muß darüberhinaus vorher bekannt sein. Eine Vorverarbeitung des Bildes ist notwendig, da der geringe Grauwertunterschied den Wert der binären Zugehörigkeitsfunktion $\theta(x)$ nicht und den der fuzzifizierten Zugehörigkeitsfunktion $m(x, r)$ nur gering verändert. Einen direkten Weg der quantitativen strukturellen Beschreibung kann durch die Skalierungs-Index-Methode in Verbindung mit topologisch verteilter Kodierung (*topological distributed encoding*, TDE, [Gei90, Pom94]) der Grauwerte erreicht werden. TDE fand bisher in der Neuroinformatik zur Kodierung von Eingangssignalen für neuronale Netze [Eld96, ESP97] Anwendung. Eine strukturelle Analyse mit SIM und topologisch verteilter Kodierung soll mit TDE-SIM abgekürzt werden.

Topologisch verteilte Kodierung (TDE)

Zur topologisch verteilten Kodierung wird der Wertebereich des Eingangssignals (z.B. die Grauwertskala) gleichmäßig mit Funktionen mit lokalem Ansprechverhalten überdeckt (sogenannte Kodierungsfunktionen). Lokales Ansprechverhalten bedeutet, daß die einzelnen Funktionen nur in einem Teilintervall (*rezeptives Feld*) des möglichen Wertebereichs einen signifikant von 0 verschiedenen Funktionswert (die Aktivität einer Kodierungsfunktion) haben. Im Zentrum μ des rezeptiven Feldes ist die Aktivierung *cod* der Funktion maximal und fällt symmetrisch mit wachsender Distanz ab. Eine vorbestimmte Anzahl dieser Kodierungsfunktionen wird äquidistant über das vorhandene Grauwertintervall verteilt. Ein Grauwert g aktiviert nun mehrere dieser Kodierungsfunktionen. Grauwerte in der Umgebung von g erzeugen ein ähnliches Aktivierungsmuster. Grauwertunterschiede können jedoch durch die unterschiedlichen Aktivierungen benachbarter Kodierungsfunktionen besser unterschieden werden. Die Anzahl der Kodierungsfunktionen bestimmt das Auflösungsvermögen der Kodierung; sie steigt mit zunehmender Zahl an Kodierungsfunktionen. Durch die topologisch verteilte Kodierung mit n Kodierungsfunktionen wird ein eindimensionales Signal in einen n -dimensionalen Raum abgebildet. Diese Kodierung ist also eine Funktion der Form

$$TDE : \mathbb{R} \rightarrow \mathbb{R}^n \quad (4.40)$$

und soll mit $TDE(x)$ bezeichnet werden.

Oftmals sind die Eingangssignale nicht gleichmäßig über ihren Wertebereich verteilt, sondern kommen an bestimmten Intervallen gehäuft vor. Anstatt die Zentren der Kodierungsfunktionen äquidistant über den Wertebereich zu verteilen, können die Kodierungsfunktionen an diesen Intervallen konzentriert werden, um die Auflösung dort lokal zu erhöhen.

Aus der Vielzahl möglicher Kodierungsfunktionen wird hier die Gaußsche Glockenkurve verwendet:

$$cod_{\mu}^{\sigma}(x) = \exp\left(-\frac{1}{2} \cdot \frac{(x - \mu)^2}{\sigma^2}\right) \quad (4.41)$$

Der Streuungsparameter σ wird dabei so besetzt, daß das Auflösungsvermögen der Kodierung optimiert wird. Dabei wird angenommen, daß das maximale Auflösungsvermögen ei-

ner Kodierungsfunktion an der Stelle lokalisiert ist, an der der Betrag des Gradienten der Kodierungsfunktion maximal ist. σ ist nun so zu wählen, daß jede Kodierungsfunktion ein definiertes Teilintervall des Wertebereichs des Eingangssignals optimal kodiert und so der Wertebereich des Eingangssignals durch die Gesamtheit der Kodierungsfunktionen kontinuierlich abgedeckt wird. Zur Optimierung des Auflösungsvermögens der Kodierung wird die Streuung σ der Kodierungsfunktionen belegt mit ($\Delta\mu$ ist der Abstand zwischen den Zentren zweier Kodierungsfunktionen):

$$\sigma = \frac{k_\sigma}{2} \cdot \frac{1}{\sqrt{2}} \cdot \Delta\mu \quad k_\sigma = 2, 3, 4, \dots \quad (4.42)$$

Mit steigendem k_σ nimmt die Breite der einzelnen rezeptiven Felder zu. Für eine genauere Beschreibung und Herleitung von Gleichung 4.42 siehe [Kin90].

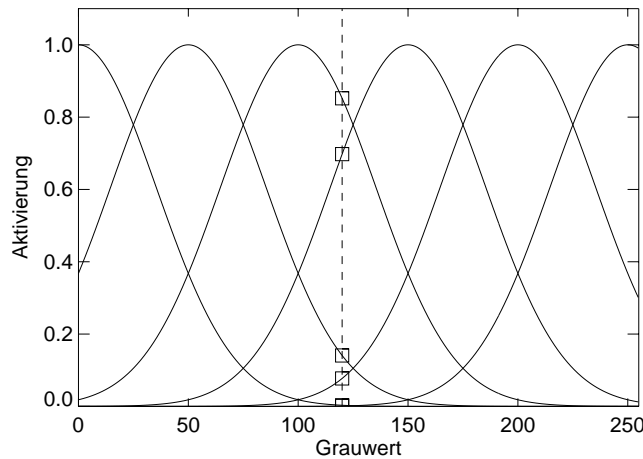


Abbildung 4.22: *Topologisch verteilte Kodierung des Wertes 120 (gestrichelte vertikale Linie) mit 6 Kodierungsfunktionen.* Die Aktivierungen der Funktionen sind mit einem Kästchen markiert.

Abbildung 4.22 zeigt beispielhaft die Kodierung des Grauwertes 120 mit 6 Kodierungsfunktionen bei $k_\sigma = 2$. Der Grauwert wird damit in einen höherdimensionalen Raum eingebettet. Das stark erhöhte Auflösungsvermögen führt allerdings eine erhöhte Rauschempfindlichkeit des Verfahrens mit sich.

TDE-SIM

Die formale Definition von TDE-SIM erfordert einige Änderungen am SIM-Formalismus. Aus Gründen der Übersichtlichkeit wird von einem Grauwertbild ausgegangen. Damit ist nur der Grauwert, ein eindimensionales Signal, zu kodieren. Die Definition für höherdimensionale Signalmräume erfolgt analog.

In der Formulierung von SIM bestimmen die Radien r_1 und r_2 auch die lokale Umgebung des zu untersuchenden Punktes im diskreten Gitter eines digitalen Bildes (Gleichung 4.3, Seite 22). Die Abbildung der Grauwerte in den n -dimensionalen Raum $[0, 1]^n$ erfolgt mit Hilfe der Gaußfunktion. Es empfiehlt sich daher, die Radien einzeln zu skalieren (vgl. Abschnitt 4.2.1,

Seite 24). Aus diesem Grund muß der Formalismus zur Berechnung der Skalierungsindizes leicht verändert werden. Dazu werden wie bisher r_1 und r_2 als Radien für das x - und y -Bildgitter verwendet. Zusätzlich werden die Parameter r_1^c und r_2^c eingeführt, die die Radien für die Aktivierungen der Kodierungsfunktionen enthalten. Zur formalen Beschreibung der Methode ist es vorteilhaft, die Position eines Punktes \vec{x}_i im diskreten Bildgitter mit

$$pos(\vec{x}_i) = (x_i^x, x_i^y) \quad (4.43)$$

abzukürzen. x_i^x bezeichnet die x -Koordinate und x_i^y die y -Koordinate von \vec{x}_i . Weiterhin soll mit g_i der Grauwert des Pixels \vec{x}_i bezeichnet werden. Somit läßt sich die Berechnung der lokalen Masse N^{tde} für einen Punkt \vec{x}_i bei TDE-SIM beschreiben mit:

$$N^{tde}(\vec{x}_i, r, r^c) = \sum_j \Theta(r - \|pos(\vec{x}_i) - pos(\vec{x}_j)\|_p) \cdot \Theta(r^c - \|TDE(g_i) - TDE(g_j)\|_p) \quad (4.44)$$

Der erste Faktor in Gleichung 4.44 überprüft die Zugehörigkeit des Punktes \vec{x}_j zur lokalen Umgebung von \vec{x}_i aufgrund seiner Position im diskreten Bildgitter und der zweite Faktor bestimmt diese Zugehörigkeit auf der Basis des durch TDE kodierten Grauwerts.

Der Skalierungsindex α^{tde} läßt sich nun bestimmen durch

$$\alpha^{tde}(\vec{x}_i, r_1, r_2, r_1^c, r_2^c) = \frac{\log N(\vec{x}_i, r_2, r_2^c) - \log N(\vec{x}_i, r_1, r_1^c)}{\log r_2 - \log r_1} \quad (4.45)$$



Abbildung 4.23: *Testbild zur TDE-SIM*: Neben den sichtbaren Strukturen sind im Grauwertbild weitere drei Strukturen enthalten, die sich nur durch eine Grauwertdifferenz von 1 vom Hintergrund abheben.

Beispiel

An einem künstlich erzeugten Beispiel (Abbildung 4.23) soll die Verbesserung der strukturellen Erfassung mit TDE demonstriert werden. Das Bild (256×256 Pixel) zeigt zwei linienartige Strukturen und eine kreisförmige Struktur (deren Grauwert beträgt jeweils 150) vor einem Hintergrund mit Grauwert 128. Mit einem Grauwert von 129 (Grauwertdifferenz zum Hintergrund: 1) sind zwei weiteren Linien und ein Kreis für das Auge nicht sichtbar.

Dieses Grauwertbild wird mit SIM und TDE-SIM analysiert. Da die zu untersuchenden Strukturen eine maximale Breite von etwa 5 Pixeln haben, wurden zur Erfassung dieser Objekte mit SIM als Radien $r_1 = 3$ und $r_2 = 6$ gewählt. Die in Grauwerten umgesetzten Skalierungsindizes sind im linken Teil der Abbildung 4.24 zu sehen (mit der Helligkeit nimmt auch der Skalierungsindex zu). Mit SIM können zwar die deutlich vom Hintergrund abgesetzten Strukturelemente detektiert werden, aber die restlichen Strukturen werden nicht erfaßt. Das gleiche Bild wurde mit TDE-SIM mit 10 Kodierungsfunktionen analysiert. Für das diskrete Bildgitter wurden dieselben Radien und als Aktivationsradien $r_1^c = 0.1$ und $r_2^c = 0.2$ gewählt. Die Belegung dieser Parameter wurde in Versuchen bestimmt. Das Ergebnis ist im rechten Teil der Abbildung 4.24 zu sehen. Neben den auffälligen Strukturen wurden auch diejenigen korrekt detektiert, die nur einen sehr geringen Grauwertunterschied zur Umgebung aufweisen.




Abbildung 4.24: Bei der Analyse des Bildes 4.23 mit SIM (links, die Skalierungsindizes der Bildpixel sind mit dem Grauwert kodiert) werden nur die deutlich abgesetzten Strukturen detektiert. Neben den visuell erkennbaren Strukturen werden mit TDE-SIM (rechts) auch die Strukturen mit Grauwertunterschied 1 zum Hintergrund erkannt.

Ausblick

Der fSIM-Ansatz ist auch bei TDE-SIM anwendbar. Diese Kombination läßt sich ebenfalls neuronal formulieren und die damit erreichte Plastizität kann zur Optimierung des Auflösungsvermögens eingesetzt werden. Zur verbesserten Nutzung der Kodierungsfunktionen lassen sich ihre Zentren selbstorganisierend verschieben (adaptive topologisch verteilte Kodierung ATDE [EG94] [Pom94]). Diese Optimierung des Auflösungsvermögens durch Konzentration von Kodierungsneuronen an bestimmten Stellen des Grauwertintervalls kann anhand zweier Ansätze vorgenommen werden. Zum einen kann man Kodierungsfunktionen adaptiv in Grauwertintervallen konzentrieren, in die viele Grauwerte der Anwendung fallen. Zum anderen können auch zur Minimierung des Klassifizierungsfehlers des neuronalen Netzes die Kodierungsneuronen zu Bereichen der Grauwertachse verschoben werden, an denen die Fehlerhäufigkeit des neuronalen Netzes besonders hoch ist. Auch ein adaptives Einfügen neuer Kodierungsfunktionen [Pom94] sollte untersucht werden.

Kapitel 5

Randeigenschaften

In diesem Kapitel werden Verfahren vorgestellt, die Eigenschaften von Objekträndern quantitativ und nachvollziehbar charakterisieren. Unter dem Begriff *Rand* wird die Kontur und der Randbereich eines Objekts zusammengefaßt. Randbereiche werden hier als Regionen definiert, die die Kontur enthalten, aber in unterschiedlicher Ausprägung flächenartig in das Objekt hineinreichen können. Zur Bestimmung des Randbereichs werden zwei Algorithmen mit unterschiedlichen Eigenschaften beschrieben. Die so bestimmte Region wird hinsichtlich struktureller Zusammensetzung und Homogenität charakterisiert. Abschließend werden die Verfahren an einem Beispiel aus der Ozeanographie getestet. Weiterhin werden Charakterisierungsalgorithmen für den Konturverlauf und seine Homogenität vorgestellt.

5.1 Randbereich

Viele Objekte sind zu ihrer Umgebung nicht markant abgesetzt, sondern weisen einen Übergangsbereich auf. Der binär maskierte Übergangsbereich soll hier Randbereich genannt werden und entspricht einem zusammenhängenden, das Objekt umfassenden Bereich. Die Eigenschaften des Randbereichs enthalten oft wichtige Informationen über die Art des Objekts. Von besonderem Interesse ist die strukturelle Beschreibung des Randbereichs und die Homogenität dieser strukturellen Eigenschaften. Voraussetzung zur Quantifizierung dieser Eigenschaften ist die Extraktion des Randbereichs. Daher werden zunächst zwei unterschiedliche Verfahren zur Randbestimmung angegeben. Dem schließt sich die Beschreibung der Quantifizierungsverfahren und deren Anwendung auf ein Beispiel an, das der Ozeanographie entstammt.

5.1.1 Extraktion des Randbereichs

Der vorgeschlagene Extraktionsalgorithmus basiert auf dem Prinzip der Bereichswachstumsverfahren [GW92]. Ausgehend von einem oder mehreren Startpunkten (*seed points*) werden Umgebungspixel angelagert, die unmittelbar an den Startpunkt angrenzen und ein Homogenitätskriterium erfüllen (z.B. der Grauwert des Pixels fällt in ein definiertes Grauwertintervall). Dieser Prozeß wird solange fortgesetzt bis keine weiteren Nachbarpixel das Homogenitätskriterium erfüllen oder ein zu definierendes Abbruchkriterium gilt. Dieser Ansatz trägt inhärent zwei Probleme in sich. Die erste Schwierigkeit ist die Wahl des Startpunkts. Zur Lösung werden häufig Heuristiken eingesetzt oder der Startpunkt wird durch den Benutzer interaktiv gewählt. Das zweite Problem betrifft die Wahl des Homogenitätskriteriums. Ist der Übergang der Grauwerte der Pixel des Randbereichs in ihre Umgebung teilweise scharf begrenzt und andernorts nur schwach kontrastiert, so muß die Homogenitätsfunktion beide konkurrierende Teilaufgaben bewältigen. Wird das Homogenitätskriterium restriktiv formuliert, so wird der Randbereich unvollständig erfaßt. Bei unspezifischer Formulierung kann es dagegen zu einem unerwünschten "Auslaufen" des Randbereichs kommen.

In dem vorgeschlagenen Verfahren werden beide Probleme durch zwei Annahmen vermieden. Die Startmenge des modifizierten Bereichswachstumsverfahrens sind die Konturpixel des zu untersuchenden Objekts. Durch eine maximal mögliche Breite des Randbereichs wird ein Auslaufen verhindert. Beide Annahmen stellen keine Restriktion im Sinne einer Randbereichsbestimmung dar, da die erste Annahme eine sinnvolle Initialisierung der Randbereichspixel darstellt und die zweite Annahme lediglich eine Begrenzung der möglichen Breite des Randbereichs vornimmt.

Es werden zwei Algorithmen vorgestellt, die den Randbereich von Objekten unter verschiedenen Aspekten extrahieren. Es wird dabei angenommen, daß sich der Randbereich des Objekts durch einen Grauwertübergang von hell zu dunkel oder umgekehrt vom umgebenden Bereich unterscheidet. Der erste Algorithmus, eine leichte Variation des Bereichswachstumsverfahrens, dient zur Bestimmung der Ausdehnung des Grauwertübergangs. Der zweite betont Inhomogenitäten in den Grauwertübergängen von der Kontur zum Objektinneren.

Ausdehnungsorientierter Ansatz

In diesem Ansatz wird die Breite des Randbereichs durch ein globales Homogenitätskriterium bestimmt, mit dem überprüft wird, ob der Grauwert eines Pixels in ein definiertes Grauwert-

intervall fällt. Durch dieses globale Kriterium wächst der Randbereich an den Stellen, die einen wenig akzentuierten Übergang zur Umgebung aufweisen.

Dazu wird die Menge der Randbereichspixel B mit der Menge der Konturpixel initialisiert. Im nächsten Schritt wird der Mittelwert der Grauwerte \bar{g} aller Konturpixel berechnet (g bezeichnet den Grauwert eines Pixels), der zur Auswertung des globalen Homogenitätskriteriums verwendet wird. Zur Bestimmung der weiteren Randbereichspixel wird iterativ n -mal folgenderweise vorgegangen. Die in der Berandungsmenge B befindlichen Pixel werden in einem Binärbild markiert. Durch morphologische Operationen (siehe untenstehende pseudoalgorithmische Formulierung) werden diejenigen Pixel innerhalb des Objekts bestimmt, die noch nicht zur Menge B gehören und benachbart zu den Pixeln aus B sind. Aus der Menge der so bestimmten Pixel werden diejenigen der Randbereichsmenge B zugeführt, deren Grauwerte g dem Homogenitätskriterium genügen. Ist das Objekt dunkler als seine Umgebung, so ist der Randbereich durch eine höhere Helligkeit als das Objektinnere charakterisiert und das Homogenitätskriterium umfaßt diejenigen Pixel g , die heller als ein Schwellwert sind: $g \in [(\bar{g} - g_{\text{diff}}), 255]$. g_{diff} ist ein vorgegebener Parameter, der die Selektivität des Algorithmus steuert. Mit steigendem Wert von g_{diff} verbreitert sich das Intervall, in das der Grauwert eines Pixels fallen muß, um zur Randbereichsmenge hinzugefügt zu werden. Ist das Objekt heller als seine Umgebung, so ist das Homogenitätskriterium durch das Intervall $[0, (\bar{g} + g_{\text{diff}})]$ definiert. Durch das iterative Verfahren wird der Randbereich in einem schichtenweisen Vorgehen bestimmt, das in Abbildung 5.1 illustriert ist.



Abbildung 5.1: *Illustration zur Bestimmung des Randbereichs*: Die drei Abbildungen zeigen Momentaufnahmen aus dem iterativen und schichtenweisen Vorgehen (von links nach rechts: Ergebnis nach 5, 10 und 20 Iterationen). Ausgehend von der Kontur entsteht eine geschlossene und das Objekt umfassende Region. Deutlich wird, daß in der rechten Abbildung (20 Iterationen) der Randbereich in der linken Hälfte breiter wird. Dies bedeutet, daß der Helligkeitsübergang von Objekt zu Umgebung dort relativ langsam erfolgt.

Das Auslaufen des Randbereichs wird durch die Beschränkung auf n Iterationsschritte verhindert. Als Vorverarbeitungsschritt empfiehlt sich eine Grauwertglättung. In pseudoalgorithmischer Darstellung läßt sich der Algorithmus folgendermaßen zusammenfassen:

```

Initialisiere B mit den Konturpixeln
imMask := binäres Bild, nur Objektpixel ausser Kontur sind gesetzt
imNeg := not(imMask)

```

```

gMean := Mittelwert der Grauwerte der Konturpixel
H(g) := Homogenitätskriterium zu Grauwert g
/* z.B. H(g) := g ≥ (ḡ - gdiff) */
Von (i=1) bis n:
    /* Bestimmung der nächst inneren Schicht
       der nicht zur Randmenge gehörenden Objektpixel: */
    i1 = dilate(imNeg)
    i2 = xor(imNeg,i1)
    /* ueberpruefe Homogenitätskriterium */
    Von (j=1) bis (Anzahl der in i2 gesetzten Pixel)
        Falls (H(Grauwert von Pixel j) == true) dann
            B = B ∪ {Pixel j}
            setze Pixel j in imNeg auf 1

```

Das Ergebnis des Algorithmus ist eine das Objekt umschließende Region, die breiter ist, je weniger akzentuiert der Grauwertübergang von Objekt zu Umgebung ist.

Homogenitätsorientierter Ansatz

Der zweite Algorithmus zur Extraktion des Randbereichs betont Inhomogenitäten in den Helligkeitsübergängen von der Kontur zum Objektinneren. Erreicht wird dies durch ein verändertes Homogenitätskriterium. Anstatt bei jedem Randkandidaten einen globalen Schwellwert zu überprüfen wird ein adaptives Element eingeführt. In jedem Teilschritt werden die hellsten bzw. dunkelsten Pixel der Menge B zugefügt. Dazu wird bis zu der Stelle wie in obigen Algorithmus vorgegangen, an der die Pixel für den Randbereich ausgewählt werden. Die Menge der möglichen "Kandidaten" an neuen Randbereichspixeln sei mit E bezeichnet. Die Pixel werden aufsteigend (bzw. absteigend) entsprechend ihres Grauwerts sortiert. Die ersten $p \cdot |E|$ ($0 \leq p \leq 1$) Pixel aus der sortierten Menge E werden der Randbereichsmenge B zugeführt. Der Parameter p steuert die Selektivität des Algorithmus: mit fallendem p -Wert werden in jedem Iterationsschritt weniger Pixel der Randbereichsmenge zugeordnet. n bestimmt wie im vorigen Ansatz die Anzahl der Iterationen und damit die maximale Breite der Berandung. Wiederum entsteht ein geschlossenes, das gesamte Objekt umfassendes Gebiet. Auch hier führt eine vorgeschaltete Glättung des Grauwertbildes meist zu einer verbesserten Erfassung des Randbereichs. In pseudo-algorithmischer Darstellung stellt sich das Verfahren folgendermaßen dar:

```

Inititalisiere B mit den Konturpixeln
imMask := binäres Bild, nur Objektpixel ausser Kontur sind gesetzt
imNeg := not(imMask)
Von (i=1) bis n:
    /* Bestimmung der nächst inneren Schicht
       der nicht zur Randmenge gehörenden Objektpixel: */
    i1 = dilate(imNeg)
    i2 = xor(imNeg,i1)
    /* ueberpruefe Homogenitätskriterium */

```

```

E := Menge der auf 1 gesetzten Pixel in i2
sortiere die Pixel aus E aufsteigend
      bzw. absteigend nach ihrer Helligkeit
l = ROUND(p*|E|)
Von (j=1) bis l
      B = B ∪ {Pixel l}
      setze Pixel j in imNeg auf 1

```

5.1.2 Quantifizierung des Randbereichs

Im folgenden werden Verfahren beschrieben, die den extrahierten Randbereich bezüglich seiner strukturellen Zusammensetzung und der Homogenität dieser Zusammensetzung charakterisieren.

5.1.2.1 Beurteilung der strukturellen Zusammensetzung

Um die Art des Übergangs von Objekt zu Hintergrund zu beschreiben, kann der binär vorliegende Randbereich mit der Skalierungs-Index-Methode SIM (Abschnitt 4.2.1) oder fSIM (Abschnitt 4.4) analysiert werden. Dazu werden die Skalierungsindizes $\alpha(p)$ für die Randbereichspixel $p \in B$ bestimmt. Eine Analyse mit der isotropen Variante von SIM erlaubt eine Zerlegung des Randbereichs in linienförmige und flächenartige Elemente. Zusätzlich werden kurze linienhafte Strukturen, die zwei flächenhafte Regionen verbinden ("Stege"), ebenfalls markiert, da sie sich durch einen hohen Skalierungsindex auszeichnen. Aus den vielen Möglichkeiten zur Umsetzung der lokalen Skalierungsindizes in einen globalen Score sei hier stellvertretend ein Verfahren beschrieben. Mittels eines Schwellwerts t_α wird die Menge der Randbereichspixel B anhand ihrer Skalierungsindizes in zwei disjunkte Mengen geteilt:

$$B_1 = \{p \in B | \alpha(p) \leq t_\alpha\} \quad (5.1)$$

$$B_2 = \{p \in B | \alpha(p) > t_\alpha\} \quad (5.2)$$

Mit t_α lassen sich bestimmte Strukturen im Randbereich selektieren. So werden bei einem Schwellwert $t_\alpha = 1$ linienhafte Elemente markiert. Als der Berandungsscore B_{SIM} wird das Verhältnis von B_1 zu B definiert:

$$B_{SIM} = \frac{|B_1|}{|B_1| + |B_2|} \quad (5.3)$$

Das Analyseergebnis läßt sich durch unterschiedliche farbliche Darstellung der Mengen B_1 und B_2 visualisieren und damit dem Nutzer vermitteln.

Eine unterschiedliche Charakterisierung des Randbereichs läßt sich mit Hilfe der rotationsinvarianten anisotropen Skalierungsindizes erstellen (vgl. Abschnitt 4.3, Seite 29). Bei dieser Methode wird vor der Berechnung des anisotropen Skalierungsindex die Orientierung der lokalen Umgebung des untersuchten Pixels so gedreht, daß sie parallel zur x -Koordinatenachse verläuft. Die resultierenden anisotropen Skalierungsindizes können entsprechend Gleichungen 5.1 bis 5.3 zu einen globalen Score zusammengefaßt und visualisiert werden.

5.1.2.2 Beurteilung der strukturellen Homogenität

Zur Charakterisierung der Berandungseigenschaften kann auch die Homogenität der in Abschnitt 5.1.2.1 behandelten Maße bezüglich ihrer Verteilung über den Randbereich von Bedeutung sein. Im Zentrum steht also die Beurteilung, wie sehr sich Regionen des Randbereichs in ihrer strukturellen Beschreibung untereinander unterscheiden. Zur Lösung dieses Problems wird der Randbereich in disjunkte Unterbereiche geteilt. Diese Unterbereiche werden hinsichtlich ihrer strukturellen Zusammensetzung beurteilt. Aus diesen lokalen Scores wird dann das globale Maß für die strukturelle Homogenität des Randbereichs ermittelt.

Erster Schritt in dem vorgeschlagenen Verfahren ist die Unterteilung des Randbereichs in disjunkte Unterbereiche. Die Aufteilung des Randbereichs erfolgt über die Voronoi-Zerlegung [SDK96]. Zur Voronoi-Zerlegung einer Punktmenge $M \subset \mathbb{R}^d$ muß eine Menge $A \subset M$ gegeben sein. Das Voronoi-Gebiet $V(p)$ eines Punktes $p \in A$ ist die Menge aller Punkte aus M , die p bezüglich einer Abstandsmetrik näher liegen als allen anderen Punkten aus der Menge A . Als Abstandsmetrik wird üblicherweise die Euklidische Norm verwendet. In diesem Anwendungsfall entspricht die Menge der Berandungspixel $B \subset \mathbb{R}^2$ der Menge M .

Zur Voronoi-Zerlegung des Randbereichs muß also zunächst die Menge A bestimmt werden. Dazu werden zwei Varianten vorgeschlagen. Beide verwenden eine geschlossene Linie, die im Randbereich liegt und ihn adäquat beschreibt. Dies kann beispielsweise die Objektkontur oder die Linie sein, die den mittleren Verlauf des Randbereichs wiedergibt. Die Kontur ist im allgemeinen Ergebnis der Segmentierung, der mittlere Verlauf kann beispielsweise mittels morphologischer Operatoren extrahiert werden. Diese Linie kann als Punktsequenz S derart dargestellt werden, daß benachbarte Linienpixel auch in der Sequenz benachbart liegen. Die längenorientierte Variante zur Bestimmung von A fügt jeden l -ten Punkt von S der Menge A zu:

$$A^0 = S(0)$$

$$A^{i+1} = A^i \cup \{S(l \cdot i)\} \quad 0 < i < \lfloor \frac{\text{length}(S)}{l} \rfloor$$

Mit $\lfloor \cdot \rfloor$ wird die größte natürliche Zahl bezeichnet, die kleiner als das Argument ist.

Der Aufbau der Menge A bei der zweiten Variante basiert auf der äquidistanten Verteilung der Punkte entlang der Linie (distanzorientierte Variante):

```

x = S(0)
A = {x}
i = 0
while (i < length(S)) do
  suche nächsten Punkt mit ||x - S(k)||_p ≥ l (k > i)
  i = k
  x = S(k)
  if (i < length(S)) then A = A ∪ {x}

```

Die Initialisierung von A sollte im Sinne der Reproduzierbarkeit des Ergebnisses nach definierten Regeln vonstatten gehen. Anhand der so bestimmten Menge A wird die Voronoi-Zerlegung des Randbereichs B vorgenommen. Jede der disjunkten Mengen $V(p_i)$ ($p_i \in A$),

die die Unterbereiche des Randbereichs beschreiben, wird analog zu Gleichungen 5.1 bis 5.3 mittels eines Schwellwerts t_α hinsichtlich ihrer strukturellen Zusammensetzung beurteilt:

$$b_{i,1} = \{p \in V(p_i) | \alpha(p) \leq t_\alpha\} \quad (5.4)$$

$$b_{i,2} = \{p \in V(p_i) | \alpha(p) > t_\alpha\} \quad (5.5)$$

$$s_i = \frac{|b_{i,1}|}{|b_{i,1}| + |b_{i,2}|} \quad (5.6)$$

Diese auf die Voronoi-Zerlegung bezogen lokalisierten Scores werden mittels eines Varianzmaßes zusammengefaßt zu:

$$B_H = \frac{1}{n-1} \sum_i (\bar{s} - s_i)^2 \quad (5.7)$$

\bar{s} ist der Mittelwert der s_i . Berandungen, die an manchen Stellen einen regelmäßigen Verlauf aufweisen, andernorts aber sehr unregelmäßig sind, wird ein hoher Score zugewiesen. Stets regelmäßige oder stets unregelmäßige Berandungen weisen dagegen einen relativ niedrigen Score auf.




Abbildung 5.2: Randbereiche zu den Bildern der helligkeitskodierten Oberflächentemperatur des Mittelmeers: Aus den Grauwerten, die die Oberflächentemperatur des Mittelmeers kodieren, wurden die Randbereiche extrahiert. Besonders in den Wintermonaten ist die ungleiche Temperaturverteilung im Norden und Süden zu erkennen. Im Sommer dagegen ist sie deutlich ausgeglichener. Dies spiegelt sich in der homogeneren Berandungsdicke wider.

5.1.3 Beispiel

Die vorgestellten Verfahren zur Quantifizierung der Randeigenschaften sollen am Beispiel einer Bildsequenz evaluiert werden, die die Oberflächentemperatur küstennaher Gebiete des Mittelmeers im Verlauf von zwölf Monaten erfassen. Dazu liegen zwölf thermische Aufnahmen zu jedem Monat des Jahres 1996 vor, in denen die Oberflächentemperatur des Wassers durch den Grauwert repräsentiert wird [Cen99]. Die Bilder haben eine Größe von 283×135 Pixel.

Extraktion des Randbereichs

Zur Beurteilung der Oberflächentemperaturverteilung in Küstennähe wird der Randbereich nach dem homogenitätsorientierten Algorithmus nach Abschnitt 5.1.1 mit den Parametern $n = 10$ (maximale Randbreite) und $p = 0.25$ (Selektivität) extrahiert. Diese Parameter haben sich in kurzen Tests bewährt. Das Ergebnis der Randbestimmung ist in Abbildung 5.2 zu sehen. Nach dieser Rechenvorschrift werden Inhomogenitäten in der Helligkeit der Berandungspixel hervorgehoben. Objekte, deren Grauwerte in der Umgebung der Kontur sehr ähnlich sind, haben somit einen Randbereich mit konstanter Breite. Diese Eigenschaft spiegelt sich in Abbildung 5.2 wider, denn die Wintermonate weisen die größten Inhomogenitäten auf, während in den Sommermonaten (z.B. Juli, August) eine relativ regelmäßige Berandung zu beobachten ist. Dies ist darauf zurückzuführen, daß im Winter die Differenz der Oberflächentemperatur in Nord-Südrichtung größer ist als im Sommer.

Quantifizierung des Randbereichs

Eine strukturelle quantitative Beschreibung der dargestellten Randbereiche des Mittelmeers

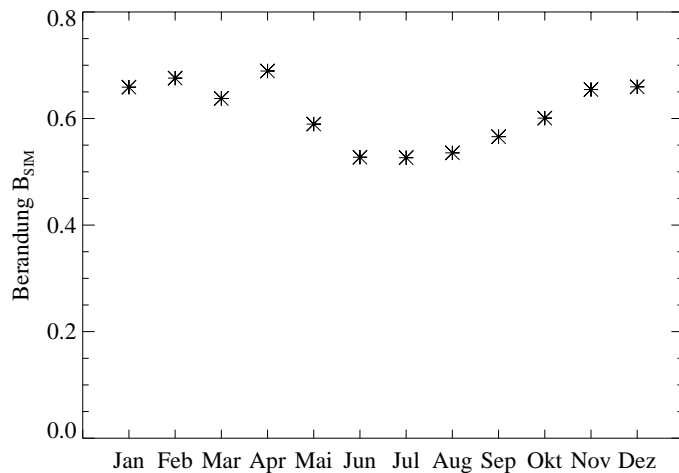


Abbildung 5.3: *Beurteilung des Randbereichs aus Abbildung 5.2:* Der Wechsel der Jahreszeiten und die damit verbundenen Schwankungen der Oberflächentemperatur des Mittelmeers lassen sich an den Werten der Berandungsscores nachvollziehen.

für die zwölf Monate kann mit dem Verfahren aus Abschnitt 5.1.2.1 (SIM-Variante) durchgeführt werden. Die Methode wurde mit den Radien $r_1 = 4$, $r_2 = 10$ und $t_\alpha = 1.3$ para-




Abbildung 5.4: *Visualisierung der strukturellen Beurteilung des Randbereichs*: Linienartige Strukturen sind grünlich, flächenartige sind rötlich markiert. Deutlich zu erkennen ist der höhere Rotanteil im Januar (links) als im Juli (rechts).

metrisiert, da diese Radien die extrahierten Strukturen gut erfassen (maximale Randbreite $n = 10$). Das globale Maß B_{SIM} zur strukturellen Beschreibung des Randbereichs ist in Abbildung 5.3 gegen die kalendarischen Monate aufgetragen. Ihr wellenförmiger Verlauf läßt sich wie folgt interpretieren. Der Score des Monats Januar ist sehr hoch und steigt weiter im Februar. Dies korrespondiert mit dem zunehmenden winterlichen Nord-Süd-Temperaturgefälle. Im Lauf des Frühlings und des Sommers sinkt der Wert und fällt im Juli auf ein Minimum, da sich durch die sommerliche Erwärmung die Temperaturen im gesamten Mittelmeerraum angleichen. Im weiteren Jahresverlauf steigen die Scores, bis im Dezember der Januarwert fast exakt erreicht wird.

Eine mögliche Visualisierung ist in Abbildung 5.4 dargestellt (links: Januar, rechts: Juli). Die Farbtabelle wurde so gewählt, daß linienartige Strukturen grün und flächenhafte Elemente rot kodiert sind. Auffällig im Januar (linker Teil der Abbildung) ist der höhere Anteil an Rot. Dieser Eindruck wird durch einen höheren Quantifizierungswert reflektiert.

Die Homogenität der strukturellen Zusammensetzung des Randbereichs, basierend auf den im vorigen Absatz beschriebenen Werten, wird mit dem Verfahren aus Abschnitt 5.1.2.2 beurteilt. Die Aufteilung der Berandung in disjunkte Mengen erfolgt nach dem längenorientierten Algorithmus (vgl. Seite 66), der mit $l = 90$ parametrisiert wurde. Der Parameter wurde in Tests ermittelt. Die Ergebnisse für die einzelnen Monate sind in Abbildung 5.5 dargestellt und lassen eine anschauliche Interpretation zu. Die minimalen Werte sind in den Winter- und Sommermonaten zu finden, da hier die Temperaturverteilungen sehr homogen sind. Obwohl im Winter der Temperaturunterschied zwischen Nord und Süd hoch ist, weist er innerhalb der nördlichen und südlichen Bereiche eine relativ geringe Variation auf. Im Sommer haben sich die Temperaturen im Mittelmeerbecken angeglichen. Die Temperaturverteilung in den Übergangsmonaten von Winter zu Sommer und von Sommer zu Winter zeichnen sich durch deutlich höhere Inhomogenitäten aus, da die Erwärmung des Mittelmeers nicht gleichmäßig verläuft.

Visualisieren läßt sich das Ergebnis anhand der Abweichungen der lokalen Scores der einzelnen Randsegmente vom Mittelwert. Diese Technik wurde zur Erstellung von Abbildung 5.6 (links: Januar, rechts: Mai) gewählt. Der Mittelwert hat in dieser Kodierung die Farbe Grün. Kleinere Scores werden bläulich, größere rötlich dargestellt.




Abbildung 5.5: *Beurteilung der Homogenität des Randbereichs aus Abbildung 5.2:* Die Homogenität der strukturellen Beschreibung des Randbereichs ist in den Monaten des Jahreszeitwechsels gegenüber Sommer bzw. Winter geringer.

5.2 Konturen

Die Kontur ist im Sinne des in Kapitel 2 beschriebenen Schemas Ergebnis der vor der Merkmalscharakterisierung erfolgenden Segmentierung. Die Beurteilung, ob die Kontur einen glatten und regelmäßigen oder aber einen unregelmäßigen Verlauf nimmt, ist ein wesentlicher Aspekt bei der Charakterisierung eines Objekts. In der Literatur finden Fourier-Deskriptoren (z.B. [Lon98]), fraktale Dimension (z.B. [Flo78] [CHKA92]) oder Krümmungsmaße (z.B. [VS91]) Verwendung. Allerdings sind die Ergebnisse der ersten beiden Techniken für eine nachvollziehbare quantitative Bildanalyse nur bedingt geeignet, da sie sich kaum transparent darstellen lassen. Daher wird in dieser Arbeit die Krümmung zur Bestimmung der Kontureigenschaften verwendet.



Abbildung 5.6: *Visualisierung der strukturellen Homogenität des Randbereichs:* Die Abweichungen der einzelnen Randsegmente vom Mittelwert sind farbkodiert. Dargestellt sind die Monate Januar (links) und Mai (rechts).

Ziel der Charakterisierung ist die quantitative Erfassung der Regelmäßigkeit des Konturverlaufs. Dazu wird für jedes Konturpixel die Krümmung an diesem Ort berechnet. Der Konturverlauf insgesamt wird mittels der Entropie der relativen Häufigkeitsverteilung der Krümmungen zu einem Gesamtscore zusammengefaßt.

Die Krümmung κ im Punkt M ist der Grenzwert des Verhältnisses des Winkels δ zwischen den positiven Tangentenrichtungen in den Punkten M und N zur Bogenlänge \widehat{MN} für $\widehat{MN} \rightarrow 0$ [BSMM95]:

$$\kappa = \lim_{\widehat{MN} \rightarrow 0} \frac{\delta}{\widehat{MN}} \quad (5.8)$$

Dieser analytische Wert kann in der Bildverarbeitung, bei der die einzelnen Pixel diskretisiert vorliegen, nicht unmittelbar errechnet werden. In der Literatur existieren verschiedene Vorschläge, wie dieses Maß in der Bildverarbeitung auf Konturen übertragbar ist. In dieser Arbeit wird der Vorschlag verwendet, der in [VS91] beschrieben ist. Dazu werden die Differenzen der Richtungen aufeinanderfolgender Konturpixel bestimmt. Der Autor zieht zur Berechnung der Richtung der Kontur bei Pixel i die 8er-Nachbarschaft mit ein. Die Richtung r_i von Konturpixel (x_i, y_i) nach (x_{i+1}, y_{i+1}) wird anhand der Differenzen $dx = x_{i+1} - x_i$ und $dy = y_{i+1} - y_i$ und folgender Zuordnung bestimmt:

r	0	1	2	3	4	5	6	7
dx	1	1	0	-1	-1	-1	0	1
dy	0	1	1	1	0	-1	-1	-1

d_i ist die Differenz aufeinanderfolgender Konturrichtungen:

$$d_i = (r_i - r_{i-1} + 12 \bmod 8) - 4 \quad (5.9)$$

Der Näherungswert K_i für die Krümmung in Konturpixel i wird bestimmt durch:

$$K_i = \sum_{j=-n}^{j=n} w(j) \cdot d_{i+j} \quad (5.10)$$

Der Parameter n bestimmt, wieviele Nachbarpixel von i in die Berechnung von K_i miteinbezogen werden. $w(j)$ ist eine geeignete Wichtungsfunktion, die näher zum Pixel i liegende Konturpixel höher gewichtet. Hier wird folgende Funktion verwendet, die eine Verallgemeinerung der in [VS91] vorgeschlagenen darstellt:

$$w(j) = \frac{(n+1) - |j|}{\sum_k w(k)} \quad (5.11)$$

Ein sehr unregelmäßiger Konturverlauf schlägt sich in einer Vielfalt von unterschiedlichen Krümmungen an den verschiedenen Positionen der Kontur nieder. Daher wird die Entropie der relativen Häufigkeitsverteilung p_j der Krümmungen als globales Maß für die Konturregelmäßigkeit K verwendet:

$$K = - \sum_j p_j \log(p_j) \quad (\forall p_j > 0) \quad (5.12)$$

Die Homogenität des Konturverlaufs läßt sich analog zu dem Verfahren zur Charakterisierung der Homogenität des Randverlaufs bestimmen (Abschnitt 5.1.2.2, Seite 66).

Kapitel 6

Farbe

Farbeigenschaften tragen wesentlich zur Beschreibung und damit implizit zur Unterscheidung von Objekten bei. Die Charakterisierung dieser Eigenschaften ist das Thema dieses Kapitels. Einleitend wird kurz auf die mathematische Modellierung von Farben zu Bildverarbeitungszwecken eingegangen. Unter Farbeigenschaften eines Objekts werden hier die Farbvielfalt, die Homogenität der Farbverteilung innerhalb eines Objekts und die Bewertung, inwieweit sich Objektpixel in achsensymmetrischer Lage ähnlich sind (Farbsymmetrie), verstanden. Zu diesen drei Aufgabenstellungen werden Methoden vorgestellt, die diese Eigenschaften quantitativ charakterisieren.

6.1 Farbräume

Im menschlichen Auge sind zwei Arten von Rezeptoren zur Lichtwahrnehmung [Rad93] zu finden. Für das Helligkeitsempfinden bei geringer Beleuchtung (skotopisches Sehen) sind die Stäbchen verantwortlich. Da es nur eine Sorte Stäbchen gibt, ist eine Farbwahrnehmung bei annähernder Dunkelheit nicht möglich. Farben werden erst ab einer gewissen Helligkeit wahrgenommen (fotopisches Sehen). Die dafür zuständigen Rezeptoren sind die Zäpfchen. Auf der Retina sind drei verschiedene Sorten von Zäpfchen vorhanden, deren maximale Empfindlichkeiten bei unterschiedlichen Wellenlängen liegen. Es sind dies die Empfindlichkeiten für Rot, Grün und Blau. Auf der Grundlage der menschlichen Farbwahrnehmung basiert die trichromatische Theorie des Farbsehens. Demzufolge sind drei verschiedene Farbmaßzahlen zur Beschreibung von Farben notwendig. Verschiedene Farben lassen sich durch additive Mischung dreier Grundfarben (Primärvalenzen) darstellen. Faßt man diese verschiedenen Farbmaßzahlen als linear unabhängige Basisvektoren auf, so erhält man einen Vektorraum, den man in diesem Zusammenhang Farbraum nennt. Eine Farbe läßt sich also als Linearkombination der Primärvalenzen beschreiben. Es wurden, entsprechend der Vielfalt der Anforderungen der einzelnen Anwendungsgebiete, eine Vielzahl von Farbräumen entwickelt. Aus dieser Fülle werden zwei Farbräume kurz beschrieben. Diese haben in der digitalen Bildverarbeitung eine große Bedeutung erlangt und bieten verschiedene Zugänge zur quantitativen Beschreibung von Farben. Für eine umfassendere Darstellung von Farbräumen sei auf [Rad93] [WS82] [Haf99] verwiesen.

6.1.1 RGB-Farbraum

Seinen Ursprung hat dieser Farbraum vornehmlich in der technischen Erfassung von Farbe, Parallelen sind aber auch bei der menschlichen Farbwahrnehmung zu finden (siehe oben). Die drei Farbanteile *Rot*, *Grün* und *Blau* werden getrennt erfaßt. Durch additive Mischung lassen sich die meisten Farben darstellen. Im kartesischen Koordinatensystem hat dieser Farbraum die Form eines Würfels (vgl. Abbildung 6.1). Schwarz hat den Nullpunkt $(0,0,0)$ als Koordinate, weiß dagegen ist durch den Punkt $(255,255,255)$ bei der üblichen Beschreibung der einzelnen Farbkanäle durch acht Bit definiert. Auf der Diagonale zwischen diesen beiden Punkten (Unbuntgerade) liegen die Grautöne. Farben im eigentlichen Sinne ("bunte Farben") liegen abseits dieser Diagonalen. Bilder im RGB-Format sind in drei Ebenen angeordnet, wobei jede Ebene einer Primärvalenz zugeordnet ist. CCD-Kameras zum Beispiel generieren Bilder in diesem Format.

6.1.2 HLS-Farbraum

Dieser Farbraum ermöglicht eine Zerlegung von Farbeigenschaften in eher semantische Begriffe, die dem menschlichen Farbempfinden nahe kommen. Farbe wird hier durch die Größen Farbton (engl. *hue*), Helligkeit (*lightness*) und Sättigung (*saturation*) beschrieben (vgl. Abbildung 6.2). Die Helligkeit ist von den anderen Komponenten entkoppelt, während diese Eigenschaft im RGB-Raum in allen drei Ebenen enthalten ist. Der Farbton wird in Grad angegeben, ist also eine zyklische Größe. Der Farbe Rot ist der Wert 0° zugeteilt, Grün hat den Wert 120° und Blau 240° . Die beiden anderen Komponenten liegen im Intervall $[0, 1]$.




Abbildung 6.1: *RGB-Farbmolell* Punkte auf der Diagonalen von schwarz zu weiß (Unbuntergerade) sind Grautöne. Punkte abseits dieser Diagonalen sind Farben im eigentlichen Sinne. Alle im RGB-Raum darstellbaren Farben sind innerhalb dieses Würfels enthalten. (nach [GW92])

Vorschriften zur Farbraumtransformation aus der RGB-Darstellung und umgekehrt sind beispielsweise in [FvD82] zu finden.

6.2 Farbvielfalt

Ziel dieses Abschnitts ist die Quantifizierung der Vielfalt der in einem Objekt auftretenden Farben. Der Terminus *Farbvielfalt* soll nicht nur die Anzahl der in einem Objekt auftretenden Farben, sondern auch ihre relativen Häufigkeiten umfassen. So soll beispielsweise eine Farbe, die nur durch ein Objektpixel vertreten ist, einen sehr geringen Einfluß auf den Gesamtscore haben. Daher bietet sich ein Entropiemaß zur Quantifizierung der Farbvielfalt (genauer: Farbverteilungsentropie) an. Wie im vorherigen Abschnitt erläutert, wird eine Farbe im trichromatischen Modell durch drei Komponenten definiert. Im folgenden werden deshalb alle drei beschreibenden Elemente mit berücksichtigt. In manchen Anwendungen jedoch kann beispielsweise die Helligkeit geringe Bedeutung haben, ja sogar störend sein. Die Quantifizierung der Farbvielfalt mit weniger als drei Komponenten läßt sich analog formulieren.

Zur Berechnung der Farbverteilungsentropie muß die relative Häufigkeitsverteilung der auftretenden Farben berechnet werden. Die dazu notwendige Diskretisierung des Farbraums hat großen Einfluß auf die Granularität der Farberfassung. Eine starke Diskretisierung bewirkt eine Einteilung in wenige Farbklassen; mit zunehmender Verfeinerung werden mehr Farben unterschieden. Die Diskretisierung läßt sich auf dreierlei Weise bewerkstelligen:

Homogene Partition Jede Koordinatenachse wird in n Abschnitte gleicher Größe unterteilt. Bei unterschiedlichen Wertebereichen der Koordinatenachsen variiert die Intervallbreite von Achse zu Achse.




Abbildung 6.2: *HLS-Farbmodell* Rot ist durch den H -Wert 0° , Grün durch 120° beschrieben. Der Helligkeitswert L liegt auf der vertikalen, der Sättigungswert S auf der horizontalen Achse. (nach [LOPR97])

Inhomogene Partition Die Aufteilung der einzelnen Intervallachsen erfolgt in unterschiedlicher Granularität. Jede Achse i wird in n_i Intervalle partitioniert. Innerhalb der einzelnen Achsen können die einzelnen Intervalle dieselbe Größe haben. In diesem Fall werden den Achsen unterschiedliche Wertigkeiten zugeordnet. Grund hierfür kann beispielsweise die anwendungsspezifische Besonderheit des untersuchten Objekts sein. Weiterhin ist es möglich, daß die Aufnahmetechnik die Anwendung eines solchen Vorgehens nahe legt. So kann beispielsweise ein Aufnahmekanal eine geringere Auflösung aufweisen oder sehr verrauscht sein (mangelnde Zuverlässigkeit).

Adaptive Partition Diese Möglichkeit ist mit der inhomogenen Partition verwandt. Allerdings wird die Partitionierung durch ein adaptives Verfahren (z.B. *Clustering*) erzeugt. Vorteil dieser Methode ist ihr starker kontextueller Bezug: die Partitionierung ist sehr stark an das zu bearbeitende Problem angepaßt. Nachteilig ist hingegen der erhöhte Aufwand zur Bestimmung der Partitionen.

Anhand der verwendeten Partition wird die relative dreidimensionale Häufigkeitsverteilung p_{abc} berechnet. p_{abc} beschreibt dabei die relative Häufigkeit von Objektpixeln bei den diskretisierten Farbkoordinaten a , b und c . abc steht also für den verwendeten Farbraum (z.B. *hls* für den HLS-Farbraum). Daraus läßt sich die Entropie der Farbhäufigkeitsverteilung bestimmen:

$$C_V = - \sum_a \sum_b \sum_c p_{abc} \log(p_{abc}) \quad (\forall p_{abc} > 0) \quad (6.1)$$

Der Score C_V wächst monoton mit der Anzahl der Farben und der Homogenität der Farbhäufigkeitsverteilung.

6.3 Farbhomogenität

Neben der Quantifizierung der Farbvielfalt ist auch die Beurteilung der räumlichen Homogenität der Farbverteilung von Bedeutung. Anders formuliert ist die Frage zu beantworten, inwieweit unterscheidet sich die Farbvielfalt in verschiedenen lokalen Bereichen des Objekts von der globalen. Zur Lösung dieses Problems wird der in Abschnitt 3.2 (Seite 13) beschriebene Algorithmus verwendet. Er basiert auf einer gitterartigen Aufteilung des Objekts und der lokalen Beurteilung der Farbeigenschaft. Die einzelnen Gitterzellen G_i werden analog zu Gleichung 6.1 quantifiziert. Zur Bestimmung der lokalen Farbvielfalt in Gitterzelle G_i gilt also:

$$v_C^i = - \sum_a \sum_b \sum_c p_{abc}^i \log(p_{abc}^i) \quad p_{abc}^i > 0 \quad (6.2)$$

p_{abc}^i nimmt Bezug auf die relative Häufigkeit der entsprechenden Farbe im betrachteten Gitterelement. Analog zu Gleichung 3.7 (Seite 16) wird die Farbhomogenität definiert als:

$$C_H = \sqrt{\frac{1}{n-1} \sum_{i=1}^n w_i (\mu_C - v_C^i)^2} \quad (6.3)$$

Die Anzahl der betrachteten Gitterfenster wird durch n und der Mittelwert der v_C^i durch μ_C symbolisiert. Die Faktoren w_i gewichten die quadrierte Differenz zwischen dem Mittelwert μ_C und dem lokalen Score v_C^i mit dem Füllungsgrad der Gitterzelle G_i (Gleichung 3.5, Seite 15).




Abbildung 6.3: *Beispiel zur Quantifizierung der Farbhomogenität:* Im Ausgangsbild (links) werden sukzessiv zufällig ausgewählte Bildpixel vertauscht bis ein Durchmischungsgrad von 100% erreicht wird. Zu jedem der so entstandenen Bilder wird anschließend die Farbhomogenität gemessen (rechts).

Der Algorithmus soll an einem einfachen Beispiel (Abbildung 6.3, links) getestet werden. Das Testbild (256×256 Pixel) enthält 25 Quadrate (Kantenlänge 40 Pixel), die jeweils mit einer Farbe gefüllt sind. Das Bild ist also stark strukturiert und sehr inhomogen. Diese Inhomogenität wird durch folgendes Vorgehen schrittweise verringert. Zu einem bestimmten

Prozentsatz (von 0% bis 10% in Zweierschritten, von 10% bis 100% in Zehnerschritten) werden Pixel zufällig ausgewählt und mit ebenfalls durch einen Zufallsalgorithmus bestimmte Pixel vertauscht. Damit erhöht sich bei jeder Durchmischung der Grad an globaler Homogenität. Als Farbraum wird das RGB-Modell verwendet und die Gitterkonstanten wurden mit $g_x = g_y = 80$ festgelegt. Nach jedem Schritt wird die Farbhomogenität C_H und die Farbvielfalt C_V gemessen. Die Quantifizierungen der Farbhomogenität sind im rechten Teil der Abbildung 6.3 zu sehen. Das Bild im Originalzustand weist, wie zu erwarten, den höchsten Score auf. Mit jeder Steigerung des Durchmischungsgrads und der damit verbundenen Erhöhung der Farbhomogenität fällt der Wert von C_H . Dieser Effekt ist schon bei einer Durchmischungsrate von 2% zu erkennen. Den Minimalwert nimmt dieser Score bei dem Bild an, bei dem jedes Pixel einmal vertauscht worden ist. Nachdem nur die Position der Farbpixel, aber nicht deren Werte verändert werden, liegt der Wert der Farbvielfalt C_V konstant bei 0.191.

6.4 Farbsymmetrie

Ein weiteres Element der Farbeigenschaften eines Objekts ist durch die Charakterisierung der Farbsymmetrie gegeben. Beurteilt werden soll, inwieweit Objektpixel in achsensymmetrischer Lage ähnliche Farbwerte aufweisen. Die algorithmische Formulierung umfaßt demnach zwei Aufgaben. Im ersten Schritt werden die Symmetrieachsen des Objekts bestimmt, während im zweiten die Farbwerte von Pixeln in achsensymmetrischer Lage verglichen werden.

Zur Lösung der ersten Teilaufgabe müssen diejenigen Objektpixel bestimmt werden, zu denen ein achsensymmetrisches Pendant existiert. Dies wird nach dem in Abschnitt 3.3.1 (Seite 16) beschriebenen Verfahren durchgeführt. Bezüglich der zwei Objektsymmetrieachsen g_1 und g_2 werden diejenigen Objektpixel p betrachtet, zu denen ein Objektpixel p' in achsensymmetrischer Lage existiert. Die Menge dieser Punkte sei mit \mathcal{P}^i ($i = 1, 2$) bezeichnet. Zum Vergleich der Farbwerte von Pixeln in achsensymmetrischer Lage wird für jedes dieser Punktepaare der Farbabstand im gewählten Farbraum berechnet (hier als Beispiel der HLS-Farbraum):

$$d(p) = \sqrt{(w_h \min(\{|h_p - h_{p'}|, 360 - |h_p - h_{p'}|\}))^2 + (w_l(l_p - l_{p'}))^2 + (w_s(s_p - s_{p'}))^2} \quad (6.4)$$

Dabei bezeichnet h_p den *hue*-Wert des Pixels p , l_p den *lightness*-Wert und s_p den *saturation*-Wert. Durch die Gewichte (w_h, w_l, w_s) kann einerseits der Einfluß der Farb-Koordinatenachsen gesteuert und andererseits die unterschiedlichen Größenskalen ausgeglichen werden. Für beide Symmetrieachsen g_1 und g_2 wird der Mittelwert der nach Gleichung 6.4 bestimmten Farbdifferenzen bestimmt:

$$C_S^i = \frac{1}{|\mathcal{P}^i|} \sum_{p \in \mathcal{P}^i} d(p) \quad (i = 1, 2) \quad (6.5)$$

Der Gesamtscore ist nun das Maximum der beiden Werte:

$$C_S = \max(\{C_S^1, C_S^2\}) \quad (6.6)$$

Kapitel 7

Klassifikation

Die Klassifikation eines Objekts basiert auf seinen Merkmalscharakterisierungen, die in dieser Arbeit quantitativ vorliegen. Wünschenswert ist eine Klassifikation unter Verwendung möglichst weniger Merkmale bei Minimierung der Fehlklassifikationen. In diesem Kapitel werden zunächst vier oft verwendete Klassifikationsverfahren kurz beschrieben und ihre Eignung für den Einsatz in einem nachvollziehbaren Bildanalysesystem diskutiert. Der letzte Abschnitt dieses Kapitels beschreibt Verfahren zur Merkmalsauswahl. Zunächst wird die damit verbundene Merkmalsreduktion motiviert und anschließend werden zwei Verfahren vorgeschlagen, wie diese Auswahl vonstatten gehen kann und wann welche Methode zum Einsatz kommen sollte.

7.1 Allgemeines

Nach der Objektbeschreibung durch eine quantitative Merkmalscharakterisierung ist meist eine Zuordnung des untersuchten Objekts zu einer bestimmten Klasse gefordert. Diese Abbildung von Objektmerkmalen auf eine Klasse wird Klassifikation genannt. Auf Grund sowohl theoretischer und praktischer Betrachtungen als auch im Hinblick auf die Nachvollziehbarkeit des Analysesystems ist eine geringe Merkmalsanzahl für die Klassifikation erstrebenswert. Dieses Thema wird in Abschnitt 7.3 behandelt. In dieser Arbeit werden nur überwachte Klassifikationsverfahren berücksichtigt. Dies bedeutet, daß eine Menge von Objekten mit bekannter Klassenzugehörigkeit vorhanden ist. Aus dieser Trainingsmenge werden Regeln (impliziter oder expliziter Art) gewonnen, mit denen bisher unbekannte Objekte möglichst korrekt klassifiziert werden können.

In einem nachvollziehbaren quantitativen Bildanalysesystem sollte auch die Klassifikation transparent sein. Dies bedeutet, daß dem Benutzer deutlich gemacht werden kann, weshalb das System zu der konkreten Klassifikation gelangt ist. In Abschnitt 7.2 werden exemplarisch vier häufig verwendete Klassifikationsverfahren beschrieben (lineare Diskriminanzanalyse, neuronale Netze, Nearest-Neighbor-Verfahren, Entscheidungsbäume). Für jede Methode wird dargestellt, inwieweit sie eine Nachvollziehbarkeit des Ergebnisses erlaubt. Auf diese Weise soll aufgezeigt werden, anhand welcher Kriterien ein Klassifikationsverfahren in diesem Sinne bewertet werden kann.

Im folgenden wird die Anzahl der Merkmalsvektoren der Klasse c_i mit n_i bezeichnet. Der j te Merkmalsvektor der Klasse c_i wird durch d Merkmale charakterisiert: $\vec{x}_{ij} = (x_{ij}^1, x_{ij}^2, \dots, x_{ij}^d)$.

7.2 Klassifikatoren

7.2.1 Lineare Diskriminanzanalyse

In diesem Abschnitt wird im Hinblick auf die Anwendung in Kapitel 8 von einem Zwei-Klassen-Problem ausgegangen. Das heißt, ein bisher unbekannter Merkmalsvektor kann nur einer von zwei möglichen Klassen angehören. Zur Zuordnung eines Objekts \vec{x} mit unbekannter Klassenzugehörigkeit zu einer der beiden Klassen wird bei der linearen Diskriminanzanalyse [Hoe71] [Han97] ein Indikator z durch eine Linearkombination der Merkmale x^i bestimmt:

$$z = \lambda_1 x^1 + \lambda_2 x^2 + \dots + \lambda_d x^d \quad (7.1)$$

Dies entspricht in der geometrischen Interpretation der Bildung einer Hyperebene im d -dimensionalen Raum. Die in Gleichung 7.1 dargestellte Abbildung der Merkmale auf einen Indikator wird auch als lineare Diskriminanzfunktion bezeichnet und soll mit $lda(\vec{x})$ symbolisiert werden. Anhand des abgeleiteten Indikators z wird durch einen Schwellwert entschieden, welcher Klasse der Merkmalsvektor \vec{x} zugeteilt wird. Die Bestimmung der Koeffizienten λ_i wird von zwei Zielen geleitet. Zum einen soll der Indikator z die beiden Klassen deutlich separieren. Diese Eigenschaft wird durch den quadrierten Abstand der Indikator-Mittelwerte für die beiden Klassen $(\bar{z}_1 - \bar{z}_2)^2$ ausgedrückt. Zum anderen soll die Variation der Indikatorwerte innerhalb der Klassen $\sum_{i=1}^2 \sum_{j=1}^{n_i} (z_{ij} - \bar{z}_i)^2$ gering sein (z_{ij} bezeichnet dabei den Indikator

zum j ten Merkmalsvektor der Klasse i). Insgesamt soll also folgender Ausdruck maximiert werden:

$$G = \frac{(\bar{z}_1 - \bar{z}_2)^2}{\sum_{i=1}^2 \sum_{j=1}^{n_i} (z_{ij} - \bar{z}_i)^2} \quad (7.2)$$

Aus dieser Gleichung läßt sich eine Lösung des Problems ableiten (für Details siehe [Hoe71]). Zur Formulierung des Ergebnisses werden zwei Hilfsgrößen verwendet. Mit S_{pq} wird folgender Term bezeichnet, wobei x_{ij}^p das p te Merkmal des j ten Vektors der Klasse i symbolisiert:

$$S_{pq} = \sum_{i=1}^2 \sum_{j=1}^{n_i} (x_{ij}^p - \bar{x}_i^p)(x_{ij}^q - \bar{x}_i^q) \quad (7.3)$$

Weiterhin wird mit d_p der Abstand der Mittelpunkte der beiden Klassen bezüglich Merkmal p symbolisiert:

$$d_p = \bar{x}_1^p - \bar{x}_2^p \quad (7.4)$$

Mit diesen beiden Hilfsgrößen kann folgendes lineares Gleichungssystem aufgestellt werden:

$$\lambda_1 S_{r1} + \lambda_2 S_{r2} + \dots + \lambda_d S_{rd} = k d_r \quad r = 1, \dots, d \quad (7.5)$$

Durch den Faktor k in der obigen Gleichung ist die Lösung des Problems nicht eindeutig bestimmt. Da aber eine Multiplikation des abzuleitenden Indikators z mit einer Konstante die Ordnung innerhalb der Indikatoren bezüglich des Datensatzes nicht verändern würde, wird üblicherweise $k = 1$ gesetzt. Dieses lineare Gleichungssystem kann beispielsweise mit dem Gaußschen Eliminationsverfahren [Sto89] gelöst werden. Die Zuordnung eines Merkmalsvektors zu einer Klasse c_i erfolgt durch Vergleich des Indikatorwertes z mit einem Schwellwert t_z :

$$\text{class}(\vec{x}) = \begin{cases} c_1 & \text{falls } z = \text{lda}(\vec{x}) > t_z \\ c_2 & \text{sonst} \end{cases} \quad (7.6)$$

Dieses Klassifikationsverfahren eignet sich zum Einsatz im Umfeld einer nachvollziehbaren quantitativen Bildanalyse. Nachdem die Werte für die Quantifizierungen der einzelnen Merkmale für den Benutzer verständlich sind, werden diesen Merkmalen gewissermaßen Gewichte zugewiesen. Voraussetzung für eine unmittelbare Interpretierbarkeit dieser Gewichte ist allerdings eine Normierung der Wertebereiche der einzelnen Scores. Ist eine solche Normierung vorhanden, so geben die Gewichte Auskunft über die Bedeutung der einzelnen Merkmale hinsichtlich des Klassifikationsproblems. Diese Eigenschaft unterstützt die Nachvollziehbarkeit des Analysesystems. Auch die Zuordnung des Objekts zu einer Klasse durch Vergleich der gewichteten Summe der Einzelscores mit einem Schwellwert ist wegen seiner Einfachheit diesem Ziel dienlich.

7.2.2 Neuronale Netze

Neuronale Netze wurden bereits in Abschnitt 4.4.5 (Seite 47) kurz beleuchtet. Eine ausführlichere Darstellung dieses umfangreichen Themenbereichs findet sich in [Roj93] [Bra97]. An dieser Stelle soll nur auf die Eignung neuronaler Netze für die Klassifikation im Umfeld der nachvollziehbaren quantitativen Bildanalyse eingegangen werden.

Da das ‐Wissen‐ eines neuronalen Netzes in seiner Topologie und seinen freien Parametern (Gewichte, Schwellwerte) kodiert ist, l sst sich bei mehrschichtigen Netzen von au en nur mit M he und nach eingehender Analyse verstehen, weshalb das Netz zu dem konkreten Ergebnis gelangt ist. Daher erscheinen neuronale Netze als wenig geeignet, in einem nachvollziehbaren Analysesystem Anwendung zu finden. Einschr nkend sei aber darauf hingewiesen, da  bei den Verfahren der quantitativen Merkmalscharakterisierung neuronale Techniken durchaus eingesetzt werden k nnen. Es ist dabei im Einzelfall zu pr fen, ob der Einsatz den Zielen der Nachvollziehbarkeit abtr glich ist.

7.2.3 Nearest-Neighbor-Algorithmen

Der k -Nearest-Neighbor-Klassifikator ist ein sogenannter *lazy learning* Algorithmus [WAM97]. Das Verfahren speichert die Trainingsmenge und wertet sie erst zum Klassifikationszeitpunkt aus. Das Grundprinzip besteht darin, da  zu einem Merkmalsvektor \vec{x} unbekannter Klassenzugeh rigkeit aus einer Trainingsmenge die k n chsten (und damit  hnlichsten) Nachbarn bezuglich eines Distanzma es bestimmt werden. Die Klasse von \vec{x} wird aus der Klassenzugeh rigkeit dieser Nachbarn und aus deren Abst nde zu \vec{x} berechnet. Zun chst m ssen also die Abst nde zwischen \vec{x} und den Trainingsmustern \vec{x}_i bestimmt werden:

$$d(\vec{x}, \vec{x}_i) = \left(\sum_{l=1}^d w_l \cdot |x^l - x_i^l|^p \right)^{1/p} \quad (7.7)$$

Im Allgemeinen wird die Euklidische Norm verwendet ($p = 2$). Die Faktoren w_l erlauben eine unterschiedliche Gewichtung der Koordinatenachsen. Mit der sogenannten *Kernel-Funktion* wird die N he eines Vektors \vec{x}_i zu dem zu klassifizierenden Muster \vec{x} bewertet. Je geringer der Abstand zu \vec{x} ist, desto  hnlicher sind sich die Muster:

$$K(d(\vec{x}, \vec{x}_i)) = \frac{1}{d(\vec{x}, \vec{x}_i)} \quad (\vec{x} \neq \vec{x}_i) \quad (7.8)$$

Anschließend werden in der Menge $K_{\vec{x}}$ die k Merkmalsmuster zusammengefa t, die die geringsten Abst nde zu \vec{x} aufweisen (*n chste Nachbarn*). Anhand dieser Menge und den bekannten Klassenzugeh rigkeiten wird \vec{x} klassifiziert. Dazu bezeichne im folgenden $class(\vec{x}_i)$ die Klasse von Vektor \vec{x}_i aus der Trainingsmenge. Ben tigt wird weiterhin die $1(\cdot)$ -Funktion, die den Wert 1 hat, falls ihr Argument wahr ist, ansonsten liefert sie 0. Mit diesen Hilfsgr en werden die Klassenzugeh rigkeitswahrscheinlichkeiten berechnet:

$$p(c_j|\vec{x}) = \frac{\sum_{\vec{x}_i \in K_{\vec{x}}} 1(class(\vec{x}_i) = c_j) \cdot K(d(\vec{x}, \vec{x}_i))}{\sum_{\vec{x}_i \in K_{\vec{x}}} K(d(\vec{x}, \vec{x}_i))} \quad (7.9)$$

Schlie lich wird \vec{x} der Klasse zugeordnet, f r die $p(c_j|\vec{x})$ maximal ist:

$$\text{k-NN}(\vec{x}) = \max_{c_j} p(c_j|\vec{x}) \quad (7.10)$$

Das Nearest-Neighbor-Klassifikationsverfahren eignet sich sehr gut f r den Einsatz im Rahmen der nachvollziehbaren quantitativen Bildanalyse. Eine besondere Eigenschaft dieser Methode ist, da  inh rent Vergleichsf lle zusammen mit einem  hnlichkeitsma  bestimmt werden. Diese lassen sich dem Benutzer darstellen, um das Klassifikationsergebnis transparent

zu begründen. Problematisch sind jedoch “Ausreißer” im Merkmalsraum. Bei diesen sind die nächstgelegenen Punkte im Merkmalsraum relativ weit entfernt. Die dabei herangezogenen Vergleichsfälle sind im Allgemeinen wenig aussagekräftig. Diesem Problem läßt sich allerdings mit einer Überprüfung der berechneten Abstände der Merkmalsvektoren in $K_{\vec{x}}$ und einer entsprechenden Warnung begegnen. Einschränkend seien noch zwei Hinweise erwähnt. Problematisch sind Klassifikationsprobleme, bei denen die einzelnen Klassen verschieden stark vertreten sind. Weiterhin ist das Verfahren als ineffizient zu betrachten, wenn sehr viele Trainingsdaten vorliegen und sie bei jeder Klassifikation mit dem Eingabevektor verglichen werden müssen.

7.2.4 Entscheidungsbäume

Ein hierarchisches Vorgehen im Klassifikationsprozeß findet bei Entscheidungsbäumen Anwendung. Dazu wird in der Trainingsphase ein Baum konstruiert, mit dessen Hilfe ein bisher unbekanntes Merkmalsmuster klassifiziert wird. An jedem Knoten des Baumes wird, beginnend an seiner Wurzel, eine Fallunterscheidung in Abhängigkeit eines Merkmals oder einer Merkmalskombination, getroffen. Dieser Prozeß wird fortgeführt, bis ein Blatt des Baumes erreicht ist. In den Blättern des Baumes ist die jeweilige Klasseninformation enthalten, die für Merkmalsvektoren in dem zu ihm führenden Pfad gilt. Für den Aufbau des Baumes wurde eine Vielzahl von Verfahren und Strategien entwickelt. Als Beispiele seien ID3 [Qui90] und CART [BJFS84] genannt.

Entscheidungsbäume eignen sich ebenfalls für den Einsatz im Bereich der nachvollziehbaren quantitativen Bildanalyse, da sich der Entscheidungspfad im Allgemeinen gut darstellen und sogar sprachlich ausdrücken läßt (im Sinne von “*Da die Bewertung von Merkmal A größer ist als Wert X und Merkmal B kleiner ist als Y und ... wird das Objekt der Klasse M zugeordnet.*”). Einschränkend sei aber angemerkt, daß diese Darstellbarkeit nur bis zu einer gewissen Komplexität des Baumes gilt. Für komplizierte Entscheidungen an den Knoten oder ab einer gewissen Baumhöhe kann der Entscheidungsprozeß nicht mehr übersichtlich dargestellt werden.

7.3 Merkmalsauswahl

Bei Klassifikationsproblemen ist in der Regel vorab nicht bekannt, welche Merkmale für eine verlässliche Klassenzuordnung relevant sind. Daher wird meist eine große Menge an Merkmalen quantifiziert. Es ist allerdings wünschenswert, eine möglichst kleine Merkmalsmenge für die Klassifikation zu verwenden. Diese Reduktion der Merkmalsmenge hat sowohl theoretische als auch praktische Gründe.

Um die Parameter eines Klassifikators optimal zu bestimmen, muß der Merkmalsraum (d.h. der Raum, der mit den einzelnen Merkmalen als Koordinatenachsen aufgespannt wird) ausreichend dicht mit Mustern bekannter Klassenzugehörigkeit belegt sein. Auf die Belegung dieses Merkmalsraums bezieht sich das Phänomen des *curse of dimensionality* [Bel61]. Die notwendige Menge vorklassifizierter Muster für eine ausreichende Belegung des Merkmalsraums wächst exponentiell mit der Dimensionalität der Merkmalsvektoren: Unterteilt man die einzelnen Achsen des d -dimensionalen Merkmalsraums in k Intervalle und setzt man die

so entstandenen Zellen im Merkmalsraum mit notwendigen Merkmalsmustern gleich, so trägt die Anzahl an Merkmalsmuster k^d . Größere Mengen an Trainingsmuster sind jedoch meist nicht vorhanden (insbesondere im medizinischen Bereich). Neben der Verfügbarkeit an vorklassifizierten Daten hat diese Beschränkung ihre Ursache im notwendigen Zeit- und Kostenaufwand.

Im Zusammenhang mit nachvollziehbarer quantitativer Bildanalyse stützt auch eine empirische Erkenntnis die Forderung nach einer Reduktion der Merkmalsmenge. Miller [Mil56] hat in Versuchen beobachtet, daß es auch erfahrenen Ärzten nicht möglich ist, eine systematische Antwort auf ein Klassifikationsproblem zu geben, dessen Merkmalsvektoren aus mehr als sieben (± 2) Komponenten bestehen (sog. *Millers magische Zahl*). Das bedeutet, daß es dem Menschen Schwierigkeiten bereitet, ein Problem adäquat zu behandeln, das aus mehr als sieben Variablen besteht. Ist die Nachvollziehbarkeit ein wesentlicher Bestandteil des Bildanalyse-Systems, so ist es erstrebenswert, für die Klassifikation nicht mehr Merkmale zu verwenden.

Scherf et al. [SB97b] weisen darauf hin, daß eine Merkmalsauswahl unter Berücksichtigung der Ergebnisse des verwendeten Klassifikators zu guten Resultaten führt. Ein solches Verfahren wird auch *wrapper*-Ansatz genannt. Dazu kann man die Klassifikationsgenauigkeit aller möglichen Merkmalskombinationen abschätzen (exhaustive Suche). Dies ist allerdings, in Abhängigkeit vom verwendeten Klassifikator, nur bis zu einer bestimmten Merkmalsanzahl praktikabel, da für q Merkmale $2^q - 1$ Merkmalskombinationen untersucht werden müssen. Deshalb schlagen die Autoren ein zweistufiges Vorgehen (vgl. Abbildung 7.1) vor. In einem ersten Schritt wird mit Hilfe einer Bewertungsfunktion und einer Suchstrategie eine Vorauswahl von Merkmalen getroffen. Das Verfahren, die Merkmalsauswahl unabhängig vom Klassifikator durchzuführen, wird auch als *filter*-Ansatz bezeichnet. Basierend auf dieser Auswahl wird die zu verwendende Merkmalskombination durch exhaustive Suche unter Berücksichtigung der Klassifikationsgenauigkeit bestimmt. Eine solche Vorauswahl kann mit dem EUBAFES-Ansatz [Sch98] [SB97b] vorgenommen werden. Die Grundlage dieses Verfahrens ist die Minimierung der Abstände von Merkmalsvektoren derselben Klasse bei gleichzeitiger Maximierung der Abstände von Merkmalsvektoren unterschiedlicher Klassenzugehörigkeit. Dazu werden den Merkmalen Gewichte zugewiesen, die deren Bedeutung reflektieren. Die Gewichte werden durch Minimierung einer Energiefunktion mittels Gradientenabstieg bestimmt. Anhand der so gewonnenen Gewichte kann eine Vorauswahl der Merkmale vorgenommen werden.

Zusammenfassend wird ein Vorgehen zur Reduktion der Merkmalsmenge vorgeschlagen, das sich nach der Anzahl der anfänglich vorhandenen Merkmale und nach dem verwendeten Klassifikator richtet:

- Ist die Anzahl der Merkmale klein genug, auch bezüglich der Komplexität des Klassifikators, so sollte eine exhaustive Suche vorgenommen werden.
- Andernfalls wird zunächst die Merkmalsanzahl mittels EUBAFES auf ein handhabbares Maß reduziert. Anschließend bietet sich zur weiteren Reduktion die exhaustive Suche an (Abbildung 7.1). Dadurch vereint man die Vorteile des *filter*- und *wrapper*-Ansatzes.

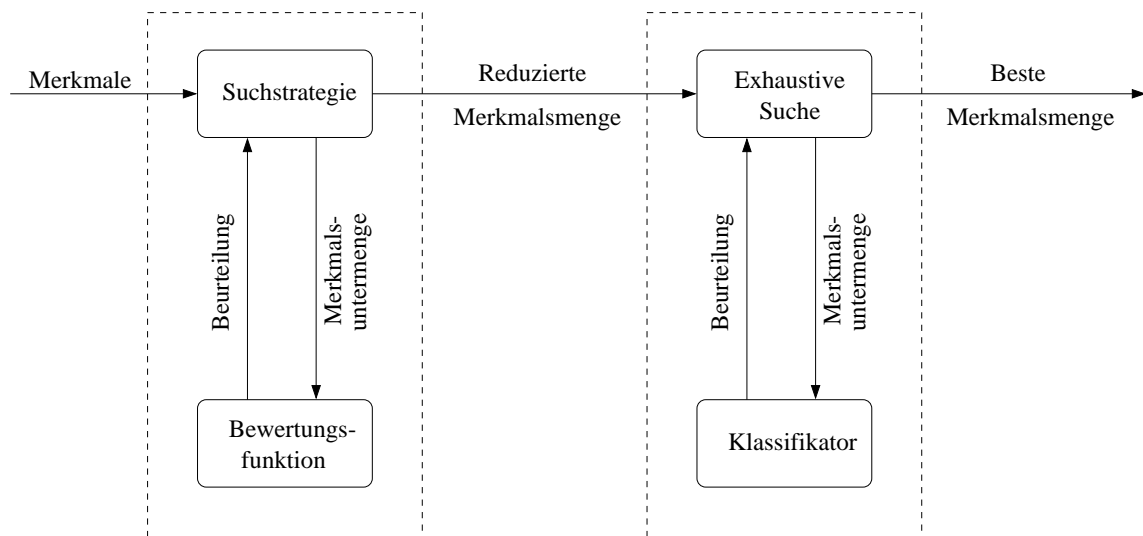


Abbildung 7.1: Zweistufiges Vorgehen zur Merkmalsauswahl (nach [SB97b]): Zunächst wird eine Vorauswahl mittels einer Suchstrategie und einer Bewertungsfunktion bestimmt. Durch exhaustive Suche unter Verwendung der Klassifikationsgenauigkeit wird aus dieser reduzierten Merkmalsmenge die beste Merkmalskombination bestimmt.

Kapitel 8

Anwendung: Früherkennung des malignen Melanoms

Schwerpunkt dieses Kapitels ist die Anwendung der nachvollziehbaren quantitativen Bildanalyse auf die Problematik der Früherkennung des malignen Melanoms. Zunächst wird die Problematik und ihre Relevanz beschrieben sowie der Einsatz eines nachvollziehbaren quantitativen Bildanalyse-Systems motiviert. Der einleitende Teil schließt mit einem Überblick über bisherige Ansätze. Die Beschreibung der Ergebnisse folgt dem in Kapitel 2 dargestellten Schema von der Bildakquisition bis zur Klassifikation. Besonderes Augenmerk gilt der Darstellung der Ergebnisse der Quantifikationen und Visualisierungen, die auf den in den Kapiteln 3 bis 6 vorgestellten Verfahren basieren. Im letzten Abschnitt wird die diagnostische Genauigkeit des abgeleiteten Klassifikators abgeschätzt.

8.1 Überblick: Pigmentierte Hautveränderungen

Das maligne Melanom der Haut hat in den letzten Jahren große Beachtung gefunden, forciert auch durch die Aufklärungsbemühungen der Dermatologen. Hintergrund ist die starke Zunahme im Auftreten dieses aggressiven bösartigen Tumors. Das maligne Melanom wird der allgemeineren Klasse der pigmentierten Hautveränderungen zugeordnet. Pigmentierte Hautveränderungen zerfallen in zwei Gruppen [SBFBL93]: die melanozytären und die nicht-melanozytären Hautveränderungen. Beim malignen Melanom handelt es sich um eine bösartige melanozytäre Hautveränderung und muß von gutartigen melanozytären Hautveränderungen unterschieden werden. Gegenstand der Betrachtungen dieses Kapitels ist die Differenzierung zwischen benignen und malignen melanozytären Hautveränderungen durch nachvollziehbare quantitative Bildanalyse.

8.2 Das maligne Melanom

Das maligne Melanom, auch bekannt als "schwarzer Hautkrebs", ist die gefährlichste Hautkrankheit beim Menschen. Es handelt sich um eine bösartige Geschwulst der Haut (bzw. der Schleimhäute), die ihren Ausgang von den pigmentbildenden Zellen (Melanozyten) nimmt ([Zin90],[Bos87]). Die besondere Gefährlichkeit dieses Tumors liegt in seinem Wachstumsverhalten und seiner anatomischen Lage begründet. Nach einem üblicherweise anfänglichen horizontalen Wachstum beginnt sich der Tumor vertikal in die tieferen Dermis-schichten auszubreiten. Die dort vorhandenen Blut- und Lymphgefäße bieten die Voraussetzung zum Abtransport von Tumorzellen und damit zur rasch einsetzenden Metastasierung [CHKA92].

Obwohl das maligne Melanom nur 10% der Hautkrebsfälle in den USA ausmacht, ist es doch für 75% der Hautkrebstoten verantwortlich ([SSA⁺93a],[LB96]). Seine Inzidenz (Neuerkrankungsrate) in den USA hat sich gegenüber den Dreißiger Jahren dieses Jahrhunderts mehr als verfünffach [SM92]. Die Entwicklung in Deutschland weist eine Verdopplung der Inzidenz innerhalb der letzten zehn Jahre [PK94] bei einer geschätzten jährlichen Zuwachsrate von 5-10% [SSA⁺93a] auf. Als Ursachen für diesen scharfen Anstieg werden unter anderen das höhere Durchschnittsalter der Bevölkerung, der verbesserte Lebensstil mit veränderten sozialen Gewohnheiten und Umwelteinflüsse verantwortlich gemacht. Wesentlich scheint die erhöhte Sonnenexposition der Haut zu sein [KS92].

Als therapeutische Maßnahme wird üblicherweise die chirurgische Exzision (Entfernung) des betroffenen Hautareals mit einem definierten Sicherheitsabstands angesetzt. Die Prognose korreliert stark mit dem Zeitpunkt der Diagnosestellung. In frühen Stadien (Eindringtiefe bis 0.76 mm) beträgt die Zehnjahres-Überlebensrate 96%, ab 3 mm nur 50% [BMR⁺89]. Entscheidend für das Überleben des Patienten ist also die möglichst frühzeitige Diagnose.

8.3 Diagnostik: Dermatoskopie

Die ausgeprägte Neigung zur Metastasierung und die epidemiologische Beschreibung des malignen Melanoms weisen deutlich auf die hohe Bedeutung der Früherkennung hin. In der klinischen Diagnostik wurde bis vor wenigen Jahren die dermatologische ABCD-Regel ver-

wendet. Diese beurteilt die vier Merkmale Asymmetrie, Begrenzung, Farben und Durchmesser der Hautveränderung (Läsion) durch optische Inspektion ohne weitere technische Hilfsmittel (der Name der Regel leitet sich aus den Anfangsbuchstaben der englischen Bezeichnung der Merkmale ab). Mehrere Untersuchungen haben nachgewiesen, daß die diagnostische Treffsicherheit bei Dermatologen mit großer klinischer Erfahrung bei initialen Melanomen nur 75% beträgt [SBFBL93]. Für Ärzte anderer Fachrichtungen liegt sie deutlich niedriger.

In den letzten Jahren hat sich die Dermatoskopie in der klinischen Diagnostik als Standardmittel etabliert. Dieser Begriff umfaßt die Technik der Auflichtmikroskopie bei 10facher Vergrößerung unter Verwendung einer Flüssigkeit. Mit dem Dermatoskop (das Gerät ähnelt einer Handlupe mit spezieller Beleuchtungseinrichtung) erfolgt die Befundung durch visuelle Inspektion. Durch die Verwendung der Kontaktflüssigkeit (z.B. Olivenöl, Desinfektionsspray) wird der Unterschied des Brechungsindex zwischen Glasplatte des Dermatoskops und Hornschicht deutlich reduziert [SBFBL93]. Damit werden tiefer liegende Strukturen sichtbar und die Läsion in ihrer farblichen und strukturellen Zusammensetzung besser erfaßt. Dem Dermatologen wird dadurch eine Fülle Informationen zugänglich gemacht, zu deren zielgerechten Auswertung die dermatoskopische ABCD-Regel ([SRC⁺94],[SBFBL93]) entwickelt wurde.

Die dermatoskopische ABCD-Regel beurteilt semi-quantitativ vier Merkmale:

Asymmetrie Die Hautveränderung wird mit Hilfe zweier orthogonaler imaginärer Linien aufgeteilt. Anhand dieser Linien wird festgehalten, ob signifikante Asymmetrie an keiner, einer oder zwei Achsen vorliegt. Asymmetrie wird durch Geometrie, Farben und Strukturmerkmale der Läsion beschrieben. Die Hilfslinien werden so gewählt, daß sich ein möglichst geringer Asymmetriewert ergibt.

Begrenzung Mit diesem Merkmal wird beurteilt, inwieweit der Abbruch des Pigmentmusters zur umliegenden Haut abrupt erfolgt. Dazu wird der sichtbare Hautausschnitt ausgehend vom Mittelpunkt der Läsion in acht gleichgroße Segmente eingeteilt. Für jedes Segment mit einem markanten Übergang zur Haut wird ein Punkt vergeben.

Farbtöne Aus einer vorbestimmten Menge von typischen Farben (weiß, rot, hellbraun, dunkelbraun, blaugrau und schwarz) wird die Anzahl der vorhandenen Farben bestimmt.

Differentialstruktur Unter Differentialstrukturen versteht man die in melanozytären Hautveränderungen beobachtbaren strukturellen Komponenten: strukturlose Areale, Netzwerke, Streifen, Schollen und Punkte. Beurteilt wird die Anzahl der identifizierten Strukturformen. Bei manchen Strukturen muß eine Mindestanzahl erkennbar sein (z.B. bei Punkten mindestens 3).

Die einzelnen Merkmale werden mittels gewichteter Summation zum sogenannten Dermatoskopie-Punktwert (DPW) zusammengefaßt, der als Risikoindikator für Malignität zu verstehen ist:

$$DPW = 1.3 \cdot A + 0.1 \cdot B + 0.5 \cdot C + 0.5 \cdot D \quad (8.1)$$

Tabelle 8.1 faßt die Merkmale, ihren Wertebereich, ihre Gewichte und ihren minimalen sowie maximalen Beitrag zum DPW zusammen. Ersichtlich wird daraus auch der minimal mögliche DPW von 1.0 und der maximal mögliche DPW von 8.9. Zur Diagnosefindung wird

Merkmal	Wertebereich	Gewicht	Min	Max
Asymmetrie	0-2	1.3	0	2.6
Begrenzung	0-8	0.1	0	0.8
Color (Farbtöne)	1-6	0.5	0.5	3.0
Differentialstrukturen	1-5	0.5	0.5	2.5
Summe			1	8.9

Tabelle 8.1: Die Merkmale der dermatoskopischen ABCD-Regel: Jedes Merkmal wird entsprechend seiner Ausprägung innerhalb eines vordefinierten Wertebereichs beurteilt und mit einem Gewicht bewertet. Die beiden letzten Spalten in der Tabelle zeigen den minimalen und maximalen Beitrag des Merkmals zum Gesamtscore.

dieser Wertebereich in drei Intervalle aufgeteilt:

$$\begin{array}{llll}
 1.0 \leq DPW < 4.8 & \text{unauffällige Hautveränderung} \\
 4.8 \leq DPW < 5.5 & \text{suspekte Hautveränderung} \\
 5.5 \leq DPW \leq 8.9 & \text{mit hoher Wahrscheinlichkeit Melanom}
 \end{array}$$

Studien belegen, daß mit dieser Diagnosetechnik eine Steigerung der diagnostischen Genauigkeit um 15% auf 90% erreicht wird [SPB+98]. Allerdings kann die Anwendung durch dermatoskopische Laien sogar zu einer Verschlechterung der Erkennungsraten führen [KEP97]. Andere Untersuchungen kommen zu einem ähnlichen Ergebnis [RMS+97].

Diese Zahlen verdeutlichen den Nutzen, aber auch die Problematik der Dermatoskopie:

- Die einzelnen Merkmale sind zwar objektiv definiert, erfordern allerdings zu ihrer korrekten Auswertung ein umfangreiches Expertenwissen und entsprechende Erfahrung. Diese ist gerade für nicht-spezialisierte Dermatologen schwierig zu erwerben, da sie in ihrer Praxis üblicherweise nur selten mit einem malignen Melanom konfrontiert werden. Zu dieser Problematik gesellen sich die intra- und interindividuellen Schwankungen der Bewertungen.
- Die Beurteilung der Merkmale erfolgt semiquantitativ. Feinere Abstufungen sind nicht möglich und damit kann die Läsion nur ungenau charakterisiert werden.

Aus diesen Gründen erscheint ein computergestütztes System zur Analyse von melanozytären Hautveränderungen geeignet, die Früherkennung des malignen Melanoms zu verbessern. Die Verantwortung für die Diagnose und Behandlung des Patienten soll inhärent beim Dermatologen verbleiben; der Arzt soll also durch Methoden der Bildverarbeitung lediglich in der Diagnosefindung unterstützt werden (computergestützte *second opinion* [Hor97]). Notwendige Nebenbedingung ist jedoch, daß der Dermatologe mehr als einen Diagnosevorschlag erhält. Gerade in einem Fachbereich, in dem visuelle Information eine bestimmende Rolle spielt, ist die Nachvollziehbarkeit des Diagnosevorschlags für seine Nützlichkeit von entscheidender Bedeutung. Diese Problemstellung eignet sich also prototypisch für ein nachvollziehbares quantitatives Bildanalysesystem.

Die in den Kapiteln 3 bis 6 dargestellten Methoden werden auf dieses Problem angewandt mit dem Ziel einer quantitativen und nachvollziehbaren Charakterisierung melanozytärer Hautveränderungen bei einer möglichst hohen Erkennungsrate [HSN⁺97] [SPB⁺98] [PBH⁺99]. Ausgangspunkt für diese quantitative Beschreibung sind die Merkmale der dermatoskopischen ABCD-Regel. Dadurch können die dargestellten Probleme umgangen und der Nutzen der Dermatoskopie einer breiteren Schicht von Dermatologen zum Nutzen der Patienten nähergebracht werden.

Die Darstellung des Analyseprozesses ab Abschnitt 8.5 folgt dem in Kapitel 2 dargestellten Schema. Zuvor wird jedoch ein Überblick über bisherige Ansätze in der computergestützten Melanomdiagnostik gegeben.

8.4 Ansätze zur Bildanalyse in der Melanomdiagnostik

Umfangreichere Bestrebungen, digitale Systeme für die Früherkennung des malignen Melanoms einzusetzen, begannen ca. 1985, als sich Dermatologen um eine breite Sensibilisierung der Bevölkerung für diese Tumorart bemühten [SM92]. Seitdem wurden die Ergebnisse mehrerer Arbeitsgruppen publiziert, die Bildverarbeitung zur Diagnosefindung einsetzen. Sie sollen hier kurz anhand der verwendeten Merkmale, des Datensatzes und der Klassifikationsergebnisse vorgestellt werden. Eine umfangreichere Darstellung findet sich in [Hor98]. Daneben existieren eine Reihe von Veröffentlichungen zur Beschreibung von Einzelmerkmalen, die im Zuge der Schilderung der jeweiligen Quantifikationsergebnisse in den Abschnitten 8.7.4 bis 8.7.15 diskutiert werden.

Zusammenfassung der Ansätze

Green et al. [GMM⁺94] veröffentlichten 1994 ihre Ergebnisse, die auf Vorarbeiten aus dem Jahre 1991 aufbauen [GMM⁺91]. Es wurden 17 Parameter vermessen, unter anderem Mittelwert und Standardabweichung der drei RGB-Farbkanäle sowie Formmaße, wie das Verhältnis von Fläche zu Umfang. Diese Parameter wurden aus insgesamt 164 Bildern pigmentierter Hautveränderungen extrahiert, darunter 18 maligne Melanome. Merkmalsauswahl und Klassifikation wurden mit dem Programmpaket SPSS unter Verwendung der Diskriminanzanalyse durchgeführt. Dabei konnte eine Sensitivität von 88.9% bei einer Spezifität von 89% erreicht werden.

Cascinelli et al. [CFB⁺92] erarbeiteten ihre Ergebnisse anhand eines Datensatzes von 169 Aufnahmen, darunter 45 maligne Melanome. Aus einem Pool von 298 nicht näher definierten Merkmalen wurden acht als relevant zur Diskriminierung erachtet. Darunter befinden sich Formmerkmale, die statistische Beschreibung der Farbverteilung, ein Maß für die Farbsättigung und ein Texturmerkmal. Darüberhinaus wird ein Merkmal nicht durch Bildanalyse sondern durch Beobachtung des behandelnden Arztes bestimmt. Eigentümlich ist diesem Ansatz der Verzicht auf quantitative Werte: für die Klassifikation werden binäre Daten verwendet, die auf den quantitativen Werten beruhen. Eine Läsion wird als malign klassifiziert, wenn mindestens zwei der acht Merkmale erfüllt sind. Auf dem Trainingsdatensatz wurde eine Sensitivität von 93.3% bei einer Spezifität von 59.6% erreicht. Das so definierte System wurde an einem Testdatensatz evaluiert, das aus 44 Aufnahmen bestand (darunter 12 maligne Melanome). Es wurde eine Sensitivität von 83.3% bei einer Spezifität von 59.3% erzielt.

Dieses System wurde von Cristofolini et al. [CBB⁺97] unabhängig an einem Datensatz von 176 Aufnahmen (darunter 35 maligne Melanome) getestet, offenbar aber unter Einbeziehung gleich vieler, aber teilweise anderer Merkmale (z.B. Hauttyp, Farbe der Iris). Die erreichte Sensitivität betrug 78% bei einer Spezifität von 46%.

Kjoelen et al. [KTU⁺95] verwenden in ihrem Ansatz 16 Merkmale, wobei zwei vom Dermatologen dem Diagnosesystem vorgegeben werden müssen (Elevation und Fläche). Der Arbeitsgruppe stand ein Datensatz mit Bildern von 92 malignen Melanomen und 169 benignen Hautveränderungen zur Verfügung, die von Farbdias eingescannt wurden. Zur Klassifikation verwenden die Autoren Entscheidungsbäume und neuronale Verfahren, berichten allerdings lediglich die Erkennungsrate der korrekt identifizierten malignen Melanome (Sensitivität, vgl. Abschnitt 8.7.2, Seite 99); der damit verbundene Anteil an falsch klassifizierten gutartigen Hautveränderungen wird nicht genannt. Eine Einordnung der Resultate erscheint damit nicht möglich. Die Spannweite der erreichten Sensitivität reicht, abhängig vom Klassifikationsverfahren und vom verwendeten Datensatz, von 70% - 95%.

1998 stellte Seidenari et al. [SPP98] die Ergebnisse eines Bildanalyseystems vor, dessen Aufbau bereits 1995 beschrieben wurde [APB⁺95]. Es beurteilt quantitativ die Merkmale Größe, Form, Berandung, Symmetrie, Farbe und Textur. Bei einigen Merkmalen wie Form oder Symmetrie ist eine Visualisierung vorgesehen. Das Datenmaterial bestand zwar aus 917 Bildern, aber die Gesamtperformanz wurde an einer Untermenge von 90 Aufnahmen (darunter 31 maligne Melanome) ermittelt. Bei Klassifikation mit Diskriminanzanalyse geben die Autoren eine Sensitivität von 93% bei einer Spezifität von 95% an. Eine Unterscheidung in Test- und Trainingsdatensatz findet nicht statt. In einem weiteren Artikel berichten Andreassi et al. [APR⁺99] über ihr System, in dem die Autoren eine andere Merkmalskombination vorstellen. Das Datenmaterial besteht aus 90 benignen und 57 malignen Hautveränderungen. Es wird eine Sensitivität von 81% und eine Spezifität von 88% unter Verwendung von 13 Merkmalen erreicht.

Unter der strikten Vorbedingung einer zu erreichenden Sensitivität von 100% erarbeiteten Gutkowicz-Krusin et al. [GKESK97] ihren Ansatz. Die Autoren definierten 13 Parameter zur quantitativen Analyse von Symmetrie, Berandung, Intensitätsverteilung, Textur und Farbe. In der Auswertung unter Verwendung eines linearen Klassifikators unterschieden die Autoren zwischen Trainings- und Testdaten. Im Trainingsdatensatz befanden sich 76 Aufnahmen (darunter 25 maligne Melanome). Der Testdatensatz bestand aus 28 Bildern (darunter 5 maligne Melanome). Die Vorbedingung einer hundertprozentigen Sensitivität konnte auch im Testdatensatz eingehalten werden. Die Spezifität betrug im Trainingsdatensatz 92% und im Testdatensatz 61%.

In mehreren Arbeiten stellen Schindewolf et al. ihre Ergebnisse vor ([SSA⁺93a] [SSA⁺93b] [SAS⁺93]). Für jedes Merkmal der ABCD-Regel wurde eine Vielzahl von Merkmalen definiert. Aus diesem Merkmalspool wurden mittels des Klassifikationsverfahrens CART, das zur Entscheidungsfindung Binärbäume benutzt, 23 Merkmale ausgewählt. Anhand des Datensatzes, bestehend aus 353 Aufnahmen gescannter Farbdias (darunter 215 maligne Melanome), wurde eine Sensitivität von 94% bei einer Spezifität von 88% erreicht [SSA⁺93a].

Die Autoren nahmen auch eine separate Analyse unter erneuter Evaluierung der zu verwendenden Merkmale an direkt digital erfaßten Farbbildern vor (309 Aufnahmen, darunter 80 Melanome). Die dabei erreichte Sensitivität betrug 91% bei einer Spezifität von 83%.

Diskussion

Eine vergleichende Auswertung der bisherigen Aktivitäten auf diesem Gebiet gestaltet sich aus vielfältigen Gründen schwierig. Die Erfassung des Datenmaterials ist sehr unterschiedlich. Verwendung finden sowohl dermatoskopische als auch nicht dermatoskopische Techniken. Die Aufnahme der digitalen Bilder erfolgt bei manchen direkt von der Haut, bei anderen über das Einscannen von Dias. Auch der Vergrößerungsfaktor schwankt beträchtlich (0.5 bis 20). Einige Autoren haben in ihr Datenmaterial neben malignen und benignen melanozytären Hautveränderungen auch andere pigmentierte Läsionen aufgenommen.

Auffällig in den meisten Studien ist allerdings die geringe Fallzahl an Bildern im allgemeinen und insbesondere solchen von Melanomen. Eine Ausnahme stellt die Arbeit von Schindewolf et al. dar [SSA⁺93a].

Die Aussagekraft der Klassifikationsergebnisse ist bei denjenigen Arbeiten unklar, die keine Trennung in Trainings- und Testmenge vorgenommen haben. Viele der Arbeiten haben also eher den Charakter einer Machbarkeitsstudie.

Dennoch lassen sich manche Feststellungen treffen. Alle Autoren verfolgen das Ziel einer computergestützten Diagnose. Sie unterscheiden sich jedoch in ihrer Strategie. Manche berechnen eine Vielzahl von Merkmalen (bei Cascinelli sind es beispielsweise 298), die vom medizinischen Experten nicht nachvollzogen werden können. Andere stützen ihre Extraktionsalgorithmen explizit auf die klinische Diagnostik. Jedoch gilt auch hier, daß dem Arzt die Gründe für den Diagnosevorschlag meistens nicht transparent gemacht werden können. Kein System erlaubt eine durchgehende Transparenz der computergestützten Klassifikation. Dem Arzt wird neben den Zahlenwerten der Einzelscores nur das Gesamtergebnis mitgeteilt. Bis auf eine Ausnahme [CBB⁺97] kommen alle Autoren übereinstimmend zu der Feststellung, daß computergestützte Diagnostik ein geeignetes Instrument zur Verbesserung der Hautkrebsfrüherkennung darstellt.

8.5 Bildakquisition und Vorverarbeitung

Die in dieser Arbeit verwendeten Bilder wurden direkt von der Haut, also ohne Umweg über Diapositive, mit einer 3-Chip-CCD-Kamera vom Typ XC-007P (Firma Sony, Tokyo, Japan) aufgenommen [SSP⁺96]. Die Kamera ist mit einem Objektiv mit Brennweite 25 mm und Lichtstärke 1:1.4 (Firma Canon, Chiba, Japan) ausgestattet. Ein eigens konstruierter Vorsatz gewährleistet einen standardisierten Abstand vom Objektiv zur Haut. Am vorderen Ende des Vorsatzes ist eine Glasplatte montiert, mit der unter Verwendung einer Kontaktflüssigkeit dermatoskopische Aufnahmen gemacht werden können. Die aufgenommenen Bilder haben eine Auflösung von 44 Pixel/mm. Der Bildausschnitt entspricht einer Fläche von 11.6 mm × 11.6 mm in vivo. Die Beleuchtung der Läsion erfolgt durch eine Halogenlampe, deren Licht über zwei verschiedene Glasfasern zum Kamerakopf geleitet wird. Die digitalisierten Bilder liegen im RGB-Format vor und haben eine Größe von 512 × 512 Pixel bei einer Farbtiefe von 8 Bit pro Kanal.

Die Standardisierung der Bildakquisition wird durch mehrere Maßnahmen gesichert. Entsprechend der auf Seite 8 beschriebenen Einteilung lassen sie sich wie folgt zusammenfassen.

Kameraparameter Um standardisierte Aufnahmen zu erhalten, wird eine automatische Helligkeitsjustierung vorgenommen. Dazu wird vor Inbetriebnahme der Kamera ein

Schwarzbild und ein Weißbild aufgenommen. Der Weißabgleich der drei Farbkanäle R,G,B wird manuell so angesteuert, daß ein mittlerer Weißwert von ca. 220 bei einer Grauwertskala von 0 bis 255 erreicht wird. Dies ermöglicht eine Standardisierung der drei Farbkanäle an den Sollwerten "Schwarz" und "Weiß". Eine explizite Farbkorrektur wird nicht durchgeführt.

Objektparameter Durch den Kameravorsatz wird eine einheitliche Entfernung des Kamerakopfes zur Hautveränderung erreicht. Die Hautveränderungen werden also mit einem standardisierten Vergrößerungsfaktor digitalisiert. Bei der Aufnahme wird die Kamera immer senkrecht zur Objektebene gehalten. Auch in dieser Hinsicht ist also eine Standardisierung gewährleistet.

Umgebungsparameter Durch die gezielte Lichtzuführung mittels zweier Glasfasern wird eine weitgehend homogene Ausleuchtung gewährleistet. Verbleibende Inhomogenitäten der Objektflächenausleuchtung werden durch eine Hintergrundkompensation (*Shadingkorrektur* [Abm94]) ausgeglichen.

8.6 Segmentation

Zentrales Thema dieses Abschnitts ist die Segmentation der Hautveränderungen, also die Trennung der Läsion von der umgebenden Haut. Der Segmentierungsalgorithmus basiert auf der Beobachtung, daß Hautveränderungen im Vergleich zur Haut dunkler sind. Viele Hautareale weisen, auch geschlechtsspezifisch, Haarbewuchs auf. Da Haare sich ebenfalls dunkel abbilden und daher die Läsionsdetektion stören, ist der Segmentierungsprozeß zweigeteilt. Im ersten Schritt werden die Haare detektiert und im zweiten findet die eigentliche Segmentation statt.

8.6.1 Haardetektion

Die Erkennung von Haaren ist Voraussetzung für eine erfolgreiche Segmentation und eine korrekte Quantifizierung der die Läsion charakterisierenden Merkmale. Haare haben naturgemäß eine dünne, längliche Struktur und somit bietet sich ein Liniendetektorverfahren zu ihrer Identifikation an. Für diese Arbeit wurde der Ansatz von Steger [Ste96b] [Ste96a] verwendet. Das Verfahren basiert auf einem konkreten Linienmodell und ist durch die Verwendung von Gaußfunktionen für Linien unterschiedlicher Breiten skalierbar. Es ist für die Haardetektion besonders geeignet, da es neben der Linienposition auch Auskunft über die Linienbreite gibt. Auf eine ausführliche Beschreibung des Verfahrens wird an dieser Stelle aus Platzgründen verzichtet und auf die oben genannte Literatur verwiesen.

Zur Haardetektion wird das Farbbild zunächst in ein Grauwertbild umgewandelt. Dieses Grauwertbild wird nun mit dem Verfahren von Steger analysiert. In Versuchen hat sich als Parameter der Gaußfunktion der Wert $\sigma = 1.5$ im Zusammenhang mit dem niedrigeren Schwellwert 1 und dem höheren Schwellwert 2 als günstig erwiesen (für die Bedeutung dieser drei Parameter sei auf die Literatur verwiesen). Im Resultat sind auch kurze Linienstücke enthalten, die nicht Teile von Haaren sind. Daher werden Linienstücke, die aus weniger als 125 Pixeln bestehen nicht als Haare gewertet. Diese Schwelle wurde in Versuchen ermittelt. In Abbildung 8.1 ist ein Beispiel für eine erfolgreiche Haardetektion dargestellt.

8.6.2 Segmentation der Läsion

Wegen der morphologischen Vielfalt von melanozytären Hautveränderungen wurde ein relativ einfaches und robustes schwellwertbasiertes Segmentationsverfahren gewählt. Durch die Vielgestaltigkeit des Untersuchungsobjekts muß die Entscheidung über die Korrektheit der Segmentation vom Dermatologen bestätigt bzw. das Ergebnis von ihm korrigiert werden. Der Wahl eines schwellwertbasierten Verfahrens liegt die Beobachtung zugrunde, daß melanozytäre Hautveränderungen ein dunkleres Erscheinungsbild haben als die umgebende Haut. Damit ist die Aufgabe definiert, durch Minimumssuche im Grauerthistogramm den Bereich mit Pixeln geringer Helligkeit vom Rest zu trennen. Bei den Untersuchungen hat sich gezeigt, daß im RGB-Farbbild der Pigmentbereich einen geringen Anteil an Blau aufweist. Daher wurde die Blau-Ebene des RGB-Bildes als Grundlage der weiteren Segmentationsschritte verwendet.

Schwellwertbasierte Verfahren nutzen im Allgemeinen das Grauerthistogramm, wobei in diesem Fall die Grauwerte des Blaukanals verwendet werden. Falls im Bild Haare detektiert




Abbildung 8.1: *Identifikation von Haaren*: Die detektierten Haare sind in der rechten Darstellung weiß maskiert.

wurden, werden die Grauwerte der Haarpixel zur Vermeidung von Störungen bei der Berechnung des Histogramms nicht berücksichtigt. Grundlage des Verfahrens ist die Bestimmung eines im Histogramm ausgezeichneten Wertes, der dann als Schwellwert verwendet wird. In diesem Fall ist eine Unterscheidung in Areale mit niedriger (geringer Grauwert, Läsion) und hoher Helligkeit (hoher Grauwert, umgebende Haut) vorzunehmen. Im Regelfall ist der Hauthintergrund im Vergleich zur Hautveränderung relativ homogen und somit bilden die Hautpixel im Histogramm eine gaußähnliche Verteilung. Als im Histogramm ausgezeichneter Ort ist daher ein Minimum zu suchen, das vor der Verteilung der Hautpixel liegt. Problematisch ist die Bestimmung des richtigen Minimums, da im Histogramm unter Umständen mehrere lokale Minima vorhanden sind. Daher wurde zum einen das Histogramm mit einem Mittelwertfilter der Breite 5 geglättet und zum anderen ein iterativer Ansatz gewählt, in dem die Binsgröße des Histogramms schrittweise verfeinert wird. Dieser Prozeß ist beispielhaft in Abbildung 8.2 dargestellt. Im ersten Schritt wird das Histogramm bei einer relativ breiten Binsgröße erstellt und dort das Minimum zwischen den zwei Verteilungen dunkler und heller Pixel gesucht. Wird bei dieser Auflösung noch keine bimodale Histogrammform erreicht, so wird die Auflösung solange verfeinert bis diese Form angenommen wird. Es hat sich als vorteilhaft erwiesen, nach Bestimmung des Minimums den Schwellwert auf der Grauwertachse einen gewissen Betrag in Richtung höherer Grauwerte zu verschieben. Damit werden die Übergangsbereiche von Läsion zur Haut besser erfaßt, die zwar noch zur Läsion gehören aber eine höhere Helligkeit aufweisen. Anschließend wird iterativ die Binsgröße des Histogramms verfeinert und als Ausgangspunkt zur Minimumssuche der Schwellwert der vorherigen Iteration genutzt.

Die Grauwerte, die kleiner oder gleich dem Schwellwert sind, werden in einem Binärbild markiert. Ein Beispiel zu diesem Zwischenergebnis ist im linken Teil der Abbildung 8.3 zu sehen. Da Haare sich im Grauwertbild ebenfalls dunkel darstellen, sind sie im Binärbild auch ent-




Abbildung 8.2: *Iterative Segmentierung der Hautveränderung*: Dargestellt sind die Zwischenergebnisse der Schwellwertbestimmung im Histogramm der Helligkeitswerte. Pixel, deren Grauwert kleiner als der angezeigte Schwellwert ist, werden als zur Läsion zugehörig klassifiziert. Der Schwellwert wird durch Minimumssuche bestimmt. Ausgehend von diesem Minimum wird der Schwellwert um einen gewissen Betrag in Richtung höhere Grauwerte versetzt. Auf diese Weise wird der hellere Randbereich der Läsion mitsegmentiert. Durch zunehmende Verfeinerung der Bingröße im Histogramm erfolgt die Schwellwertsuche iterativ. Zur besseren Darstellung wurde die Grauwertachse auf die Skala $[0, 255]$ skaliert. Dargestellt ist hier die Schwellwertbestimmung zu dem Bild aus Abbildung 8.3.

halten. Diese Haarpixel werden aus dem Binärbild entfernt und die entstandenen Lücken mit einer Dilatation gefüllt.

Der ermittelte Schwellwert stellt in gewisser Weise eine artifizielle Markierung dar und so verläuft der Läsionsrand sehr unregelmäßig (vgl. linker Teil von Abbildung 8.3). Zur Vermeidung dieses Effekts wird das Binärbild mit einem Medianfilter der Größe 9×9 geglättet.

Bei der Schwellwertoperation werden neben der eigentlichen Läsion auch andere, kleine Regionen extrahiert, die nicht zur Hautveränderung gehören und daher entfernt werden müssen. Zur Differenzierung der einzelnen Regionen wird ein *Labeling* [LOPR97] vorgenommen. Durch diese Operation wird jeder zusammengehörenden Gruppe von Pixeln (eine Region) eine eindeutige Zahl (das *Label*) zugeordnet. Da der Läsionsbereich die größte Fläche einnimmt, wird die Region ausgewählt, die die meisten Pixeln enthält. Die so bestimmte Maske kann noch Löcher enthalten. Daher wird die Kontur dieser Maske bestimmt und als Läsionsmaske diejenigen Pixel definiert, die innerhalb dieser Kontur liegen. Im rechten Teil von Abbildung 8.3

ist das Ergebnis zu dem Beispiel dargestellt, wobei zur besseren Übersicht nur die Kontur der Läsionsmaske im Bild markiert ist.




Abbildung 8.3: *Segmentation*: In der linken Abbildung sind diejenigen Pixel dargestellt, deren Grauwert kleiner ist als der in der iterativen Histogrammanalyse bestimmte Schwellwert (vgl. Abbildung 8.2). Die Nachbearbeitung dieses Binärbildes führt zum Segmentationsergebnis (rechts).

Das Ergebnis wird dem Dermatologen als Segmentationsvorschlag präsentiert. Erscheint es ihm nicht korrekt, so bieten sich zwei Möglichkeiten. In der ersten wird im dargestellten Histogramm interaktiv ein neuer Schwellwert gewählt und daraus die Läsionsmaske nach obigen Schema errechnet. Mit diesem Korrekturmechanismus können die meisten Läsionen korrekt segmentiert werden. Führt auch dieses Vorgehen zu keinem befriedigendem Ergebnis, so können beispielsweise interaktiv diejenigen Regionen markiert werden, die zur bisher segmentierten Läsionsfläche addiert bzw. subtrahiert werden sollen. Die in dieser Arbeit verwendeten Bilder melanozytärer Hautveränderungen wurden nach diesem Schema segmentiert. Die einzelnen Segmentierungen wurden von einem Dermatoskopie-Experten überprüft, um anschließend, falls erforderlich, korrigiert zu werden.

8.7 Merkmalsextraktion

In den folgenden Abschnitten werden die Ergebnisse der einzelnen Merkmalsquantifizierungen sowie deren Visualisierungen beschrieben. Die Güte dieser Quantifizierungen hinsichtlich ihrer Fähigkeit, die beiden Klassen der benignen und malignen melanozytären Hautveränderungen zu trennen, ist dabei ein wesentlicher Aspekt. Nach einer Beschreibung des verwendeten Bildmaterials werden daher einige elementare Maße vorgestellt, mit denen diese Beurteilung durchgeführt wird.

8.7.1 Bildmaterial

Die Resultate der Merkmalsquantifizierungen wurden anhand eines Datensatzes von 749 dermatoskopischen Aufnahmen erzielt. Die Aufnahmen wurden nach dem in Abschnitt 8.5 beschriebenen Verfahren an der Dermatologischen Klinik und Poliklinik Regensburg über mehrere Jahre hinweg akquiriert und retrospektiv zusammengestellt. Dieser Datensatz setzt sich aus 560 benignen melanozytären Hautveränderungen und 189 malignen Melanomen zusammen. Die Parameterwahl und -optimierung der verwendeten Algorithmen wurde auf der Grundlage eines Datensatzes von 120 Bildern unternommen, die mit einem Zufallsalgorithmus aus den beiden Untermengen ausgewählt wurden. In diesem Trainingsdatensatz sind anteilig gleich viele benigne wie maligne Hautveränderungen enthalten.

Um eine Wiederholung der Darstellung der Ergebnisse zu vermeiden, wird im folgenden die Qualität der Merkmale hinsichtlich der Separabilität der beiden Klassen bezüglich des gesamten Datensatzes untersucht. Die Merkmalsauswahl in Verbindung mit der Abschätzung der Klassifikationsleistung in Abschnitt 8.8 (Seite 143) wird unter Beachtung des Prinzips der Trennung von Trainings- und Testdatensatz durchgeführt.

8.7.2 Qualitätsmaße

Ziel der Untersuchungen ist die Separierung der Klasse der malignen von der Klasse der benignen melanozytären Hautveränderungen anhand der extrahierten Merkmale. Da für jedes Einzelmerkmal ein quantitatives Maß berechnet wird, kann mit einem Schwellwert t eine Trennung in die benigne und maligne Klasse vorgenommen werden. Die Separierfähigkeit eines Merkmals wird mittels verschiedener Qualitätsmaße beurteilt.

Dazu werden die Scores x_i bezüglich eines Merkmals M einer vorgegebenen Menge maligner Melanome in der Menge MEL^M und die der benignen melanozytären Hautveränderungen in NAV^M zusammengefaßt. Die folgende Definition der charakterisierenden Größen erfolgt in der Annahme, daß die Scores maligner Melanome im Durchschnitt größer sind als die der benignen melanozytären Hautveränderungen (andernfalls sind die Vergleichsoperatoren entsprechend anzupassen):

RP	=	$ \{x_i \in \text{MEL}^M x_i \geq t\} $...	Anzahl der korrekt identifizierten malignen Melanome (Richtig Positiv)
FN	=	$ \{x_i \in \text{MEL}^M x_i < t\} $...	Anzahl der falsch identifizierten malignen Melanome (Falsch Negativ)
RN	=	$ \{x_i \in \text{NAV}^M x_i < t\} $...	Anzahl der korrekt identifizierten benignen melanozytären Hautveränderungen (Richtig Negativ)
FP	=	$ \{x_i \in \text{NAV}^M x_i \geq t\} $...	Anzahl der falsch identifizierten benignen melanozytären Hautveränderungen (Falsch Positiv)

Aus dieser Darstellung lassen sich folgende drei elementare Qualitätsmaße ([Wer92] [Han97]) definieren, die hier konkret für die Melanomproblematik formuliert sind:

Sensitivität: Diese Kenngröße beschreibt den Anteil korrekt identifizierter maligner Melanome:

$$\text{Sens} = \frac{RP}{RP + FN}$$

Spezifität: Dieses Maß quantifiziert den Anteil korrekt identifizierter benigner melanozytärer Hautveränderungen:

$$\text{Spec} = \frac{RN}{RN + FP}$$

Korrektheit: Dieses Maß quantifiziert den Anteil korrekt identifizierter melanozytärer Hautveränderungen:

$$\rho = \frac{RP + RN}{RN + FN + RP + FP}$$

Sensitivität und Spezifität bedingen einander und müssen daher zusammen betrachtet werden (durch eine passende Wahl des Schwellwerts t kann eine Sensitivität von 100% erreicht werden; oft ist dann die erzielte Spezifität sehr gering).

Variiert man nun systematisch den Schwellwert t und mißt die jeweils erreichte Sensitivität und Spezifität, so kann man diese Qualitätsmaße gegeneinander in einer sogenannten ROC-Kurve (*receiver operating characteristic*) [Han97] darstellen. In dieser Darstellung wird die Falsch-Positiv-Rate ($FPR = 1 - \text{Spezifität}$) gegen die Sensitivität aufgetragen. Eine beispielhafte ROC-Kurve wird in Abbildung 8.4 gezeigt. Mit dieser Darstellung läßt sich die Separierfähigkeit des Merkmals eingehend charakterisieren. Im Optimalfall lassen sich die beiden Klassen mit dem Merkmal gänzlich trennen, d.h. Sensitivität und Spezifität haben zu einem gegebenen Schwellwert t den Wert 1. Damit ist auch der Optimalpunkt der ROC-Kurve definiert: er liegt bei einer Sensitivität von 1 und einer Falsch-Positiv-Rate von 0. Die ROC-Kurve läßt sich durch folgende Eigenschaften charakterisieren:

- Ein Maß für die Güte des Merkmals ist die Fläche unter der Kurve AUC (*area under curve*). Mit steigender AUC gewinnt das Merkmal an Qualität bezüglich der Separierfähigkeit.




Abbildung 8.4: *Beispiel einer ROC-Kurve:* Angezeigt wird neben der Kurve an sich die *area under the curve* (Fläche). Mit einem Stern gekennzeichnet ist der Kurvenpunkt, der dem Optimalpunkt (Sensitivität = Spezifität = 1) am nächsten liegt. Die Position dieses Punktes ist neben der Fläche angegeben.

- Ein weiteres Charakteristikum ist die Position des Kurvenpunktes, der dem Optimum (Sensitivität = Spezifität = 1) am nächsten kommt, wobei üblicherweise die Euklidische Norm als Distanzmaß Verwendung findet. In dieser Arbeit ist dieser Punkt mit einem Stern-Symbol gekennzeichnet und seine Position wird neben der AUC angezeigt.

Es ist wünschenswert, daß die Kurve möglichst lange eine hohe Sensitivität und Spezifität aufweist. Dies ist ein Hinweis darauf, daß die Merkmalsverteilungen der beiden Klassen einen definierten Überlappungsbereich haben und abseits davon wenig Ausreißer zu finden sind.

8.7.3 Aufbau der Einzelbeschreibungen

In den folgenden Abschnitten werden die Ergebnisse für die einzelnen Merkmale erläutert und diskutiert. Dabei finden die Abkürzungen MM für maligne Melanome und benigne MHV für benigne melanozytäre Hautveränderungen Verwendung. Jede Darstellung der Ergebnisse folgt dem gleichen Schema:

Ansätze aus der Literatur: Soweit zu dem Merkmal bereits Arbeiten veröffentlicht worden sind, werden sie kurz dargestellt und diskutiert. Diese Diskussion erfolgt insbesondere unter dem Aspekt der nachvollziehbaren quantitativen Bildanalyse.

Verwendete Methode: In dieser Sektion wird der genaue Quantifikationsprozeß angegeben. Da er in fast allen Fällen in allgemeiner Form in den Kapiteln 3 bis 6 beschrieben ist, ist diese Schilderung unter Angabe der entsprechenden Referenz kurz gefaßt.

Ergebnisse: Hier werden die Ergebnisse der Quantifizierungen für den gesamten Datensatz beschrieben und diskutiert. Angegeben wird immer die Verteilung der Scores beider

Klassen. Als Maße zur Evaluierung der Verteilungen wird jeweils der Mittelwert und die Standardabweichung für beide Klassen verwendet. Die Scores der malignen und der benignen melanozytären Hautveränderungen werden getrennt sortiert in einem Diagramm aufgetragen. Der jeweilige Mittelwert wird durch eine horizontale Linie angezeigt. Zwei vertikale Linien, die von der Mittelwert-Linie ausgehen, repräsentieren die Standardabweichung. Zur Beurteilung der Separierfähigkeit durch das Merkmal wird die ROC-Kurve angegeben und diskutiert.

Visualisierung: Abschließend wird das Ziel der Visualisierung und die Technik, mit der dieses erreicht wird, beschrieben. Dabei sind die Visualisierungen lediglich als Vorschlag zu verstehen, wie die Scores der Einzelmerkmale nachvollziehbar dargestellt werden können. Aus diesem Grunde sind die Beschreibungen der konkreten Visualisierungsvorschriften meist kurz gehalten. Als Beispiele werden jeweils drei melanozytäre Hautveränderungen zusammen mit der Visualisierung des Merkmals abgebildet. Durchwegs handelt es sich um Hautveränderungen, bei denen eine geringe, eine mittlere und eine hohe Ausprägung des Merkmals zu finden ist.

8.7.4 Asymmetrie der Läsionsform

Verläuft das maligne Wachstum horizontal in der Haut, so breitet sich die Läsion zentrifugal aus. Dieser Prozeß resultiert bei malignen Melanomen durch das unkoordinierte Wachstum oft in einer asymmetrischen äußeren Form der Läsion. In der dermatoskopischen ABCD-Regel ist diese Eigenschaft in der A-Komponente enthalten.

Ansätze aus der Literatur

Die meisten Autoren, die sich mit der digitalen Analyse von melanozytären Hautveränderungen beschäftigen, verwenden Maße zur Quantifizierung der Symmetrie der äußeren Läsionsform oder ähnliche Formmaße. Seidenari et al. ([SBD⁺95] [SPP98]) unterteilen die Läsion in 256 Sektoren. Die Konstruktion dieser Sektoren orientiert sich am geometrischen Schwerpunkt der Läsion. Der Symmetriescore errechnet sich aus den Differenzen der Läsionsfläche in achsensymmetrischen Sektoren. Schindewolf et al. [HSS⁺94] verwenden zur Beschreibung der äußeren Läsionsform 39 Formparameter wie beispielsweise das Verhältnis Umfang zu Fläche. Claridge et al. [CHKA92] verwenden als Maß für die Regelmäßigkeit das Verhältnis der Fläche einer der Läsion äquivalenten Ellipse zu der Fläche der Läsion (der Begriff "äquivalente Ellipse" wird nicht genau definiert). Diese Quantifizierungsalgorithmen lehnen sich jedoch nicht an den Vorgang der visuellen Inspektion von Läsionen durch Dermatologen an und sind daher für die Ziele einer nachvollziehbaren quantitativen Bildanalyse weniger geeignet. Zwei Autoren ([SLM92] [GKESK97]) verfolgen einen Ansatz, der auch in dieser Arbeit Verwendung findet und im folgenden Absatz erläutert wird.

Verwendete Methode

Die Asymmetrie der äußeren Form der Läsion wird anhand der binären Läsionsmaske und der Symmetrieachsen g_1 und g_2 (vgl. Abschnitt 3.1, Seite 12) bestimmt. Der Quantifizierungsalgorithmus basiert auf dem allgemeineren Verfahren zur Bestimmung der pixelbezogenen Symmetrieeigenschaften aus Abschnitt 3.3.1 (Seite 16). Für Pixel p und p' in achsensymmetrischer Lage wird dort die Ähnlichkeit der das Merkmal M beschreibenden Maßzahlen mittels einer Ähnlichkeitsfunktion $s(f(p), f(p'))$ berechnet. Da die Läsion durch ein Binärobjekt repräsentiert wird, dient in diesem Fall als Ähnlichkeitsmaß der Absolutbetrag der Differenz der Binärwerte von p und p' . Für jede der beiden Symmetrieachsen g_i ($i = 1, 2$) wird die mittlere Ähnlichkeit $G_{S_P}^i$ nach Gleichung 3.8 (Seite 17) bestimmt. Je höher $G_{S_P}^i$ ist, desto weniger Pixel sind in achsensymmetrischer Lage vorhanden und somit ist auch die Asymmetrie der äußeren Form erhöht. Der Gesamtscore wird nach Gleichung 3.9 (Seite 17) gebildet.

Ergebnisse

Alle Bilder im vorhandenen Datensatz wurden nach oben beschriebenen Algorithmus hinsichtlich der Asymmetrie der äußeren Form quantifiziert. Die Ergebnisse dazu sind in Abbildung 8.5 dargestellt. Im linken Diagramm sind die geordneten Scores für die MM (Sternchen-Symbole) und für die benignen MHV (Quadrat-Symbole) aufgetragen. Für die benignen MHV beträgt der Mittelwert 0.077 und unterscheidet sich deutlich vom Mittelwert der MM mit 0.12. Die Standardabweichung der benignen MHV beträgt 0.032 und ist damit halb so groß wie die der MM mit 0.065. Gerade die hohe Standardabweichung der Scores der MM schränkt die Separierfähigkeit dieses Merkmals ein. Die Fläche unter der ROC-Kurve (rechtes Dia-

gramm in Abbildung 8.5) beträgt 0.738 und der dem Optimalpunkt am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.630 und bei einer Spezifität von 0.730. Mit diesen Ergebnissen zählt dieses Merkmal zu den schwächeren bezüglich der Separierfähigkeit zwischen malignen und benignen melanozytären Hautveränderungen.

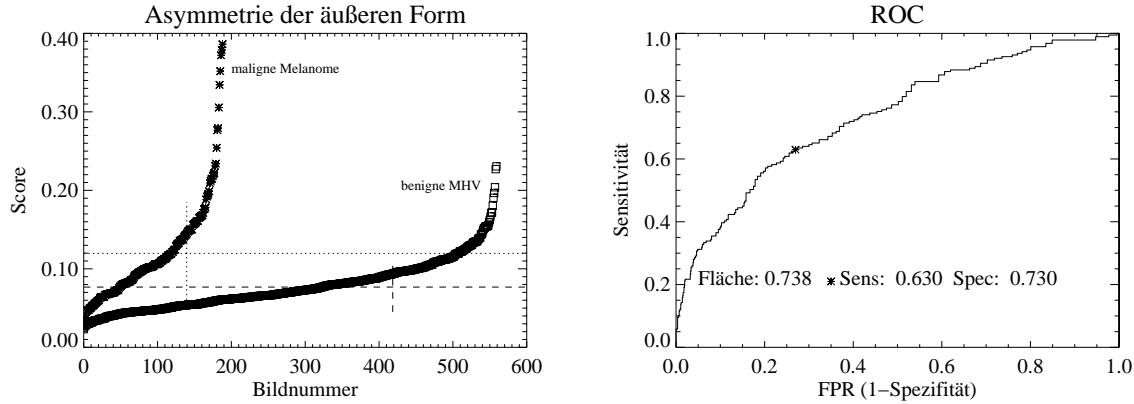


Abbildung 8.5: *Ergebnis der Quantifizierung der Asymmetrie der äußeren Form*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Visualisierung

In der Visualisierung soll zur besseren Orientierung für den Dermatologen die Struktur des Originalbildes ersichtlich sein und diejenigen Pixel, die ein achsensymmetrisches Pendant aufweisen, auffällig markiert werden. Dazu wird eine Farbraumtransformation in den HLS-Farbraum (vgl. Abschnitt 6.1.2, Seite 74) vorgenommen. Die *hue*-Komponente der Pixel mit achsensymmetrisches Pendant wird auf den Farbwert Grün gesetzt, während die restlichen Läsionspixel rot markiert werden. Der *saturation*-Wert wird konstant auf den Wert 0.5 gesetzt. Um die Struktur der Läsion erkennbar zu lassen, wird der *lightness*-Wert nur soweit verändert, daß der Mittelwert den Wert 0.4 aufweist. Damit bleibt die innere Struktur der Läsion erkennbar und es wird eine gute Darstellbarkeit des Scores auch bei dunkleren Läsionen erreicht. Weiterhin werden die Kontur und der Schwerpunkt der Läsion markiert. Durch diese Visualisierung wird ersichtlich, welche Pixel von der Läsion zu entfernen wären, um eine perfekt symmetrische Läsion zu erhalten.

In Abbildung 8.6 sind drei Beispiele zur Visualisierung dargestellt. In der linken Spalte ist eine Läsion mit geringer, in der mittleren Spalte eine Läsion mit mittlerer und schließlich in der rechten Spalte eine Läsion mit hoher Asymmetrie der äußeren Form dargestellt. Die Zunahme des Scores wird beim Betrachten der Visualisierungen am wachsenden Anteil roter Areale nachvollziehbar.




Abbildung 8.6: *Visualisierung der Asymmetrie der äußeren Form:* In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmender Formasymmetrie. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.5 Konvexität der Läsionsform

Mit der Quantifizierung der Symmetrie der äußeren Läsionsform wird das asymmetrische maligne Wachstum in die umgebende Haut gemessen. Mit dem in diesem Abschnitt erläuterten Verfahren soll die Gleichmäßigkeit des horizontalen melanozytären Wachstums quantifiziert werden. Das Verfahren basiert auf der Bestimmung der Form, die die Läsion haben müßte, um konvex zu sein. Dieses Merkmal ist nicht Bestandteil der dermatoskopischen ABCD-Regel.

Ansätze aus der Literatur

Dem Autor ist keine Arbeit bekannt, in der die oben beschriebene Eigenschaft behandelt wird. Die meisten Autoren verwenden zur Quantifizierung der Läsionsgeometrie Formmaße wie das Verhältnis von Fläche zu Umfang [GMM⁺94], oder die Ähnlichkeit der Läsionsform zu einem Kreis [SPP98] bzw. zu einer Ellipse [CHKA92].

Verwendete Methode

Um das Binärobjekt mit der geringsten Fläche zu bestimmen, das die Läsion enthält und konvex ist, ist die konvexe Hülle zur tatsächlichen binären Maske der Läsion zu berechnen. Gesucht ist also die konvexe Hülle zur Läsionskontur. Die Menge der Punkte K , die sich in der konvexen Hülle befinden, ist dann die gesuchte Läsionsform. Nach der Berechnung der konvexen Hülle (Algorithmen hierzu sind beispielsweise in [SDK96] beschrieben) wird folgender Quotient bestimmt, wobei mit L die Menge der Pixel der binären Läsionsmaske bezeichnet wird:

$$A_K = \frac{|K \setminus L|}{|L|}$$

Der Zähler des Terms im rechten Teil der Gleichung beschreibt die Anzahl der Pixel, die benötigt werden, um aus der tatsächlichen Läsion die kleinstmögliche konvexe Form zu erhalten. Durch den Nenner wird der Zähler mit der Anzahl der tatsächlich vorhandenen Läsionspixel normiert. Beträgt der Score $A_K = 0$, so ist die tatsächliche Läsionsform konvex. Mit steigendem Score A_K erhöht sich die Anzahl, der Pixel, die benötigt werden, um eine konvexe Form zu erhalten.

Ergebnisse

In Abbildung 8.7 sind die Ergebnisse der Quantifizierungen aufgetragen. Im linken Diagramm sind die geordneten Scores für die MM (Sternchen-Symbole) und für die benignen MHV (Quadrat-Symbole) dargestellt. Die Scores der benignen MHV weisen eine geringe Streuung auf (Mittelwert: 0.059, Standardabweichung: 0.033). Demgegenüber ist zwar der Mittelwert der Scores bei den MM mit einem Wert von 0.097 deutlich größer, aber deren Standardabweichung ist mit einem Wert von 0.071 relativ hoch. Dies hat eine Beeinträchtigung der Separierfähigkeit des Merkmals zur Folge, wie sie in der rechts abgebildeten ROC-Kurve zu erkennen ist. Die AUC beträgt 0.701 und der dem Optimum am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.635 und einer Spezifität von 0.671.




Abbildung 8.7: *Ergebnis der Quantifizierung der Konvexität der äußeren Form*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve




Abbildung 8.8: *Visualisierung der Konvexität der äußeren Form*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmender Formasymmetrie. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

Visualisierung

Mit der Visualisierung dieses Merkmals soll dem Dermatologen ersichtlich werden, welche Areale zur Hautveränderung hinzugefügt werden müssen, damit sie eine konvexe Form hat. Die Visualisierungstechnik ähnelt derjenigen der Asymmetrie der äußeren Form (Abschnitt 8.7.4). Im Bild werden diejenigen Areale rot markiert, die innerhalb der konvexen Hülle liegen, aber nicht Teil der Läsion sind. Zur besseren visuellen Abgrenzbarkeit wird die Kontur der Hautveränderung weiß gekennzeichnet.

Drei Beispiele zur Visualisierung sind in Abbildung 8.8 dargestellt mit von links nach rechts zunehmenden Score. Während im linken Beispiel fast alle Läsionspixel innerhalb der konvexen Hülle liegen, ist dieser Anteil im mittleren Bild durch größere Einbuchtungen in der Läsion deutlich erhöht. Im rechten Bild ist der rot markierte Anteil durch die sehr unregelmäßige Läsionsform noch umfangreicher.

8.7.6 Farbasymmetrie

Die Farbe einer melanozytären Hautveränderung wird vor allem durch das Melaninpigment bestimmt [SBFBL93]. Durch unterschiedliche Einlagerungstiefen des Melanins in der Haut entstehen verschiedene Farbtöne. So erscheint Melanin in den oberen Anteilen der Epidermis schwarz, während es beispielsweise in der retikulären Dermis ein stahlblaues Erscheinungsbild hat. Durch verstärkte Gefäßbildung können rote Farbtöne entstehen. Beim malignen Wachstum ist Melanin oft unregelmäßig verteilt und daher ist die Beurteilung der Farbasymmetrie bei der Differentialdiagnose wichtig (insbesondere, da auch gutartige melanozytäre Hautveränderungen eine erhöhte Farbvielfalt aufweisen können und sie sich daher allein mit diesem Merkmal nicht unterscheiden lassen). In der dermatoskopischen ABCD-Regel ist diese Eigenschaft Bestandteil der Beurteilung des Merkmals "Asymmetrie", zusammen mit der Asymmetrie von Struktur und Form.

Ansätze aus der Literatur

Schindewolf et al. ([SSA⁺93a] [HSS⁺94]) beschreiben ein Verfahren zur Bestimmung der Farbasymmetrie. Dazu wird die Läsion in vier konzentrische Areale aufgeteilt. Durch das Zentrum der Läsion werden vier Linien in einem Winkel von 45° zueinander aufgetragen, die sich jedoch nicht an der geometrischen Symmetrieachse der Läsion orientieren. Aus dieser Aufteilung resultieren 32 Segmente. Für jedes Segment werden mehrere Maße wie Minimum oder Maximum der Farbwerte bestimmt sowie die Summe der absoluten Differenzen gegenüberliegender Segmente. Insgesamt werden 88 Merkmale für die Farbasymmetrie errechnet. Die Nachvollziehbarkeit und Reproduzierbarkeit wurden bei der Formulierung dieses Ansatzes nicht berücksichtigt.

Gutkowicz-Krusin et al. [GKESK97] verwenden einen Ansatz, der dem Vorschlag aus dieser Arbeit ähnlich ist. Auch sie führen einen Vergleich achsensymmetrischer Pixel durch. Allerdings verwenden die Autoren nur die Intensitätswerte der einzelnen Farbkanäle, führen also einen echten Farbvergleich nicht durch.

Verwendete Methode

Das Merkmal der Farbasymmetrie wird nach dem in Abschnitt 6.4 (Seite 78) beschriebenen Verfahren quantifiziert [PBD⁺99]. Der Quantifikationsalgorithmus basiert auf dem Farbvergleich von Pixeln in achsensymmetrischer Lage. Wie in Abschnitt 6.4 erläutert, muß das zu untersuchende Objekt für die Anwendbarkeit dieses Vorgehens gewisse Eigenschaften (einfache äußere Form und langsame Änderungen der Farbwerte innerhalb des Objekts) aufweisen. Diese Voraussetzungen sind bei melanozytären Hautveränderungen erfüllt, da sie meist ellipsoförmig sind und da nur geringe Schwankungen der Farbwerte auftreten.

Als erster Schritt wird eine Farbraumtransformation in den HLS-Raum durchgeführt. Diese Wahl ist zum einen in der Ähnlichkeit der Zerlegung in die Komponenten Farbton, Sättigung und Helligkeit zum menschlichen Farbempfinden begründet. Weiterhin hat sich dieser Farbraum in kleinen Testreihen als positiv für die Separierungseigenschaft des Merkmals "Farbasymmetrie" herausgestellt. Falls zu einem Pixel ein achsensymmetrisches Pendant existiert, wird der Farbabstand nach Gleichung 6.4 (Seite 78) bestimmt. Um einen Ausgleich des unterschiedlichen Wertebereichs der einzelnen Farbkoordinatenachsen zu erreichen und den Einfluß dieser Achsen unterschiedlich gestalten zu können, sind in Gleichung 6.4 Gewichte

vorgesehen. In den genannten Tests hat sich die Gewichtungskombination $w_h = 1$, $w_l = 120$ und $w_s = 120$ als vorteilhaft erwiesen. Für die globale Quantifizierung der Farbeigenschaft wird nach Gleichung 6.6 (Seite 78) vorgegangen.

Ergebnisse

Die Quantifizierungsergebnisse für den gesamten Datensatz aber getrennt nach MM (Sternchen-Symbole) und benigne MHV (Quadrat-Symbole) ist im linken Teil von Abbildung 8.9 zu sehen. Der Mittelwert der Melanombeurteilungen hinsichtlich dieses Merkmals beträgt 17.29, der der benignen MHV 9.81. Die Standardabweichung der Scores für die malignen Melanome ist mit 4.63 etwa doppelt so groß wie die der benignen melanozytären Hautveränderungen ($\sigma = 2.67$). Aus diesen Zahlen wird ersichtlich, daß dieses Merkmal eine weitgehende Separierung der beiden Klassen zuläßt. Im rechten Teil der Abbildung ist die ROC-Kurve dargestellt. Die AUC beträgt 0.941 und der dem Optimum am nächsten gelegene Kurvenpunkt weist eine Sensitivität von 0.884 bei einer Spezifität von 0.875 auf.




Abbildung 8.9: *Ergebnis der Quantifizierung der Farbasymmetrie*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Die gute Separierfähigkeit dieses Merkmals findet ihre Bestätigung auch in der dermatoskopischen ABCD-Regel. Dort beträgt der Höchstbeitrag der Asymmetrie 2.6, also fast 30% des maximal möglichen Dermatoskopie-Punktwerts DPW (vgl. Tabelle 8.1, Seite 90).

Visualisierung

In der angestrebten Visualisierung soll deutlich werden, wie groß die Farbunterschiede innerhalb der Läsion bezüglich der Symmetrieachse sind. Grundlage für die Visualisierung bilden die Farbabstände von Pixeln in achsensymmetrischer Lage (Gleichung 6.4, Seite 78). Die Ähnlichkeit jedes Pixels einer Halbebene zu seinem achsensymmetrisches Pendant ist durch den Farbabstand charakterisiert. Dieser Abstand wird mittels einer Look-up-Tabelle farbkodiert. Mit steigendem Farbabstand variiert die Farbe von Blau über Grün zu Rot. Pixel, die kein Pendant in achsensymmetrischer Lage haben, sind schwarz gekennzeichnet.

Beispiele für Visualisierungen des Merkmals Farbasymmetrie sind in Abbildung 8.10 dargestellt. Die linke Spalte zeigt eine Läsion mit geringer, die mittlere Spalte mit durchschnittlicher und die rechte Spalte mit hoher Farbasymmetrie. Eingezeichnet sind weiterhin zur

besseren Orientierung die Kontur der Läsion, ihr Schwerpunkt und die geometrischen Symmetrieachsen. Die Visualisierung der linken Hautveränderung zeigt einen hohen Anteil an Blau (geringe Farbabstände). Die mittlere Visualisierung weist einen deutlich höheren Anteil an Grün auf, während in der rechten Abbildung grüne und rote (hohe Farbabstände) Areale dominieren.




Abbildung 8.10: *Visualisierung der Farbasymmetrie*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmender Farbasymmetrie. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.7 Asymmetrie der Strukturverteilung

Neben der Farbasymmetrie deutet auch eine asymmetrische Verteilung der Strukturelemente auf Malignität hin. Dies ist in dem unregelmäßigen Wachstum maligner Zellen begründet (vgl. Abschnitt 8.7.13).

Ansätze aus der Literatur

In den meisten dem Autor bekannten Arbeiten wird die Asymmetrie der Strukturverteilung nicht erfaßt. Lediglich Schindewolf et al. ([SSA⁺93a] [HSS⁺94]) geben ein Verfahren zur quantitativen Beschreibung dieses Merkmals an. Es basiert auf Texturmerkmalen, die mit vier Gradientenfilter (Größe: 3 × 3) bestimmt wurden. Das weitere Vorgehen im Quantifizierungsmechanismus wird von den Autoren auch zur Charakterisierung der Farbasymmetrie angewendet und wurde bereits in Abschnitt 8.7.6 beschrieben. Das Verfahren ist allerdings nicht rotationsinvariant. Die Autoren leiten aus diesem Mechanismus 23 Merkmale für die Texturasymmetrie ab und damit ist es nur bedingt für eine nachvollziehbare quantitative Bildanalyse geeignet.

Verwendete Methode

Zur Beurteilung der Asymmetrie der Strukturverteilung werden die Läsionsbilder mit der fSIM-Methode (Abschnitt 4.4 Seite 33) und den Radien $r_1 = 3$ und $r_2 = 5$ analysiert. Die Wahl dieser Parameter ist in der Größenskala der gesuchten Strukturen begründet und hat sich in Tests als positiv für die Separierfähigkeit dieses Merkmals erwiesen. Wie bei der Beurteilung der Farbasymmetrie basiert das Verfahren auf dem Vergleich von Scores in achsensymmetrischer Lage. Da jedoch Pixel, die Teil von Strukturelementen sind (wie beispielsweise Linien), nur in Ausnahmefällen direkt ein achsensymmetrisches Pendant aufweisen, ist ein pixelweiser Vergleich in diesem Falle nicht sinnvoll. Daher findet das in Abschnitt 3.3.2 (Seite 17) beschriebene Verfahren Verwendung. Dort wird die Läsion mit Hilfe eines Gitters in Unterbereiche unterteilt und für diese werden die strukturellen Eigenschaften lokal bestimmt. Der Vergleich dieser lokalen Scores bezüglich Gitterelementen in achsensymmetrischer Lage bildet die Grundlage der Quantifizierung der Asymmetrie der Strukturverteilung.

In Tests hat sich herausgestellt, daß eine Anpassung der Gitterkonstanten g_x und g_y (in diesem Fall gilt $g_x = g_y$, Überlappungsfaktor $f = 1$) an die Läsionsgröße zu einer Verbesserung der Separierfähigkeit des Merkmals führt. Dabei wird zur Berechnung der Gitterkonstanten eine minimale Läsionsfläche von 3000 und eine maximale Läsionsfläche von 200000 Pixeln angenommen. Für die minimale Läsionsfläche wird eine Gitterkonstante von 40 und bei der maximalen eine Gitterkonstante von 80 Pixeln verwendet. Der Zwischenbereich wird linear interpoliert. Diese Parameter wurden in kurzen Testreihen bestimmt.

Um eine quantitative strukturelle Beschreibung v_{AS}^j der durch ein Gitterelement j abgedeckten Läsionsfläche zu erhalten, wird zu seiner Berechnung der Mittelwert aller n im Gitterelement G_j enthaltenen und zur Läsion gehörigen Skalierungsindizes gebildet (p_k symbolisiert das Pixel k aus dem Gitterelement j):

$$v_{AS}^j = \frac{1}{n} \sum_{k=1}^n \alpha^f(p_k, r_1, r_2) \quad (p_k \in G_j) \quad (8.2)$$

Dadurch wird die im Gitterelement dominante Struktur erfaßt. Zur Berechnung des Scores

$S_{S_G}^i$ bezüglich Symmetrieachse i wird nach Gleichung 3.10 (Seite 18) vorgegangen. Dazu werden mittels einer Funktion $s(v_{A_S}^j, v_{A_S}^{j'})$ die lokalen Gitterscores $v_{A_S}^j$ und deren achsensymmetrisches Pendant $v_{A_S}^{j'}$ zusammengefaßt. In Tests konnten mit dem Quadrat der Scoredifferenz gute Ergebnisse erzielt werden: $s(v_{A_S}^j, v_{A_S}^{j'}) = (v_{A_S}^j - v_{A_S}^{j'})^2$. Der Gesamtscore wird nach Gleichung 3.12 (Seite 18) gebildet:

$$S_{S_G} = \max(\{S_{S_G}^1, S_{S_G}^2\}) \quad (8.3)$$

Ergebnisse

In Abbildung 8.11 sind die Ergebnisse für den gesamten Datensatz dargestellt. Im linken Diagramm sind die Einzelscores geordnet für die MM (Sternchen-Symbole) und für die benignen MHV (Quadrat-Symbole) aufgetragen. Der Mittelwert der MM ist mit einem Wert von 0.00178 deutlich höher als der der benignen MHV (0.00081). Die Standardabweichungen der Scores der benignen MHV beträgt 0.00077, die der MM 0.0011. Der niedrigere Mittelwert der Scores der benignen MHV zusammen mit einer deutlich niedrigeren Standardabweichung bewirken einen relativ hohen Wert der AUC von 0.836. Der dem Optimum am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.815 und einer Spezifität von 0.745. Damit zeigt dieses Merkmal eine gute Separierfähigkeit.

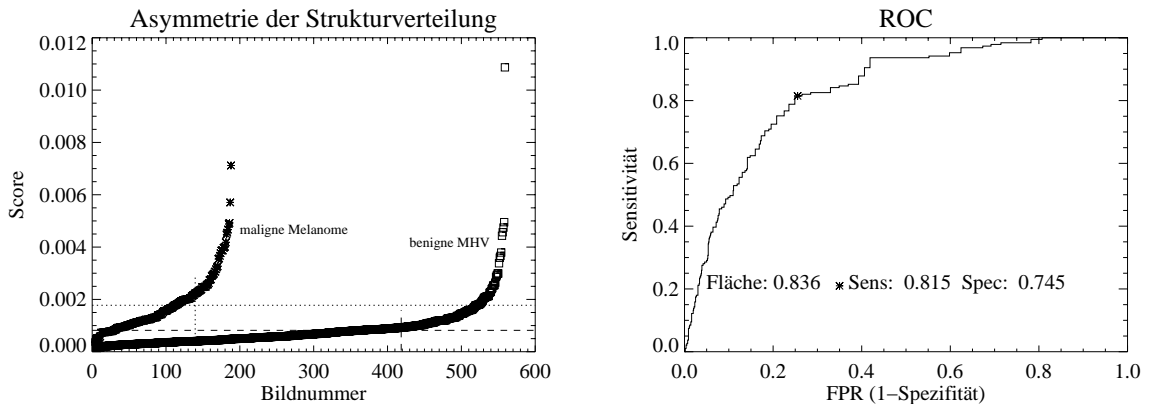


Abbildung 8.11: *Ergebnis der Quantifizierung der Asymmetrie der Strukturverteilung*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Die A-Komponente der dermatoskopischen ABCD-Regel, also die Beurteilung der Asymmetrie der Hautveränderung, hat mit 1.3 einen hohen Wert. Diese Bedeutung spiegelt sich in den guten Klassifikationswerten dieses Merkmals wider.

Visualisierung

Ziel der Visualisierung ist die farbliche Kennzeichnung des Unterschieds im strukturellen Aufbau der Läsion von Gitterelementen in achsensymmetrischer Lage. Daher werden die Gitterscores nur für eine Symmetriehälfte farblich aufbereitet. Um dem Dermatologen eine bessere Orientierungsmöglichkeit zu geben, soll die innere Struktur der Läsion erkennbar

bleiben. Dazu wird der strukturelle Aufbau der Läsion dadurch wiedergegeben, daß die Werte der Skalierungsindizes der Läsionspixel in Intensitätswerte transformiert werden.

Zur farblichen Kennzeichnung der Scoredifferenzen von Gitterelementen in achsensymmetrischer Lage wird eine Farbraumtransformation in den HLS-Farbraum (vgl. Abschnitt 6.1.2, Seite 74) vorgenommen. Die *hue*-Komponente (Farbton) des vom Gitterelement j abgedeckten Läsionsbereichs wird entsprechend der gewichteten Scoredifferenz $(v_{A_S}^j - v_{A_S}^{j'})^2$ angepaßt. Für den minimalen Wert (Differenz = 0) wird der Farbton Grün (entspricht $hue = 120$) und für sehr hohe Werte der Farbton Rot (entspricht $hue = 0$) gewählt. Der Zwischenbereich wird linear interpoliert. Die *lightness*-Komponente des Farbraums wird, da es sich um eine Struktureigenschaft handelt, mit den Skalierungsindizes belegt. Die *saturation*-Komponente der Läsionspixel wird auf die Konstante 0.5 gesetzt. Nach der Rücktransformation in den RGB-Raum werden als weitere Orientierungshilfen die Symmetrieachsen, das Gitternetz, die Kontur und der geometrische Schwerpunkt im Bild gekennzeichnet. Mit dieser Darstellung sollen die Gitterelemente schnell identifiziert werden können, die in besonderer Weise zu dem Gesamtscore beitragen.

In Abbildung 8.12 sind drei Läsionen als Originalbild (obere Reihe) und die dazugehörigen Visualisierungen (untere Reihe) dargestellt. Die Bilder sind so angeordnet, daß die Asymmetrie der Strukturverteilung von links nach rechts zunimmt. Die Visualisierung in der linken Spalte (entspricht einem niedrigen Gesamtscore) weist in fast allen Gitterelementen einen grünen Farbton auf, während einige Gitterelemente aus der Visualisierung der mittleren Spalte (entspricht einem mittleren Gesamtscore) einen gelblichen bzw. rötlichen Farbton haben. In der Darstellung des Ergebnisses zu dem Bild in der letzten Spalte (entspricht einem hohen Gesamtscore) sind einige Gitterelemente rot gekennzeichnet.




Abbildung 8.12: *Visualisierung der Asymmetrie der Strukturverteilung*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmender Asymmetrie. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.8 Berandung

Malignes Wachstumsverhalten findet in vielen Fällen lokalisiert und invasiv am Randbereich der Läsion statt. Diese neu gebildeten Regionen haben meist ein unterschiedliches Erscheinungsbild als das Läsionsinnere, wie es bei der rechten Hautveränderung in Abbildung 8.14 zu beobachten ist. Die Beschaffenheit des Läsionsrandes enthält also Informationen über die Dignität der Hautveränderung. Mit einem helligkeitsbasierten Bereichswachstumsverfahren wird der Randbereich der Läsion extrahiert und hinsichtlich seiner strukturellen Zusammensetzung und Homogenität quantitativ beurteilt.

Ansätze aus der Literatur

In den meisten aus der Literatur bekannten Ansätzen wird der Randbereich nicht berücksichtigt. Schindewolf et al. [SSA⁺93a] bilden um die Läsionskontur einen Bereich fester Breite, der anhand verschiedener Farbmerkmale charakterisiert wird. Die Konstruktion des Randbereichs ist allerdings nicht von lokalen Eigenschaften der Läsion abhängig. Andere Autoren ([GMM⁺94] [APB⁺95] [GKESK97] [SPP98]) berechnen den Grauwertgradienten senkrecht zur Läsionskontur und versuchen so die Abruptheit des Übergangs von Läsion zur umgebenden Haut zu bestimmen. Dieser Ansatz berücksichtigt allerdings nur die Läsionskontur und ist somit stark abhängig von der Korrektheit der Segmentierung. Nachteilig kann sich auch die Rauschempfindlichkeit der Gradientenberechnung auswirken.

Verwendete Methode zur Extraktion des Randbereichs

Das unregelmäßige Wachstum am Läsionsrand führt dort im allgemeinen zu einem Wechsel von dunkleren und helleren Bereichen. Um diese Inhomogenitäten des Randbereichs zu extrahieren wird das homogenitätsorientierte Bereichswachstumsverfahren aus Abschnitt 5.1.1 (Seite 64) verwendet. Dazu wird zunächst das RGB-Farbbild in ein Grauwertbild transformiert und dieses zur Bildverbesserung mit einem Mittelwertfilter der Größe 3 geglättet. Mit der Kontur als Berandung-Startmenge werden adaptiv weitere Pixel in Abhängigkeit des Grauwerts der Berandungsmenge zugefügt. Da Hautveränderungen durch die Farbstoffeinlagerung dunkler sind als die umgebende Haut, wird durch das Auswahlkriterium die Helligkeit der Pixel berücksichtigt. Die maximale Breite der Berandung (Parameter n) wird mit 30 und die Selektivität des Auswahlkriteriums (Parameter p) mit 0.25 festgelegt. Diese Parameter haben sich in Testreihen als geeignet für die Separierfähigkeit erwiesen.

Im nachfolgenden wird auf die Quantifizierungs- und Visualisierungsergebnisse der strukturellen Zusammensetzung der Berandung und deren Homogenität eingegangen.

8.7.8.1 Strukturelle Zusammensetzung

Das verwendete Bereichswachstumsverfahren extrahiert insbesondere inhomogene Regionen der Berandung. Diejenigen Läsionsbereiche, die einen weniger akzentuierten Übergang zur umgebenden Haut aufweisen, sind im extrahierten Binärbild breiter und haben demnach eine flächige Struktur. Zur Quantifizierung der strukturellen Zusammensetzung des Randbereichs findet die Skalierungs-Index-Methode und ihre anisotrope Variante Anwendung.

Verwendete Methode

Die beabsichtigte Quantifizierung des Randbereichs als binäres Objekt wird mit dem Verfahren aus Abschnitt 5.1.2.1 (Seite 65) durchgeführt [PBD⁺98]. Dort wird der Randbereich mit der Skalierungs-Index-Methode analysiert und aus dieser strukturellen Beschreibung ein globales Maß für die strukturelle Zusammensetzung der Berandung abgeleitet. Der Datensatz wurde sowohl mit der isotropen als auch mit der rotationsinvarianten anisotropen Skalierungs-Index-Methode analysiert. Dabei wurden die Radien $r_1 = 5$ und $r_2 = 10$ verwendet, da sie sich in Tests an einem kleinen Datensatz als positiv für die Diskrimination der malignen und benignen melanozytären Hautveränderungen erwiesen haben. In diesen Tests wurde auch der Parameter $t_\alpha = 1.7$ für die isotrope und $t_\alpha = 0.6$ für die rotationsinvariante anisotrope Variante (Gleichungen 5.1 und 5.2, Seite 65) bestimmt. Durch diese Parameterwahl wird als Maß für die strukturelle Zusammensetzung der Anteil der flächigen Areale im Randbereich nach Gleichung 5.3 definiert. Mit der Höhe des resultierenden Scores steigt der Anteil an flächigen Regionen im Randbereich. Je höher also der Score ist, desto inhomogener ist der Übergang von Läsion zur Haut.

Ergebnisse

Die Analyseergebnisse für die isotrope Variante sind in der oberen Reihe von Abbildung 8.13 dargestellt. Die Scores für den gesamten Datensatz getrennt nach MM (Sternchen-Symbole) und benigne MHV (Quadrat-Symbole) sind im linken oberen Diagramm aufgetragen. Der Mittelwert der Scores für die MM beträgt 0.12 bei einer Standardabweichung von 0.06. Demgegenüber weisen die Quantifizierungswerte der benignen MHV einen Mittelwert von 0.06 bei einer Standardabweichung von 0.04 auf. Tendenziell haben also die MM einen größeren Score, was mit der erhöhten Berandungsinhomogenität zu erklären ist. Die ROC-Kurve (rechtes oberes Diagramm) besitzt eine AUC von 0.783. Der dem Optimum am nächsten gelegene Kurvenpunkt hat eine Sensitivität von 0.735 bei einer Spezifität von 0.739. Die Separierungsfähigkeit dieses Merkmals ist vergleichsweise schwächer ausgeprägt. Dies korrespondiert mit dem geringen Gewicht des Berandungsmerkmals in der dermatoskopischen ABCD-Regel von 0.1 (Seite 89), womit der Höchstbeitrag zum maximalen Gesamtscore 9% entspricht.

Die untere Reihe von Abbildung 8.13 zeigt die Ergebnisse der Quantifizierung mittels der rotationsinvarianten anisotropen Skalierungsindizes. Der Mittelwert der Scores der MM beträgt 0.392 (Standardabweichung: 0.138), der der benignen MHV 0.269 (Standardabweichung: 0.121). Auch hier gilt, daß sich zwar die Mittelwerte der beiden Klassen deutlich unterscheiden, aber die hohe Standardabweichungen zu einer relativ schlechten Separierungsfähigkeit führen. Die Fläche unter der ROC-Kurve beträgt 0.757 und der dem Optimum am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.757 und einer Spezifität von 0.686. Damit ähnelt die ermittelte Separierungsfähigkeit des Merkmals der isotropen Variante.

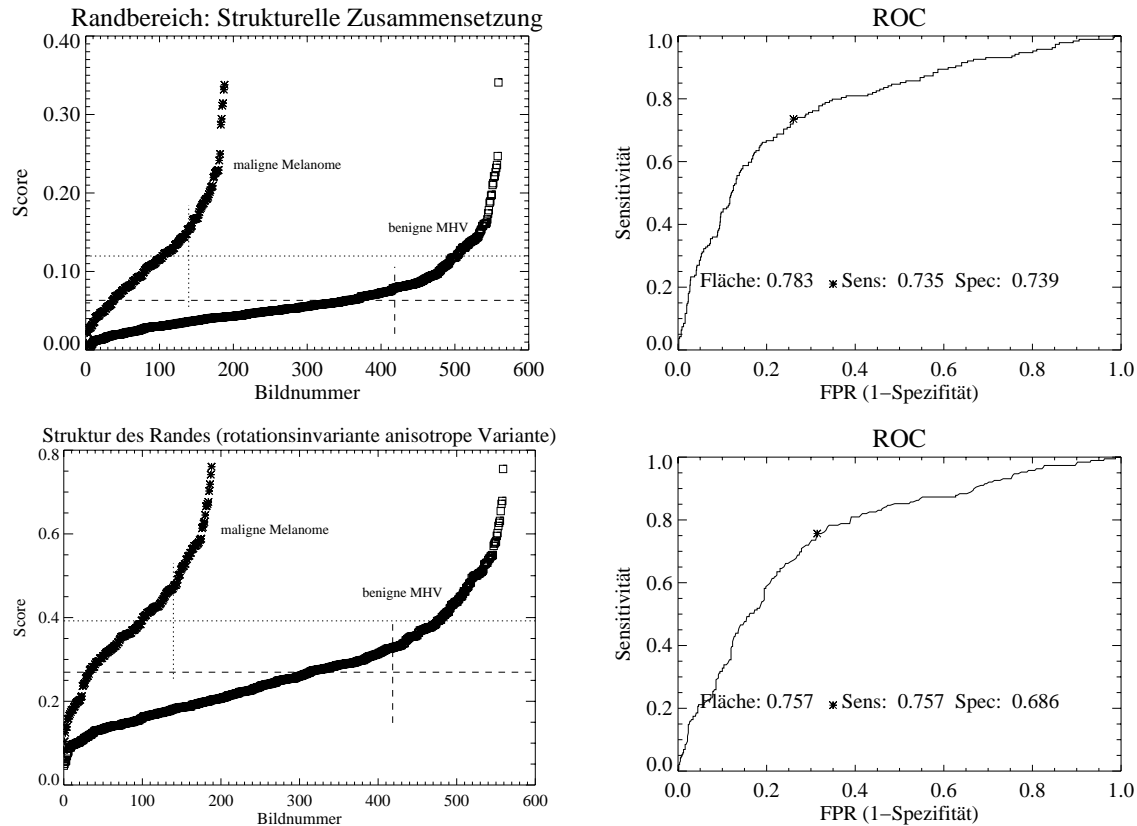


Abbildung 8.13: Ergebnis der Quantifizierung der strukturellen Zusammensetzung des Randbereichs: In der oberen Reihe sind die Ergebnisse der isotropen Variante und in der unteren Reihe die der rotationsinvarianten anisotropen Variante dargestellt. Linke Spalte: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechte Spalte: ROC-Kurve

Visualisierung

Mit der Visualisierung soll dargestellt werden, aus welchen strukturellen Komponenten sich der Randbereich zusammensetzt. Sie wird hier nur für die isotrope Variante beschrieben, lässt sich aber direkt auf die rotationsinvariante anisotrope Methode übertragen.

Zur Darstellung der strukturellen Eigenschaft der lokalen Umgebung, in der ein Randpixel eingebettet ist, wird der Skalierungsindex des Pixels farbkodiert. Die Farbtabelle verläuft mit steigendem Skalierungsindex von Grün zu Rot. In Abbildung 8.14 sind in der oberen Reihe drei melanozytäre Hautveränderungen dargestellt, mit von links nach rechts zunehmender Berandungsinhomogenität. Darunter sind die dazugehörigen Visualisierungen dieser Eigenschaft dargestellt. Im linken Bild ist der größte Anteil der Randpixel grün bis gelblich markiert. Rote Anteile sind unterrepräsentiert. Im mittleren Bild ist der rote Anteil deutlich größer geworden, während die Farbe Rot im rechten Bild dominiert. Dies korrespondiert mit dem visuellen Eindruck der Originalbilder.




Abbildung 8.14: *Visualisierung der strukturellen Beschreibung des Randbereichs*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmend unregelmäßig auslaufendem Randbereich. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.8.2 Homogenität der strukturellen Zusammensetzung

Im vorangegangenen Abschnitt wurde die strukturelle Zusammensetzung des Randbereichs quantifiziert. Nun soll die Homogenität der strukturellen Zusammensetzung des Randbereichs beurteilt werden. Der Score basiert ebenfalls auf der Skalierungs-Index-Methode, wobei sowohl die isotrope als auch die rotationsinvariante anisotrope Variante getestet wird.

Verwendete Methode

Grundlage der Quantifizierung ist das in Abschnitt 5.1.2.2 (Seite 66) beschriebene Verfahren. Darin wird der Randbereich in disjunkte Teilbereiche aufgeteilt. Aus der Variation der Scores zur strukturellen Beschreibung dieser Teilbereiche wird ein Maß für die Homogenität der strukturellen Zusammensetzung der Berandungen abgeleitet.

Erster Schritt dieser Methode ist die Aufgliederung des Randbereichs in disjunkte Teilbereiche durch eine Voronoi-Zerlegung. Voraussetzung dafür ist die Bestimmung einer Menge A von Randpixeln, zu denen die Voronoi-Gebiete bestimmt werden. Dazu wird entlang der Läsionskontur jedes n -te Pixel selektiert (längenorientierte Initialisierung, vgl. Abschnitt 5.1.2.2, Seite 66). n wird in Abhängigkeit der Läsionsgröße bestimmt. In verschiedenen Tests an einem kleinen Datensatz hat sich herausgestellt, daß mit $n = 50$ bei einer minimalen Läsionsgröße von 3000 Pixeln und mit $n = 100$ bei einer maximalen Läsionsgröße von 200000 Pixeln und einer linearen Interpolation zwischen diesen beiden Stützpunkten gute Ergebnisse erreicht werden können. Mittels der so bestimmten Menge A wird die Voronoi-Aufteilung vorgenommen.

Basierend auf den Skalierungsindizes der Randbereichspixel aus dem vorgehenden Abschnitt wird die strukturelle Zusammensetzung für jedes Voronoi-Gebiet bestimmt (vgl. Gleichung 5.6, Seite 67). Der Score zur Beurteilung der Homogenität wird nach Gleichung 5.7 gebildet. Untersucht wurden die Ergebnisse, die mittels der isotropen und der rotationsinvarianten anisotropen Skalierungs-Index-Methode erzielt wurden.

Ergebnisse

Zunächst sollen die Ergebnisse beschrieben werden, die auf der strukturellen Beschreibung des Randes mit der isotropen Skalierungs-Index-Methode beruhen. Die zugehörigen Diagramme bilden die obere Reihe von Abbildung 8.15. Die Scores der untersuchten Hautveränderungen sind im linken oberen Teil der Abbildung getrennt nach MM (Sternchen-Symbole) und benigne MHV (Quadrat-Symbole) aufgetragen. Der Mittelwert der Scores der MM ist mit 0.010 deutlich größer als der der benignen MHV mit 0.004. Allerdings ist die Standardabweichung der Scores der MM mit 0.008 gegenüber den benignen MHV mit 0.005 fast zweimal so hoch und drückt unter Berücksichtigung des Mittelwerts eine relativ starke Überschneidung dieser Verteilung mit derjenigen der benignen MHV aus. Diese Beobachtung bestätigt sich bei der Betrachtung der ROC-Kurve (rechter oberer Teil der Abbildung 8.15), deren AUC 0.797 beträgt. Der Optimalpunkt liegt bei einer Sensitivität von 0.709 und einer Spezifität von 0.779. Wie bei der Beurteilung der strukturellen Zusammensetzung des Randbereichs zeigt auch dieses Merkmal eine geringere Separierfähigkeit.

Analog zu den Ergebnissen bei der strukturellen Beschreibung des Randes weist die Separierfähigkeit der Scores, die auf der rotationsinvarianten anisotropen Charakterisierung des Randes beruhen, eine ähnliche Qualität auf. Die Ergebnisse bilden die untere Reihe von

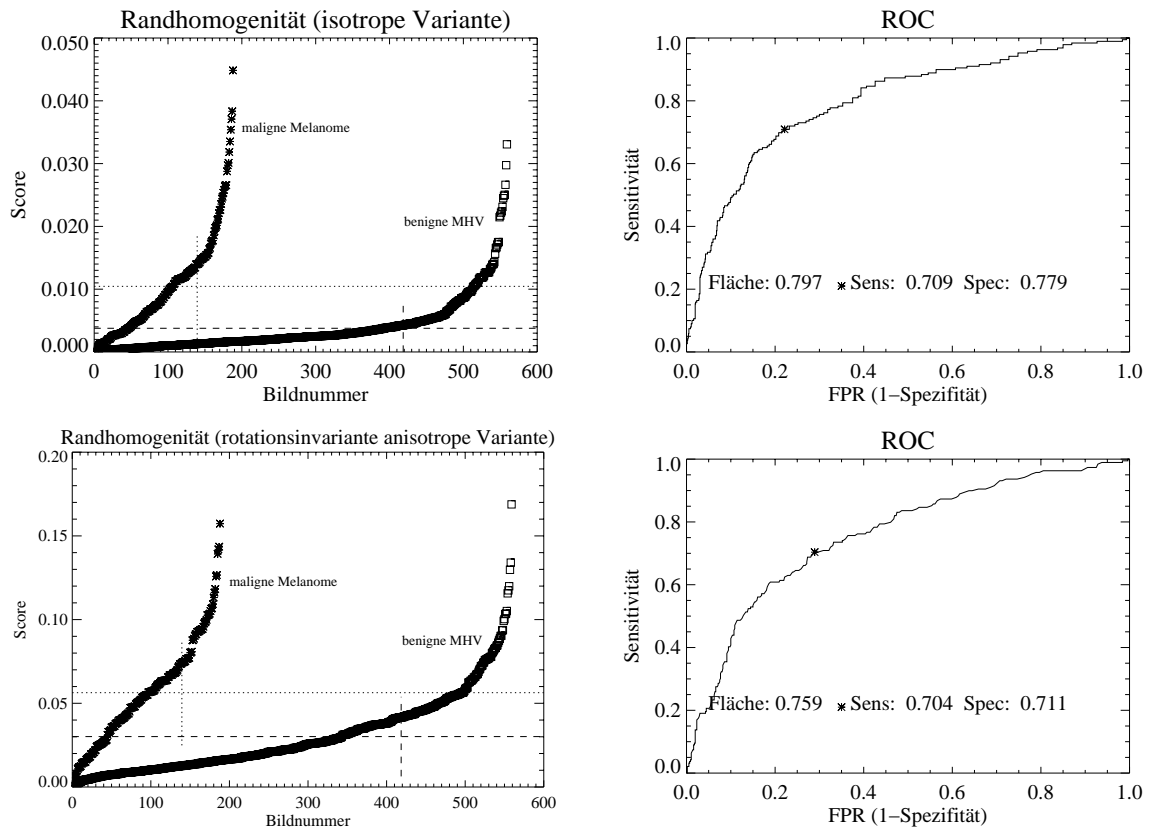


Abbildung 8.15: *Ergebnis der Quantifizierung der Homogenität der strukturellen Zusammensetzung des Randbereichs:* In der oberen Reihe sind die Ergebnisse der isotropen Variante und in der unteren Reihe die der rotationsinvarianten anisotropen Variante dargestellt. Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Abbildung 8.15. Die Mittelwerte der Scores der MM haben den Wert 0.056 bei einer relativ hohen Standardabweichung von 0.032. Die Scores der benignen MHV haben tendenziell einen geringeren Wert (Mittelwert 0.03, Standardabweichung 0.024). Vor allem die hohe Standardabweichung der Scores der MM führt wie bei der isotropen Variante zu einer vergleichsweise weniger guten Trennung. Die Fläche unter der ROC-Kurve beträgt 0.759. Der dem Optimum am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.704 und einer Spezifität von 0.711.

Visualisierung

Wie auch bei der Darstellung der Visualisierung der strukturellen Beschreibung des Randbereichs wird hier nur die Visualisierung beschrieben, die auf der isotropen Skalierungs-Index-Methode beruht, da sich diese für die rotationsinvariante anisotrope Variante analog formulieren lässt.

Ziel der Visualisierung ist die Darstellung der Abweichung der lokalen Scores der Voronoi-Gebiete vom Mittelwert. Dazu wird die Differenz dieser beiden Werte farbkodiert. Die Farbta-

belle wurde so gewählt, daß dem Mittelwert die Farbe Grün zugeordnet wird. Abweichungen des Scores nach oben, also ein im Durchschnitt eher flächiger Teilbereich, werden in einem zunehmend roten Farbton dargestellt. Pixelregionen mit unterdurchschnittlichem Score werden bläulich gekennzeichnet. Abbildung 8.16 zeigt die dermatoskopischen Aufnahmen (obere Reihe) und die Visualisierungen der Ergebnisse (untere Reihe). Die Homogenität der Berandung nimmt dabei von links nach rechts ab. Dies ist auch in der Visualisierung zu erkennen. Im linken Bild, also der bezüglich der Berandung homogensten Läsion, herrscht ein türkis-grüner Farbton vor. Das mittlere Bild weist blaue sowie gelbe Areale auf, die auf eine erhöhte Inhomogenität hinweisen. Im rechten Bild dominieren blaue und rote Areale den Randbereich. Dies korrespondiert mit dem optischen Eindruck des Randverlaufs beim Originalbild.




Abbildung 8.16: *Visualisierung der Homogenität der strukturellen Beschreibung des Randbereichs:* In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmender Inhomogenität des Randbereichs. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

Auswahl der zu verwendenden Variante

In den zwei vorangegangenen Abschnitten wurden die Merkmale “Strukturelle Beschreibung” und “Homogenität” des Randbereichs sowohl mit der isotropen als auch mit der rotationsinvarianten anisotropen Skalierungs-Index-Methode quantifiziert. In den folgenden Zeilen soll erörtert werden, inwieweit die Ergebnisse beider Verfahren bei dieser konkreten Anwendung redundant sind. Um wie bei der Auswertung der Klassifikationseigenschaften (vgl.

Abschnitt 8.8) eine Trennung von Trainings- und Testdaten vorzunehmen, wird auf den Datensatz von 120 melanozytären Hautveränderungen zurückgegriffen, der zur Optimierung der Algorithmen verwendet wurde (vgl. Seite 99). Mit diesem kleineren Datensatz wurden folgende Resultate erzielt:

Verfahren	AUC	Sensitivität	Spezifität
Strukturelle Beschreibung (isotrop)	0.812	0.800	0.800
Strukturelle Beschreibung (anisotrop)	0.776	0.833	0.717
Homogenität (isotrop)	0.836	0.750	0.850
Homogenität (anisotrop)	0.799	0.767	0.717

Aus dieser Tabelle wird ersichtlich, daß mit der isotropen Variante bei beiden Merkmalen etwas bessere Ergebnisse im Sinne der Separierbarkeit der beiden Klassen erzielt werden.

Bei näherer Untersuchung der Scores der isotropen und anisotropen Variante bezüglich des Merkmals “Strukturelle Beschreibung” stellt man einen linearen Korrelationskoeffizient von 0.951 fest. Bei Merkmal “Homogenität” beträgt er 0.948.

Bei dieser Anwendung erzielt man mit der rotationsinvarianten anisotropen Skalierungs-Index-Methode also keinen weiteren für die Klassifikation relevanten Informationsgewinn. Weiterhin läßt sich in Betracht ziehen, daß der Rechenaufwand für das anisotrope Verfahren durch die notwendigen Rotationen erheblich höher ist. Daher wird in den weiteren Betrachtungen zur Problematik der Hautkrebsfrüherkennung nur noch die isotrope Variante verwendet.

8.7.9 Krümmung der Kontur

Maligne Melanome breiten sich oft aggressiv horizontal in die umgebende Haut aus. Dieses inhomogene Wachstumsverhalten läßt die Kontur der Hautveränderung unregelmäßig verlaufen. In diesem Abschnitt wird untersucht, inwieweit sich diese Eigenschaft zur Unterscheidung von benignen und malignen melanozytären Hautveränderungen eignet. Dieses Merkmal ist nicht Bestandteil der dermatoskopischen ABCD-Regel.

Ansätze aus der Literatur

Seidenari et al. [SBD⁺95] und Claridge et al. [CHKA92] bestimmen zur Charakterisierung der Kontur deren fraktale Dimension (FD). Die letztgenannte Autorengruppe unterscheidet genauer zwischen textureller und struktureller FD. Mit der texturellen FD werden feine Unregelmäßigkeiten der Kontur beschrieben, während mit der strukturellen FD die Kontur auf einer größeren Skala charakterisiert wird. Die Autoren schließen aus ihren Daten, daß die strukturelle FD eine bessere Unterscheidung der beiden Klassen erlaubt. Da aber die FD ein globales Maß für die Kontur darstellt, läßt sie sich schwer visualisieren.

Schindewolf et al. ([SSA⁺93a] [HSS⁺94]) verwenden die Fourier-Transformation zur Bestimmung der Konturregelmäßigkeit. Ähnlich wie bei der fraktalen Dimension hat dieses Vorgehen den Nachteil, daß die Visualisierung des Ergebnisses schwer möglich ist.

Gutkowicz-Krusin et al. [GKESK97] messen die Regelmäßigkeit der Kontur, indem sie Verteilung der Abstände zwischen den Konturpixeln und dem geometrischen Schwerpunkt charakterisieren. Dieses Verfahren läßt sich visuell gut darstellen, hat aber den Nachteil, daß es bei jedem Konturpixel seine Nachbarpixel nicht betrachtet und so die lokale Richtung der Kontur nicht berücksichtigt. Daher findet in dieser Arbeit ein Verfahren Verwendung, das auch die Nachbarn eines Konturpixels miteinbezieht und den lokalen Verlauf der Kontur charakterisiert.

Verwendete Methode

Um die Regelmäßigkeit des Konturverlaufs zu quantitativ zu beschreiben, wird das Verfahren aus Abschnitt 5.2 (Seite 70) verwendet, das sich auf ein Krümmungsmaß abstützt. Bei einem annähernd runden Konturverlauf hat das Krümmungsmaß zu den einzelnen Pixeln einen ähnlichen Wert. Mit abnehmender Regelmäßigkeit unterscheiden sich die lokalen Krümmungen. Dieses Verhalten findet in der Verteilung der Krümmungsmaße seinen Ausdruck.

Die Krümmung zu einem Konturpixel wird durch die gewichtete Summe der Richtungsabweichungen von n aufeinanderfolgenden Konturpixeln bestimmt (vgl. Gleichung 5.10). Da sich die Skala, auf der der Konturverlauf variiert, mit der Größe der Läsion verändert, wird die Anzahl der Nachbarpixel zur Berechnung der lokalen Krümmung in Abhängigkeit von der Läsionsgröße gestellt. Bei einer angenommenen minimalen Läsionsgröße von 3000 Pixeln wird $n = 50$ und bei einer angenommenen maximalen Läsionsgröße von 200000 Pixeln wird $n = 100$ verwendet. Der Bereich zwischen diesen beiden Stützstellen wird durch lineare Interpolation bestimmt. Diese Parameter haben sich an einem Testdatensatz bewährt. Die so berechneten Krümmungswerte werden in der relativen Häufigkeitsverteilung zusammengefaßt. Die Berechnung des Histogramms wird bei einer Bingröße von 0.00025 durchgeführt, da der Wertebereich der lokalen Krümmungen nur ein kleines Intervall überdeckt und sich diese feine Abstufung in kurzen Tests vorteilhaft für die Unterscheidung der Klassen der benignen und malignen

melanozytären Hautveränderungen gezeigt hat. Der Gesamtscore zu diesem Merkmal wird nach Gleichung 5.12 (Seite 71) durch ein Entropiemaß bestimmt.

Ergebnisse

Im linken Teil von Abbildung 8.17 sind die Quantifizierungsergebnisse für den gesamten Datensatz aufgetragen (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Der Mittelwert der MM beträgt 4.48 bei einer Standardabweichung von 0.41. Demgegenüber beträgt der Mittelwert der benignen MHV 3.98 bei einer Standardabweichung von 0.420. Die Mittelwerte der beiden Klassen zeigen eine deutliche Trennung, die Standardabweichung der benignen melanozytären Hautveränderungen ist jedoch sehr hoch. Diese Daten erklären die vergleichsweise schlechte Klassenseparierung. Die AUC beträgt 0.808 und der dem Optimalpunkt am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.767 und einer Spezifität von 0.725.

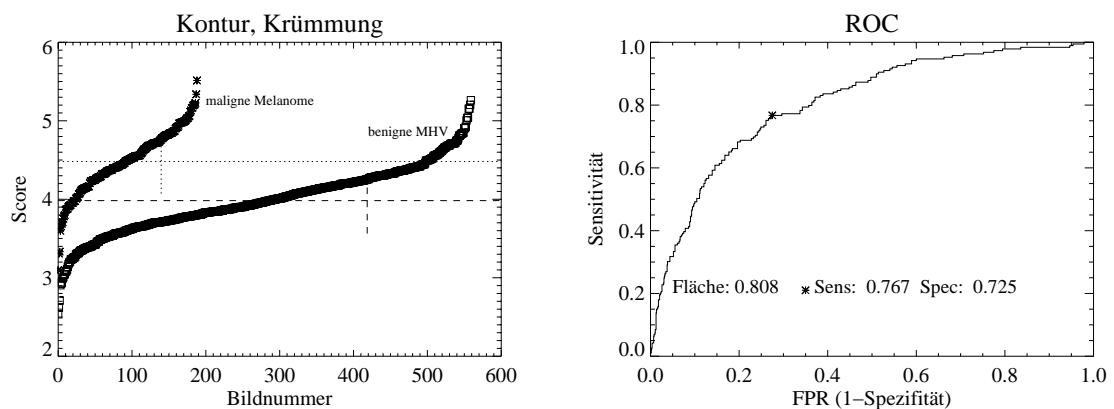


Abbildung 8.17: *Ergebnis der Quantifizierung des Konturverlaufs*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Visualisierung

Ziel der Visualisierung ist die graphische Umsetzung der einzelnen berechneten Krümmungswerte durch Falschfarben. Der Score dieses Merkmals spiegelt sich in der Vielfalt der Falschfarben wieder.

Die Bestimmung der Falschfarben erfolgt durch Abbildung des Krümmungswertes auf eine Farbskala, die von rot über grün zu blau verläuft. Hohe negative Werte werden rot und hohe positive Werte blau kodiert. Der Zwischenbereich wird mit grüner Farbe gekennzeichnet. Beispiele zur Visualisierung dieses Merkmals sind in Abbildung 8.18 abgebildet. Die Unregelmäßigkeit des Konturverlaufs nimmt von der linken über die mittlere zur rechten Spalte zu. Während bei der Visualisierung des linken Beispiels die Kontur überwiegend grün markiert ist, kommen im mittleren Bild mehr rote und auch blaue Farben hinzu. In der rechts abgebildeten Visualisierung (hoher Score) setzt sich dieser Trend noch verstärkt fort.




Abbildung 8.18: *Visualisierung der Konturkrümmungen*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmender Unregelmäßigkeit des Konturverlaufs. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.10 Homogenität der Kontur

Das horizontale maligne Wachstum erfolgt meist ungleichmäßig. Daher ist wie bei der Betrachtung der Berandung neben dem Konturverlauf auch die Homogenität des Verlaufs von Interesse. Inhalt dieses Abschnitts ist also die Bestimmung der Homogenität bezüglich der Regelmäßigkeit des Konturverlaufs. Bei der Quantifizierung dieser Eigenschaft wird auf das Krümmungsmaß (vgl. Abschnitt 8.7.9) zurückgegriffen.

Ansätze aus der Literatur

Dem Autor sind keine Arbeiten bekannt, die sich mit der Homogenität des Konturverlaufs beschäftigen.

Verwendete Methode

Zur Bestimmung der Homogenität des Konturverlaufs findet das in Abschnitt 8.7.9 berechnete Krümmungsmaß auch hier Verwendung. Grundlage des Verfahrens ist die Aufteilung der Kontur in disjunkte zusammenhängende Bereiche wie in Abschnitt 5.1.2.2 (Seite 66, längenorientierte Variante). Diese Unterbereiche werden bezüglich ihres Verlaufs ähnlich wie in Abschnitt 8.7.9 lokal charakterisiert. Bei der Berechnung der relativen Häufigkeitsverteilung findet eine größere Binggröße von 0.001 Verwendung, da mit diesem Wert in kurzen Tests bessere Ergebnisse erreicht werden konnten. Die Homogenität des Konturverlaufs wird mittels der Standardabweichung dieser lokalen Scores quantifiziert.

Die Unterbereiche werden bestimmt, indem die Kontur in je $(2 \cdot n + 1)$ Pixel große Segmente aufgeteilt wird. Um die unterschiedlichen Größen der Läsionen auszugleichen, wird der Parameter n an jede Hautveränderung angepaßt. Bei einer angenommenen minimalen Läsionsgröße von 3000 Pixeln wird $n = 30$ und bei einer angenommenen maximalen Läsionsgröße von 200000 Pixeln wird $n = 70$ verwendet. Der Bereich zwischen diesen beiden Stützstellen wird durch lineare Interpolation bestimmt. Diese Parameter haben sich an einem Datensatz bewährt.

Ergebnisse

Das Ergebnis der Quantifizierungen für den gesamten Datensatz ist in Abbildung 8.19 dargestellt. Im linken Teil der Abbildung sind die Scores für die MM (Sternchen-Symbole) und für die benignen MHV (Quadrat-Symbole) aufgetragen. Der Mittelwert für die MM beträgt 0.480 (Standardabweichung: 0.104) und für die benignen MHV 0.412 (Standardabweichung: 0.106). Da die Mittelwerte sich nicht deutlich unterscheiden und die Standardabweichungen relativ hohe Werte aufweisen, ist mit diesem Merkmal nur eine vergleichsweise schlechte Trennung möglich. Dies reflektiert sich in der rechts abgebildeten ROC-Kurve, bei der die AUC 0.680 beträgt. Der dem Optimalpunkt am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.619 und bei einer Spezifität von 0.679.

Visualisierung

Die Visualisierung dieses Merkmals soll signalisieren, inwieweit sich die Krümmungseigenschaften zwischen den einzelnen Kontursegmenten unterscheiden. Dazu wird zunächst der Mittelwert der den Segmenten zugeordneten Scores bestimmt. Als quantitativer Wert, der den Scoreunterschied der Kontursegmente wiedergibt, findet die Differenz zwischen dem Mittelwert und dem lokalen Score Verwendung. Diese Differenz wird auf eine Falschfarbenskala

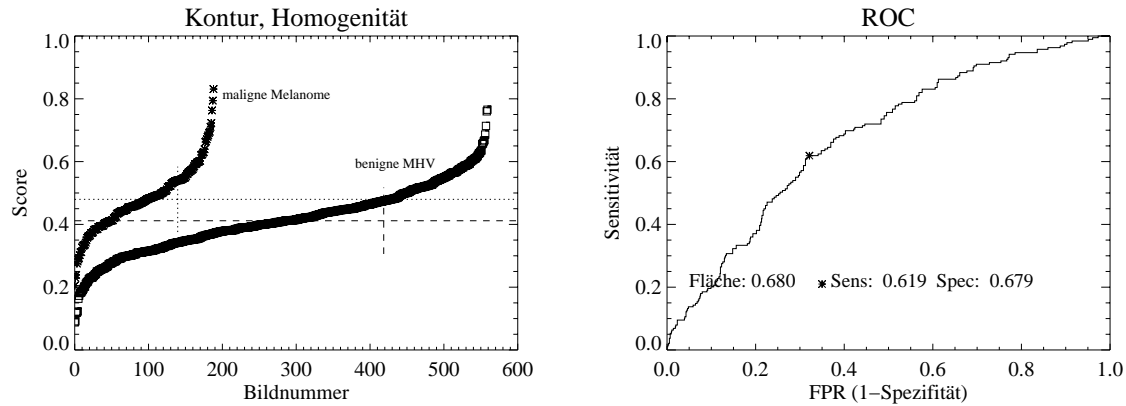


Abbildung 8.19: *Ergebnis der Quantifizierung der Homogenität des Konturverlaufs*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

abgebildet. Kontursegmente, deren Score deutlich kleiner als der Mittelwert ist, werden rötlich dargestellt, während im umgekehrten Fall das Kontursegment bläulich gekennzeichnet wird. Liegt der lokale Score unmittelbar um den Mittelwert, so wird das Kontursegment grün markiert.

Für drei verschiedene Läsionen sind die dazugehörigen Visualisierungen in Abbildung 8.20 dargestellt. Die Läsionen sind so geordnet, daß die Homogenität des Konturverlaufs von links nach rechts abnimmt. Der Konturverlauf der linken Hautveränderung bleibt relativ konstant, so daß in der Visualisierung nur grüne Farbtöne zu finden sind. Der Konturverlauf der mittleren Läsion ist zweigeteilt: er ist in der rechten Bildhälfte unregelmäßiger. Dementsprechend finden sich weniger grün markierte Kontursegmente. Die stärkste Inhomogenität ist in der rechten Abbildung zu finden. Dies spiegelt sich in einem hohen Anteil an rot und blau gefärbten Kontursegmenten wider.




Abbildung 8.20: *Visualisierung der Homogenität des Konturverlaufs*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts abnehmender Homogenität. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.11 Farbvielfalt

Melanozytäre Wachstumsprozesse reflektieren sich, wie in Abschnitt 8.7.6 dargestellt, in einer erhöhten Anzahl beobachtbarer Farbtöne. Durch vertikales Wachstum wird besonders beim malignen Melanom das Melanin in verschiedenen Hautschichten angereichert. Über den Zusammenhang zwischen der Tiefe, in der das Melanin eingelagert ist, und der Oberflächenfärbung erklärt sich die erhöhte Farbvielfalt. Zusätzlich kommen durch immunologische Vorgänge partielle Rückbildungen vor, die zu weißen Tönen führen, sowie Gefäßneubildungen, die ihren Ausdruck in rötlichen Farbtönen findet.

Ansätze aus der Literatur

In der Literatur finden sich mehrere Ansätze zur Lösung des Problems der Bestimmung der Farbvielfalt bei melanozytären Hautveränderungen. Umbaugh et al. beschreiben zwei Methoden mit dem Ziel einer binären, also qualitativen Entscheidung, ob eine Hautveränderung ein bestimmtes Mindestmaß an Vielfarbigkeit überschreitet. Es werden Entscheidungsbäume [UMS91] und neuronale Netzwerke verwendet [DSC⁺93]. Als Merkmale werden unter anderem die durchschnittlichen Werte von Rot, Grün und Blau und Messungen in transformierten Farbräumen verwendet. Auch bei anderen Autoren (vgl. Abschnitt 8.4) finden zur Beschreibung der Farbvielfalt Mittelwert und Varianz der Grauwerte der einzelnen Farbkanäle Anwendung. Die resultierende Merkmalsanzahl erschwert erheblich die Nachvollziehbarkeit des Ergebnisses. So schreibt Umbaugh bei seinem regelbasierten Ansatz ausdrücklich, daß dabei ein System entstehen kann, das der menschliche Experte nicht vollständig versteht [UMS91].

Verwendete Methode

Zur Quantifizierung der Farbvielfalt findet das in Abschnitt 6.2 (Seite 75) beschriebene Verfahren Verwendung [PBD⁺99]. Die Methode benutzt als Maß die Entropie der relativen Farbhäufigkeiten. Als Farbraum hat sich in verschiedenen Tests der HLS-Farbraum als geeignet erwiesen. Weiterer Grund für diese Wahl ist die Darstellung von Farbe in Begriffen, die der menschlichen Wahrnehmung nahekommen. In diesem Farbraum wird die relative Häufigkeitsverteilung der Farben von Läsionspixel berechnet. Dazu muß der Farbraum partitioniert werden, wobei eine homogene Partitionierung bei einer Granularität von einem Hundertstel des möglichen Wertebereichs der einzelnen Farbachsen vorgenommen wurde. Dieser Wert wurde in kurzen Tests ermittelt, die die Maximierung der Separierfähigkeit dieses Merkmals zum Ziel hatten. Für jede Hautveränderung wurde die Farbvielfalt C_V nach Gleichung 6.1 (Seite 76) berechnet.

Ergebnisse

Das Ergebnis der Quantifizierungen für die Farbvielfalt ist in Abbildung 8.21 zu sehen. Im linken Teil der Abbildung sind die Scores geordnet nach Wert und getrennt nach benignen (Quadrat-Symbole) und malignen (Sternchen-Symbole) Hautveränderungen eingezeichnet. Die horizontalen Linien zeigen den jeweiligen Mittelwert an. Er beträgt bei den MM 7.48 und bei den benignen MHV 6.35. Die eingezeichneten vertikalen Linien symbolisieren die Standardabweichungen. Bei den MM beträgt sie 0.57 und bei den benignen MHV 0.56. Dieses Merkmal läßt eine gute Separierung der beiden Klassen erwarten, da sich die Mittelwerte deutlich unterscheiden und die Standardabweichungen relativ gering sind. Diese Annahme

bestätigt sich im rechten Teil der Abbildung, in der die ROC-Kurve dargestellt ist. Die AUC beträgt 0.923 und der dem Optimalpunkt am nächsten gelegene Kurvenpunkt hat eine Sensitivität von 0.857 bei einer Spezifität von 0.830.




Abbildung 8.21: *Ergebnis der Quantifizierung der Farbvielfalt*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Die Ergebnisse bestätigen deutlich die Aussage der klinischen dermatoskopischen ABCD-Regel, bei der die Farbvielfalt ein hohes Gewicht besitzt.

Visualisierung

Die Visualisierung soll die Vielfalt der Farben erkennbar anzeigen. Dazu wurde die Technik der Falschfarbendarstellung der Farbwerte der einzelnen Läsionspixel gewählt, da durch sie eine gute visuelle Nachvollziehbarkeit bei gleichzeitiger Differenzierung auch feiner Farbtonunterschiede möglich wird. Es hat sich bei der Evaluierung der Visualisierung durch Dermatologen als ausreichend für die Nachvollziehbarkeit erwiesen, bei der graphischen Aufbereitung des Scores nur die *hue*-Komponente (Farbton) des HLS-Farbraums zu verwenden. Die Beobachtung, daß die bei melanozytären Hautveränderungen auftretenden Farben nur ein bestimmtes Intervall der *hue*-Achse belegen, kann zur Konstruktion einer *look-up*-Tabelle verwendet werden, die nur den tatsächlich belegten Bereich nutzt und somit eine deutliche Unterscheidbarkeit auch ähnlicher Farbtöne erlaubt.

In Abbildung 8.22 ist das Ergebnis der Visualisierung für drei melanozytäre Hautveränderungen zu sehen. In der oberen Reihe sind die Originalbilder dargestellt, darunter die zugehörige graphische Aufbereitung. Die Bilder sind nach zunehmender Farbvielfalt von links nach rechts angeordnet. Die linke Läsion zeigt in der Visualisierung neben einigen blau gefärbten Pixeln hauptsächlich grüne Farbtöne. Die erhöhte Farbvielfalt wird bei der mittleren Läsion durch große grün und blau gefärbte Areale dargestellt. Zusätzlich sind noch einige rötliche Bereiche zu erkennen. Eine weitere Auffächerung des dargestellten Falschfarbenspektrums ist in der rechten Visualisierung deutlich zu erkennen. Dies korrespondiert mit einem hohen Score der Farbvielfalt und dem visuellen Eindruck der Hautveränderung.




Abbildung 8.22: *Visualisierung der Farbvielfalt*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmender Farbvielfalt. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.12 Farbhomogenität

Neben der Farbvielfalt ist auch die Verteilung der Farben über die Läsion hinweg zu beurteilen. Durch das maligne Wachstum in sowohl vertikaler als auch horizontaler Richtung entsteht eine inhomogene Farbverteilung (vgl. Abschnitt 8.7.11). Dieses Merkmal ist nicht expliziter Bestandteil der dermatoskopischen ABCD-Regel.

Ansätze aus der Literatur

In der Literatur finden sich wenige Beispiele zur Quantifizierung der Farbhomogenität. Dies ist vielleicht darauf zurückzuführen, daß dieses Merkmal in der ABCD-Regel nicht berücksichtigt wird. Gutkowitz-Krusin et al. [GKESK97] vermerken zwar, daß die räumliche Verteilung der Farben das vielversprechendste Farbmerkmal sei, geben allerdings keinen Hinweis auf die Durchführung der Quantifizierung. Seidenari et al. [SPP98] berechnen Werte zur Beschreibung der "Verteilung dunkler Gebiete innerhalb der Läsion" mittels Momente verschiedener Ordnungen. Eine Definition des Begriffs "dunkle Gebiete" wird nicht angegeben.

Verwendete Methode

Die Eigenschaft der Farbhomogenität wird mittels des Verfahrens aus Abschnitt 6.3 (Seite 77) quantifiziert [PBD⁺99]. Die Läsion wird dazu gitterartig aufgeteilt und für jedes Gitterelement lokal die Farbvielfalt wie in Abschnitt 8.7.11 bestimmt. Aus der Variation dieser lokalen Scores in den verschiedenen Gitterelementen wird ein globales Maß für die Homogenität der Farbverteilung abgeleitet. Zunächst wird also die Läsion mit einem regelmäßigen Gitter überzogen (für die Gitterkonstanten gilt: $g_x = g_y$; Überlappungsfaktor $f = 1$). Um den Einfluß unterschiedlicher Läsionsgrößen auszugleichen, wird die Gitterkonstante in Abhängigkeit der Objektgröße gewählt (vgl. Seite 14). Dazu wird bei einer angenommenen minimalen Objektgröße von 3000 Pixeln eine Gitterkonstante von 40 Pixel und bei einer angenommenen maximalen Objektgröße von 200000 Pixeln eine Gitterkonstante von 80 Pixel verwendet. Der Bereich zwischen diesen beiden Stützstellen wird linear interpoliert. Diese Parameter haben sich bei einem Testdatensatz als günstig für die Klassifikation erwiesen. Für jedes der Gitterelemente wird die lokale Farbvielfalt nach Gleichung 6.2 berechnet. Da in den Gitterelementen relativ wenig Läsionspixel vorhanden sind, werden zur Bestimmung der dreidimensionalen Farbhäufigkeitsverteilung die Koordinatenachsen des Farbraums mit einem Fünffzigstel des möglichen Wertebereichs stärker diskretisiert als bei der Berechnung der Farbvielfalt. Mit diesem Wert konnte in kurzen Tests die beste Separierfähigkeit erreicht werden. Die lokalen Scores werden nach Gleichung 6.3 zu einem Gesamtscore zusammengefaßt.

Ergebnisse

In Abbildung 8.23 sind die Ergebnisse der Quantifizierungen dieses Merkmals dargestellt. Im linken Diagramm sind die einzelnen Scores geordnet und nach MM und benignen MHV getrennt aufgetragen. Deutlich zu erkennen ist der tendenziell höhere Wert bei den MM. Der Mittelwert beträgt 0.18 bei einer Standardabweichung von 0.120. Demgegenüber weisen die benignen MHV bei diesem Score einen Mittelwert von 0.09 auf, die Standardabweichung beträgt 0.060. Wie zu erwarten haben die MM einen deutlich höheren Mittelwert; er ist ungefähr doppelt so hoch wie bei den benignen MHV. Die Streuung der benignen MHV ist gegenüber den MM relativ gering. Dies wirkt sich positiv in der Qualität der ROC-Kurve aus,

die eine AUC von 0.803 aufweist. Der dem Optimum am nächsten gelegene Kurvenpunkt hat eine Sensitivität von 0.751 bei einer Spezifität von 0.725.




Abbildung 8.23: Ergebnis der Quantifizierung der Farbhomogenität: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Visualisierung

Durch die Visualisierung soll dargestellt werden, inwieweit sich die Scores für die Farbvielfalt der einzelnen Gitterelemente voneinander unterscheiden. Bei der Visualisierung wird für jedes Gitterelement die gewichtete Abweichung der lokalen Farbvielfalt vom Mittelwert auf eine Falschfarbenskala übertragen. Zur besseren Orientierung für den Dermatologen soll gleichzeitig die innere Struktur der Läsion weiterhin sichtbar sein.

Dazu findet der HLS-Farbraum (vgl. Seite 74) Verwendung, wobei seine einzelnen Komponenten gesondert behandelt werden. Zur Farbkodierung der Gitterscores wird die H-Komponente (*hue*, Farbton) in Abhängigkeit vom lokalen Score variiert. Diese Adaption läßt Gitterelemente mit Scores, die dem Mittelwert entsprechen, grünlich erscheinen, während die Gitterelemente mit geringeren Scores als der Mittelwert bläulich eingefärbt werden. Gitterelemente, deren Scores größer als der Mittelwert sind, werden rot markiert. Die L-Komponente (*lightness*, Helligkeit) wird nicht verändert, damit die Struktur des Bildes auch im Bereich der Läsion erhalten bleibt. Die S-Komponente (*saturation*, Sättigung) wird im Bereich der Läsion konstant auf den Wert 0.5 gesetzt und nicht weiter beeinflusst. Damit haben die Falschfarben zur Kodierung der Gitterscores dieselbe Sättigung. Schließlich werden noch die Läsionskontur und ihr geometrischer Schwerpunkt eingezeichnet.

Abbildung 8.24 zeigt in der oberen Reihe drei verschiedene melanozytäre Läsionen mit von links nach rechts abnehmender Homogenität der räumlichen Farbverteilung. Darunter sind die entsprechenden Visualisierungen dargestellt. Das linke Bild weist eine hohe Farbhomogenität auf. Dementsprechend sind in der Visualisierung die Gitterelemente grünlich eingefärbt. Die mittlere Abbildung hat einige rötlich und bläulich markierte Gitterelemente, was einer geringeren Farbhomogenität entspricht. Im rechten Bild ist die Farbverteilung innerhalb der Läsion sehr inhomogen, was durch eine Vielzahl an blau und rot eingefärbten Gitterelementen angezeigt wird.




Abbildung 8.24: *Visualisierung der Farbhomogenität*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts abnehmender Farbhomogenität. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.13 Strukturvielfalt

Malignes Wachstum führt oft zu einer Auflösung der regelmäßigen, für die benignen melanozytären Hautveränderungen typischen Anordnung der Zellen. Dadurch bilden sich neben dem üblicherweise vorhandenen Netzmuster auch weitere Strukturen aus (z.B. Streifen, Punkte). In diesem Abschnitt wird beschrieben, wie die unterschiedlichen Strukturen innerhalb der Hautveränderung quantitativ beschrieben und zu einem Gesamtscore zusammengefaßt werden.

Ansätze aus der Literatur

Gutkowicz-Krusin et al. [GKESK97] merken zum Thema Struktur lediglich an, daß ein “Texturparameter” jeweils für die Blau- und Grünebene des RGB-Bildes verwendet wird. Auch Schindewolf et al. [SSA⁺93a] [HSS⁺94] setzen Texturmerkmale ein. Dazu verwenden die Autoren 3×3 große Gradientenfilter für vier verschiedene Richtungen. Durch Nachbearbeitung des Ergebnisses werden zusammenhängende netzartige Strukturelemente bestimmt. Daraus werden insgesamt 33 Texturmerkmale berechnet. Durch die Vielzahl der extrahierten Merkmale scheint dieses Vorgehen für eine nachvollziehbare quantitative Bildanalyse nicht geeignet.

Verwendete Methode

Der hier vorgestellte Ansatz zur Charakterisierung der Strukturvielfalt basiert auf der fSIM-Methode (Abschnitt 4.4, Seite 33). Dazu wird zunächst das RGB-Bild in ein Grauwertbild transformiert. In verschiedenen Tests hat es sich als günstig erwiesen, das Grauwertbild mit einem 3×3 Gaußfilter zu glätten. Das so erhaltene Bild wird mit fSIM ($r_1 = 3$ und $r_2 = 5$) analysiert. Die Wahl der Radien ist in der Größe der gesuchten Strukturen begründet und so können Strukturelemente wie Netze, Streifen und Punkte visuell besonders gut hervorgehoben werden. Aus der relativen Häufigkeitsverteilung ($P(\alpha)$ -Spektrum) der erhaltenen Skalierungsindizes wird schließlich ein Maß für die Strukturvielfalt gewonnen. Für diese Charakterisierung des $P(\alpha)$ -Spektrums hat sich insbesondere die Rényi-Information [LKP94] [LB94] (vgl. Abschnitt 4.1, Seite 20) als günstig für die Separierbarkeit der beiden Klassen erwiesen:

$$H^{(q)} = \frac{1}{1-q} \log_2 \sum_i p_i^q \quad q \in \mathbb{R} \quad (8.4)$$

In den erwähnten Tests wurden für $q = 0.1$ gute Klassifizierungsergebnisse ermittelt. Mit dieser Wahl werden im Vergleich zur Shannon-Entropie die relativen Häufigkeiten der Skalierungsindizes weniger betont als vielmehr die Vielfalt an Strukturen (vgl. Abschnitt 4.1, Seite 20).

Ergebnisse

In Abbildung 8.25 sind die Ergebnisse der Quantifizierungen aller vorhandenen melanozytären Hautveränderungen abgebildet. Im linken Diagramm sind die Scores geordnet für die MM (Sternchen-Symbole) und für die benignen MHV (Quadrat-Symbole) dargestellt. Der Mittelwert für die MM beträgt 7.77 bei einer Standardabweichung von 0.0678. Die Scores der benignen MHV sind mit einem Mittelwert von 7.69 und einer Standardabweichung von 0.0750 geringer. Durch den Unterschied der Mittelwerte und der ähnlichen Standardabweichungen ergibt sich ein relativ gutes Klassifikationsergebnis. Die zugehörige ROC-Kurve ist im rechten

Teil der Abbildung dargestellt. Die AUC beträgt 0.823 und der dem Optimum am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.746 und bei einer Spezifität von 0.764.

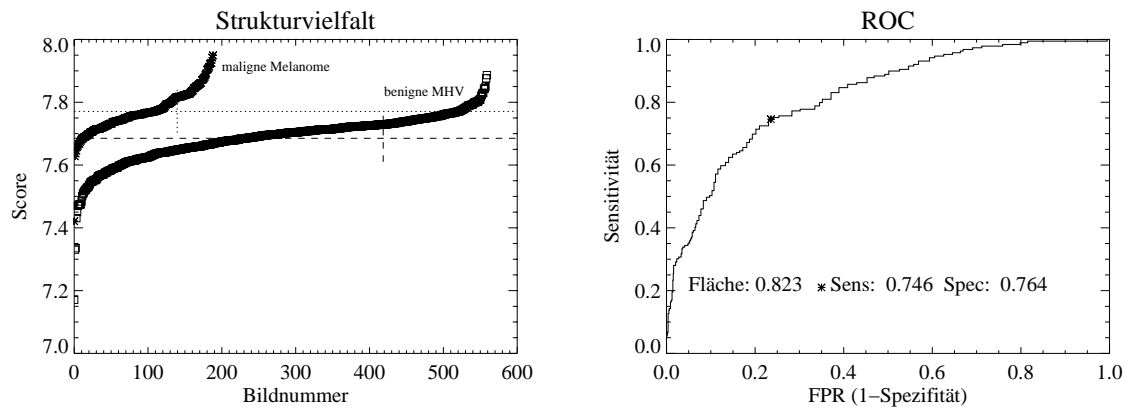


Abbildung 8.25: *Ergebnis der Quantifizierung der Strukturvielfalt*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Visualisierung

Ziel der Visualisierung ist es, dem Betrachter die vorhandenen Strukturen darzustellen. Dazu werden die strukturbeschreibenden Skalierungsindizes durch Falschfarben wiedergegeben. Die Farbtabelle wurde dabei so gewählt, daß flächenhafte Bereiche Blau und Linien Rot erscheinen. Bereiche, die zwar keine Linien enthalten, aber dennoch im Grauwertprofil nicht planar erscheinen, werden grün gekennzeichnet.

Abbildung 8.26 zeigt drei melanozytäre Hautveränderungen zusammen mit ihren Visualisierungen der Strukturvielfalt. Dabei sind die Bilder von links nach rechts mit zunehmender Vielfalt an Strukturen angeordnet. Unter jedem Bild ist die zugehörige Visualisierung dargestellt. In der linken Abbildung sind kaum Strukturen enthalten. Entsprechend zeigt die Visualisierung einen hohen Anteil an blauen und grünen Arealen an. In der mittleren Darstellung sind mehr linienhafte Strukturen zu erkennen, während in der rechten Spalte eine hohe Strukturvielfalt zu erkennen ist.




Abbildung 8.26: *Visualisierung der Strukturvielfalt*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts zunehmender Strukturvielfalt. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.14 Homogenität der Strukturverteilung

Durch das maligne melanozytäre Wachstum entsteht in vielen Fällen eine unregelmäßige Verteilung der Strukturen. Die Quantifizierung der Homogenität dieser Verteilung wird in diesem Abschnitt beschrieben und ein Visualisierungsverfahren angegeben.

Ansätze aus der Literatur

Dem Autor sind keine Arbeiten bekannt, die sich mit der Homogenität der Strukturverteilung befassen.

Verwendete Methode

Zur Charakterisierung der Homogenität der Strukturverteilung findet das Verfahren aus Abschnitt 3.2 (Seite 13) Anwendung. Um eine strukturelle Beschreibung der Hautveränderung zu erhalten, wird sie zunächst mit fSIM analysiert, wobei dieselben Radien verwendet werden wie bei der Berechnung der Strukturvielfalt (Radien $r_1 = 3$ und $r_2 = 5$). In Analogie zur Quantifizierung der Farbhomogenität (vgl. Abschnitt 8.7.12, Seite 133) wird die Läsion in Gitterelemente aufgeteilt. Auch für dieses Merkmal werden die Gitterkonstanten in Abhängigkeit der Läsionsgröße angepaßt (minimale Gitterkonstanten: $g_x = g_y = 40$, maximale Gitterkonstanten: $g_x = g_y = 60$; Überlappungsfaktor $f = 1$). Für jedes Gitterelement wird die Struktureigenschaft durch einen lokalen Score beurteilt. Aus der Standardabweichung der gitterbezogenen Scores wird ein Maß für die Homogenität der Strukturverteilung abgeleitet.

Wie bei der Quantifizierung der Asymmetrie der Strukturverteilung (Abschnitt 8.7.7, Seite 112) wird für jedes Gitterelement der Mittelwert der in ihm vorhandenen Skalierungsindizes bestimmt. Die einzelnen Gitterscores werden gewichtet nach Gleichung 3.7 (Seite 16) zu einem Gesamtscore zusammengefaßt.

Ergebnisse

Die Ergebnisse der Quantifizierungen sind in Abbildung 8.27 dargestellt. Im linken Diagramm sind die Einzelergebnisse geordnet für die MM (Sternchen-Symbole) und für die benignen MHV (Quadrat-Symbole) aufgetragen. Der Mittelwert der Scores für die MM beträgt 0.0013 bei einer Standardabweichung von 0.0007. Demgegenüber sind die Scores der benignen MHV im Durchschnitt geringer. Der Mittelwert beträgt bei ihnen 0.0007 bei einer Standardabweichung von 0.0006. Im rechten Diagramm ist die ROC-Kurve aufgetragen. Die Fläche unter der Kurve beträgt 0.782, wobei der dem Optimum an nächsten gelegene Kurvenpunkt bei einer Sensitivität von 0.757 und einer Spezifität von 0.689 liegt. Damit zeigt dieses Merkmal eine vergleichsweise schlechtere Separierfähigkeit.

Visualisierung

Durch die Visualisierung soll dem Betrachter deutlich gemacht werden, inwieweit sich die Strukturvielfalt in jedem Gitterelement vom Mittelwert unterscheidet. Wie in den vorherigen Visualisierungstechniken auch soll die innere Struktur der Läsion zur besseren Orientierung des Betrachters erkennbar bleiben.

Dazu wird eine Farbraumtransformation in den HLS-Raum durchgeführt (vgl. Abschnitt 6.1.2, Seite 74). Für jedes Gitterelement wird die gewichtete Differenz d seines lokalen Scores vom Mittelwert farblich umgesetzt, indem die *hue*-Komponente des durch das




Abbildung 8.27: Ergebnis der Quantifizierung der Homogenität der Strukturverteilung: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Gitterelement abgedeckten Bereichs in Abhängigkeit von d verändert wird. Gilt $d \approx 0$, unterscheidet sich also die Strukturen im Gitterelement nur wenig vom Durchschnitt, so wird der *hue*-Wert auf einen grünen Farbton gesetzt. Gilt $d < 0$, so wird zur Visualisierung der *hue*-Wert mit kleiner werdenden d so verändert, daß das Gitterelement zunehmend rötlich gefärbt wird. Im anderen Fall ($d > 0$) wird der Farbwert hin zu Blau verändert. Dadurch wird es dem Betrachter möglich, die Regionen zu identifizieren, die andere Struktureigenschaften als der Durchschnitt aufweisen. Da die Visualisierung eine Struktureigenschaft behandelt, wird die *lightness*-Komponente der Läsionspixel, nach entsprechender Skalierung, mit den Werten der Skalierungsindizes belegt. Die *saturation*-Komponente wird auf den konstanten Wert 0.5 gesetzt. Eingezeichnet sind weiterhin der geometrische Schwerpunkt und die Kontur der Läsion.

In Abbildung 8.28 sind drei melanozytäre Hautveränderungen mit ihren Visualisierungen für die Homogenität der Strukturverteilung dargestellt. Die Bilder sind so angeordnet daß die Homogenität von links nach rechts abnimmt. In der Visualisierung der Läsion mit hoher Homogenität haben fast alle Gitterelemente einen grünen Farbton, entsprechend der homogenen Strukturverteilung. Lediglich ein Gitterelement hat, da es weniger Strukturelemente enthält, eine blaue Färbung. In der mittleren Darstellung dominieren vier blaue Gitterelemente das Bild. Dort ist, visuell deutlich zu erkennen, eine geringere Strukturvielfalt als in den anderen vorhanden. In der rechten Darstellung sind neben blauen auch einige gelbliche und orange Gitterelemente zu sehen. Die Färbung weist darauf hin, daß die Strukturvielfalt in den entsprechenden Gitterelementen erhöht ist.




Abbildung 8.28: *Visualisierung der Homogenität der Strukturverteilung*: In der oberen Reihe sind die Originalbilder dargestellt mit von links nach rechts abnehmender Homogenität. Unter jedem Bild ist die Visualisierung dieser Eigenschaft abgebildet.

8.7.15 Größe der Läsionen

Durch horizontales Wachstum ist auch die Größe der Läsion als ein Indikator für Dignität anzusehen.

Ansätze aus der Literatur

Alle Autoren verwenden in ihren Untersuchungen auch die Größe der Hautveränderung.

Verwendete Methode

Die Größe der Läsion läßt sich aus der Segmentierung ableiten. Dieses Merkmal wird hier durch die Anzahl der Pixel der binären Läsionsmaske ausgedrückt.

Ergebnisse

Die einzelnen Werte der Läsionsgröße sind im linken Teil von Abbildung 8.29 getrennt nach MM (Sternchen-Symbole) und benignen MHV (Quadrat-Symbole) dargestellt. Der Mittelwert der MM ist mit 106849 deutlich höher als der der benignen MHV mit 52749. Die Standardabweichungen der Scores beider Klassen sind relativ ähnlich (MM: 48026, benigne MHV: 40355). Im rechten Diagramm ist die dazugehörige ROC-Kurve aufgetragen. Die Fläche unter der Kurve beträgt 0.808 und der dem Optimum am nächsten gelegene Kurvenpunkt liegt bei einer Sensitivität von 0.730 und bei einer Spezifität von 0.764. Diese Zahlen zeigen, daß mit diesem sehr einfachen Merkmal eine recht gute Trennung der beiden Klassen möglich ist.




Abbildung 8.29: *Ergebnis der Quantifizierung der Läsionsgröße*: Links: Sortierte Scores und geordnet nach Klasse (Sternchen-Symbole: MM, Quadrat-Symbole: benigne MHV). Rechts: ROC-Kurve

Visualisierung

Die Läsionsgröße ist während des Segmentierungsprozesses und bei den Visualisierungen der anderen Merkmale (die Kontur ist immer ersichtlich) zu sehen und daher wird auf eine Darstellung an dieser Stelle verzichtet.

8.8 Merkmalsauswahl und Klassifikation

Der nächste Schritt nach der quantitativen Objektbeschreibung besteht aus der Klassifikation [PBH⁺00]. Die Teilaufgaben dieses Vorgangs sind die Wahl des Klassifikators, die Merkmalsauswahl, die Abschätzung der Klassifikationsgenauigkeit und die abschließende Konstruktion des Klassifikators.

Um den Merkmalsvektor einer melanozytären Hautveränderung der Klasse der malignen oder benignen Hautveränderungen zuzuordnen, wird ein Klassifikator auf der Basis der linearen Diskriminanzanalyse verwendet. Die Konstruktion des Klassifikators wird mit der Merkmalsauswahl entsprechend Kapitel 7 gekoppelt. Die Abschätzung der Klassifikationsgenauigkeit erfolgt durch 10fache Crossvalidierung. Nach einer Bewertung des abgeleiteten Klassifikators schließt dieser Abschnitt mit Untersuchungen zur Reproduzierbarkeit. Zunächst werden die Ergebnisse der einzelnen Merkmalscharakterisierungen zusammengefaßt.

8.8.1 Zusammenfassung der Einzelmerkmale

In den vorangegangenen Abschnitten wurden 13 Merkmale quantifiziert und Möglichkeiten zur Visualisierung dieser Scores aufgezeigt. Die Güte eines Merkmals hinsichtlich der Separierfähigkeit zwischen den zwei Klassen der malignen und benignen melanozytären Hautveränderungen läßt sich an verschiedenen Kennzahlen ablesen. Hier ist die Fläche unter der ROC-Kurve (AUC) sowie die Sensitivität und die Spezifität des dem Optimum in der ROC-Kurve am nächsten gelegenen Kurvenpunktes von Interesse (vgl. Abschnitt 8.7.2, Seite 99). In Tabelle 8.2 sind die Einzelergebnisse zusammengefaßt. Wie bereits betont, sind in die Ergebnisse alle zur Verfügung stehenden Bilddaten eingeflossen; eine Unterscheidung

Merkmal	AUC	Sensitivität	Spezifität
Asymmetrie, Form	0.738	63.0%	73.0%
Asymmetrie, Konvexität	0.701	63.5%	67.1%
Asymmetrie, Farbverteilung	0.941	88.4%	87.5%
Asymmetrie, Strukturverteilung	0.836	81.5%	74.4%
Berandung, Struktur	0.783	73.5%	73.9%
Berandung, Homogenität	0.797	70.9%	77.9%
Kontur, Krümmung	0.808	76.7%	72.5%
Kontur, Homogenität	0.680	61.9%	67.9%
Farbvielfalt	0.923	85.7%	83.0%
Farbhomogenität	0.803	75.1%	72.5%
Strukturvielfalt	0.823	74.6%	76.4%
Strukturhomogenität	0.782	75.7%	68.9%
Größe	0.808	73.0%	76.4%

Tabelle 8.2: Zusammenfassung der Separierfähigkeit der einzelnen Merkmale. Angegeben ist die Fläche unter der ROC-Kurve (AUC) sowie die Sensitivität und Spezifität des dem Optimum in der ROC-Kurve am nächsten gelegenen Kurvenpunktes.

in Trainings- und Testmenge wird an dieser Stelle noch nicht vorgenommen. Die Merkmale Farbvielfalt (AUC 0.923) und Asymmetrie der Farbverteilung (AUC 0.941) weisen die besten Separierfähigkeiten auf. Auch das Merkmal Strukturvielfalt hat mit einer AUC von 0.823 einen relativ hohen Wert. Faßt man die Einzelmerkmale in Gruppen zusammen, so sind jeweils Asymmetrie, Farbe und Struktur den Randeigenschaften hinsichtlich der Separierfähigkeiten überlegen. Dies korrespondiert mit der dermatoskopischen ABCD-Regel, die der Berandung das niedrigste Gewicht zuteilt.

Bei der Zusammenfassung der Einzelmerkmale ist neben der Separierfähigkeit auch die Korrelation der Merkmalscores untereinander von Interesse. In Tabelle 8.3 sind die linearen Korrelationskoeffizienten der Merkmale gelistet. Es läßt sich feststellen, daß fast alle Merkmale eine positive Korrelation untereinander aufweisen. Dies liegt in vielen Fällen in der Natur des Problems begründet. Als Beispiel mögen die Merkmale Struktur- und Farbvielfalt dienen. Da Strukturen sich durch unterschiedliche Farben vom Hintergrund unterscheiden, bedingt eine erhöhte Strukturvielfalt auch eine höhere Farbvielfalt. Dementsprechend ist auch die Korrelation zwischen diesen beiden Merkmalen mit 0.58 relativ hoch. Ähnliches gilt für die Merkmale *Farbverteilung* und *Asymmetrie der Farbverteilung*, deren linearer Korrelationskoeffizient 0.78 beträgt. Auffallend ist die hohe Korrelation von 0.93 zwischen den Merkmalen *Berandung*, *Struktur* und *Berandung*, *Homogenität*. Bei der Melanomproblematik scheint man bei der Messung beider Merkmale keine Zusatzinformation zu gewinnen. Insgesamt aber ist die lineare Korrelation bei einem durchschnittlichen Wert von 0.36 moderat ausgeprägt. Bei den Algorithmen zur Quantifizierung der Farb- und Strukturhomogenität wird die Läsion mit einem regelmäßigen Gitter überdeckt. Dabei werden die Gitterkonstanten an die Läsionsgröße angepaßt, um eine Abhängigkeit der Scores von der Fläche der Hautveränderung gering zu halten. Dieses Ziel wurde erreicht, da die linearen Korrelationskoeffizienten dieser Merkmale und der Größe mit 0.31 bzw. 0.07 gering sind. Weiterhin kann man aus diesen Werten schließen, daß bei großen Hautveränderungen die Homogenität bezüglich dieser Merkmale nicht zwangsläufig verringert ist.

Asymmetrie, Form	1.00	Asymmetrie, Konvexität	0.81	Asymmetrie, Farbverteilung	0.41	Asymmetrie, Strukturverteilung	0.32	Berandung, Struktur	0.41	Berandung, Homogenität	0.41	Kontur, Krümmung	0.58	Kontur, Homogenität	0.23	Farbvielfalt	0.18	Farbhomogenität	0.29	Strukturvielfalt	0.19	Strukturhomogenität	0.04	Größe	0.14
Asymmetrie, Konvexität		1.00	0.32	0.32	0.51	0.24	0.24	0.46	0.46	0.41	0.46	0.71	0.19	0.19	0.27	0.09	0.09	0.27	0.27	0.19	0.19	-0.04	0.18		
Asymmetrie, Farbverteilung			1.00	1.00	0.47	0.63	0.63	0.49	0.47	0.49	0.49	0.43	0.27	0.27	0.56	0.78	0.78	0.56	0.56	0.58	0.49	0.46			
Asymmetrie, Strukturverteilung				1.00	0.42	1.00	1.00	0.42	0.42	0.42	0.42	0.26	0.14	0.14	0.61	0.34	0.34	0.61	0.61	0.38	0.40	0.18			
Berandung, Struktur					1.00			0.93	1.00	0.93	1.00	0.62	0.25	0.25	0.50	0.24	0.24	0.50	0.50	0.35	0.04	0.50			
Berandung, Homogenität								1.00		1.00	1.00	0.52	0.24	0.24	0.46	0.29	0.29	0.46	0.46	0.32	0.11	0.42			
Kontur, Krümmung												1.00	0.42	0.42	0.36	0.21	0.21	0.36	0.36	0.34	0.02	0.63			
Kontur, Homogenität													1.00	1.00	0.15	0.19	0.19	0.15	0.20	0.20	0.13	0.31			
Farbvielfalt															1.00	1.00	1.00	0.34	0.58	0.58	0.55	0.36			
Farbhomogenität															1.00			1.00	0.34	0.34	0.25	0.31			
Strukturvielfalt																			1.00	1.00	0.41	0.45			
Strukturhomogenität																					1.00	0.07			
Größe																							1.00		

Tabelle 8.3: Lineare Korrelationskoeffizienten zwischen den einzelnen Merkmalen.

8.8.2 Merkmalsauswahl und Abschätzung der Klassifikationsgenauigkeit

Wahl des Klassifikators

Als Klassifikator wird ein Verfahren ausgewählt, das auf der linearen Diskriminanzanalyse (LDA) (Abschnitt 7.2.1, Seite 80) beruht. Hauptgrund für diese Entscheidung ist die Tatsache, daß eine solche Methode bereits in der klinischen Praxis bei der dermatoskopischen ABCD-Regel (Abschnitt 8.3, Seite 88) zur Diagnose des malignen Melanoms verwendet wird. Diese Methodik ist den Dermatologen bereits vertraut und so eignet sich dieses Verfahren sowohl im Sinne einer sanften Migration [Hor97] als auch im Sinne der Nachvollziehbarkeit für ein computergestütztes Diagnoseunterstützungssystem.

Neben den Gewichten der linearen Diskriminanzfunktion muß noch ein Schwellwert bestimmt werden, mit dem die Unterscheidung in die maligne und benigne Klasse vorgenommen wird. Aus den mit der linearen Diskriminanzfunktion berechneten Indikatorwerten für die beiden Klassen läßt sich die ROC-Kurve ableiten. Als Schwellwert wird derjenige Indikatorwert verwendet, der in der ROC-Kurve den am nächsten gelegenen Wert zum Optimum (Sensitivität = Spezifität = 1) markiert.

Merkmalsauswahl

Die Merkmalsauswahl wird, wie in Kapitel 7 (Seite 79) beschrieben, mit den Klassifikationsergebnissen eng gekoppelt. Insgesamt stehen 13 Merkmale zur Verfügung. Damit sind $2^{13} - 1 = 8191$ Merkmalskombinationen möglich. Da die Berechnung der Gewichte bei der LDA nur wenig rechenintensiv ist, kann in diesem Fall eine exhaustive Suche unter allen möglichen Merkmalskombinationen vorgenommen werden (*wrapper*-Ansatz).

Die Merkmalsauswahl wird unter Beachtung des Prinzips der Trennung der Daten in Trainings- und Testmenge durchgeführt. Um eine Evaluierung des Klassifikators an nur einer, möglicherweise unausgewogenen Aufteilung der Daten in Trainings- und Testmenge zu verhindern, findet die Technik der 10fachen Crossvalidierung [Han97] Anwendung. Dabei wird der gesamte Datensatz in zehn disjunkte Untermengen aufgeteilt, die in etwa jeweils die gleiche Anzahl benignen und malignen melanozytärer Hautveränderungen enthalten. Iterativ werden jeweils neun dieser Untermengen für die Bestimmung der Klassifikatorparameter verwendet (Training) und die zehnte dient als Testdatensatz. Wie bereits in Abschnitt 8.7 (Seite 99) geschildert, wurde zur Bestimmung und Optimierung der Parameter in den Quantifikationsalgorithmen ein Datensatz von 120 Bildern verwendet. Um einen Einfluß dieser Optimierung auf die Evaluierung der Klassifikationsleistung zu vermeiden, sind diese Bilder für den Prozeß der Merkmalsauswahl ausgeschlossen.

Für jede mögliche Merkmalskombination werden die Parameter des Klassifikators mit dem Trainingsdatensatz bestimmt und anhand des Testdatensatzes evaluiert (das Verfahren ist schematisch in Abbildung 8.30 dargestellt). Folgende Qualitätsmaße werden dabei für die Klassifikationsleistung bei beiden Mengen berechnet (vgl. Abschnitt 8.7.2, Seite 100): Korrektheit ρ , Sensitivität und Spezifität. Nach der Crossvalidierung stehen also für jedes Qualitätsmaß und für jede Merkmalskombination zehn Maßzahlen zur Verfügung, die jeweils durch Mittelwertbildung zusammengefaßt werden.

Um die unterschiedlichen Wertebereiche der einzelnen Scores auszugleichen, werden die Scores des Trainingsdatensatzes linear in das Intervall $[0, 1]$ skaliert. Da die Klassifikationsleistung

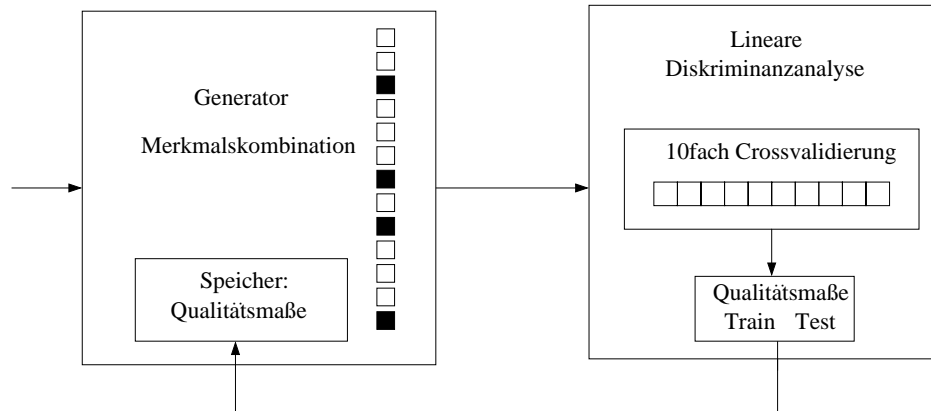


Abbildung 8.30: Schematische Darstellung des Verfahrens zur Auswahl der Merkmalsmenge. Qualitätsmaße für jede mögliche Merkmalskombination werden durch 10fache Crossvalidierung bestimmt. Die zu verwendende Merkmalskombination wird anhand der Qualitätsmaße bezüglich der Trainingsmenge ausgewählt. Die dazugehörigen Qualitätsmaße bezüglich der Testmengen erlauben eine Abschätzung der Klassifikationsleistung bei unbekanntem Mustern (vgl. Abbildung 7.1, Seite 85).

an bislang dem System unbekanntem Daten abgeschätzt werden soll, werden die dabei abgeleiteten Skalierungsparameter auch für den Testdatensatz verwendet.

Nach Durchführung dieser Berechnungen stehen neben den Sensitivitäten und Spezifitäten die Korrektheiten ρ_i^{Train} auf der Trainingsmenge und ρ_i^{Test} auf der Testmenge zur Verfügung ($i \in [1, 8191]$). Wird jedem der 13 Merkmale in einem Binärstring eine feste Position zugewiesen und die jeweils verwendeten Merkmale mit “1” und die restlichen mit “0” markiert, so läßt sich dieser Binärstring als numerischer Wert interpretieren. Dieser Index i identifiziert also eindeutig die dazugehörige Merkmalskombination. Als optimale Merkmalskombination C wird diejenige Menge angesehen, bei der die Korrektheit ρ auf der Trainingsmenge maximal ist:

$$C = \max_i \rho_i^{\text{Train}} \quad (8.5)$$

Dieses Vorgehen führt zur Auswahl folgender Merkmalskombination C :

- Asymmetrie, Farbverteilung
- Asymmetrie, Strukturverteilung
- Kontur, Krümmung
- Farbvielfalt
- Strukturvielfalt
- Größe

In dieser Merkmalskombination sind alle Komponenten der dermatoskopischen ABCD-Regel enthalten, ergänzt durch die Größe.

Abschätzung der Klassifikationsleistung

Mit den dazugehörigen Qualitätsmaßen der Testmenge läßt sich die Klassifikationsleistung bei unbekanntem Mustern abschätzen. Demnach können 93.0% der Daten korrekt klassifiziert werden. Die Sensitivität liegt bei 91.5% und die Spezifität bei 93.4%. Die Qualitätsmaße für Trainings- und Testmenge sind in der folgenden Tabelle zusammengefaßt:

	ρ	Sensitivität	Spezifität
Trainingsmenge	93.4%	92.9%	93.5%
Testmenge	93.0%	91.5%	93.4%

Klassifikator

Nach Ermittlung der zu verwendenden Merkmalskombination und Abschätzung der Klassifikationsleistung kann nun abschließend der Klassifikator bestimmt werden, der als Ergebnis dieser Studie für unbekannte Bilddaten eingesetzt wird. In die Konstruktion des Klassifikators werden alle vorhandenen Bilddaten miteinbezogen. Die so bestimmte lineare Diskriminanzfunktion stellt sich wie folgt dar:

$$\begin{aligned}
 lda(\vec{x}) = & 3.4 \cdot (\text{Asymmetrie, Farbe}) + 2.8 \cdot (\text{Asymmetrie, Struktur}) + \\
 & 2.9 \cdot (\text{Kontur, Krümmung}) + 5.3 \cdot \text{Farbvielfalt} - \\
 & 1.6 \cdot \text{Strukturvielfalt} + 1.4 \cdot \text{Größe}
 \end{aligned} \tag{8.6}$$

Mittels dieser Funktion und dem aus der ROC-Analyse ermittelten Schwellwert läßt sich abschließend der Klassifikator ableiten:

$$class(\vec{x}) = \begin{cases} \text{malign} & \text{falls } lda(\vec{x}) > 5.1 \\ \text{benign} & \text{sonst} \end{cases} \tag{8.7}$$




Abbildung 8.31: *Links*: Sortierte Gesamtscores für die malignen Melanome (Sternchen-Symbole) und benignen MHV (Quadrat-Symbole). *Rechts*: ROC-Kurve des Gesamtscores.

8.8.3 Bewertung der Klassifikationsergebnisse

Bei Vergleich der ausgewählten Merkmale mit der dermatoskopischen ABCD-Regel ist festzustellen, daß alle vier Komponenten *Asymmetrie*, *Berandung*, *Farbe* und *Differentialstrukturen* vertreten sind. Eine weitere Entsprechung mit der dermatoskopischen ABCD-Regel ist das Vorhandensein zweier Asymmetrie-Merkmale. Auch dort werden unter dem Begriff Asymmetrie mehrere Aspekte berücksichtigt.

Betrachtet man die in der linearen Diskriminanzfunktion (Gleichung 8.6) enthaltenen Gewichte als Indiz für die Bedeutung eines Merkmals, so ist das Merkmal *Farbvielfalt* mit einem Gewicht von 5.3 das wichtigste Charakteristikum. Auf den numerischen Wert des abgeleiteten Gesamtscores (Indikator z) haben die Asymmetrie-Merkmale ebenfalls starken Einfluß (die Summe der beiden Gewichte beträgt 6.2). Abweichend von der dermatoskopischen ABCD-Regel scheint die Berandung eine höhere Bedeutung zu haben, da das Gewicht der Eigenschaft *Kontur*, *Krümmung* mit 2.9 relativ hoch ist. Das Gewicht des Merkmals *Strukturvielfalt* ist mit einem Absolutwert von 1.6 relativ niedrig. Dies kann allerdings damit zusammenhängen, daß der lineare Korrelationskoeffizient zwischen den Merkmalen *Strukturvielfalt* und *Farbvielfalt* mit 0.58 einen überdurchschnittlichen Wert hat. Das Merkmal *Größe* weist mit 1.4 das niedrigste Gewicht auf. Dies korrespondiert mit dem Ziel der Diagnosestellung in einem möglichst frühzeitigen Stadium, bei dem das Melanom noch eine relativ geringe Fläche hat. Im linken Teil von Abbildung 8.31 sind die berechneten Indikatorwerte getrennt für die malignen und benignen melanozytären Hautveränderungen nach Größe sortiert aufgetragen. Der Mittelwert der Scores der malignen Melanome beträgt 6.69 bei einer Standardabweichung von 1.33. Für die benigne Klasse ist der Mittelwert mit 3.57 deutlich niedriger (Standardabweichung: 1.06). Die in diesen Zahlen sich abzeichnende gute Klassifikationsrate wird in der rechts daneben abgebildeten ROC-Kurve bestätigt, die eine AUC von 0.97 aufweist. Die oben geschilderte Abschätzung der Klassifikationsleistung sowie die ROC-Kurve zeigen, daß mit dem entwickelten Bildanalyzesystem eine Genauigkeit erreicht wird, die der eines erfahrenen Dermatologen entspricht.

Aus den bereits in Abschnitt 8.4 (Seite 91) beschriebenen Gründen ist ein Vergleich der Ergebnisse mit denen anderer Veröffentlichungen schwierig. In dieser Arbeit konnte auf einen vergleichsweise großen Datensatz zurückgegriffen werden, insbesondere auf eine große Anzahl maligner Melanome. Ein weiterer wesentlicher Unterschied zu anderen Arbeiten ist die Einhaltung des Prinzips der Trennung der Daten in Trainings- und Testdatensatz. Vergleicht man die Klassifikationsraten mit bereits publizierten, so werden mit den hier entwickelten Quantifikationsalgorithmen und dem abgeleiteten Klassifikator höhere Erkennungsraten erreicht. Lediglich Seidenari et al. [SPP98] haben mit einer Sensitivität von 93% und eine Spezifität von 95% eine bessere Erkennungsrate veröffentlicht. Diese Zahlen sind allerdings anhand eines sehr kleinen Datensatzes von 90 Hautveränderungen (darunter nur 31 maligne Melanome) gewonnen worden. Weiterhin wurde dort keine Unterscheidung in Trainings- und Testdatensatz vorgenommen. Im Gegensatz zu anderen Arbeiten verwendet der in dieser Arbeit entwickelte Klassifikator nur sechs Merkmale. Dies ermöglicht die Nachvollziehbarkeit auch der Klassifikation (vgl. Millers magische Zahl in Abschnitt 7.3, Seite 83). Eine geringere Anzahl von Merkmalen wirkt sich auch günstig auf den sogenannten *curse of dimensionality* aus (Abschnitt 7.3, Seite 83).

8.8.4 Reproduzierbarkeit

Die Reproduzierbarkeit der quantitativen Ergebnisse ist ein wichtiges Qualitätsmerkmal des Diagnoseunterstützungssystems. Im Analyseprozeß besteht nur bei der Segmentierung (Abschnitt 8.6, Seite 8.6) die Möglichkeit eines interaktiven Eingriffs. Da die in dieser Arbeit beschriebenen Algorithmen keine (Pseudo-) Zufallszahlen verwenden, sind die Quantifikationsalgorithmen deterministisch. Zur Untersuchung der Reproduzierbarkeit ergeben sich also folgende Fragestellungen:

- Inwieweit lassen sich die Messungen bei unterschiedlichen Aufnahmen derselben melanozytären Hautveränderung reproduzieren?
- Welchen Einfluß hat die Segmentierung auf die Ergebnisse (Einzelscores und abgeleiteter Gesamtscore) ?

Da aber das hier verwendete Bildmaterial retrospektiv zusammengestellt wurde und zum Zeitpunkt der Abfassung dieser Arbeit auf die Kamera nicht mehr zugegriffen werden kann (sie wurde demontiert), ist eine quantitative Beantwortung der Frage nach Reproduzierbarkeit bei verschiedenen Aufnahmen derselben Hautveränderung leider nicht möglich. Stattdessen werden an dieser Stelle Faktoren beschrieben, die die Reproduzierbarkeit direkt beeinflussen. Allerdings läßt die Untersuchung des Einflusses der Segmentierung einige Rückschlüsse auf die Reproduzierbarkeit zu.

Betrachtungen zur Reproduzierbarkeit

Die Darstellung der Faktoren, die die Reproduzierbarkeit beeinflussen, orientiert sich an der allgemeinen Diskussion, die in Abschnitt 2.2 (Seite 8) geführt wurde. Als wichtigster Faktor aus der Gruppe der Kameraparameter erscheint die standardisierte Abbildung der Farbwerte. Diese nimmt direkten Einfluß auf die Farbmerkmale (Farbasymmetrie, -vielfalt und -homogenität). Die genaue Fokussierung der Kamera beeinflußt die Schärfe der abgebildeten Strukturelemente der Läsion und somit diejenigen Merkmale, die auf die Struktureigenschaften der Läsion Bezug nehmen.

Wesentlich sind auch mehrere Objektparameter, die auf Besonderheiten des Objekts "Haut" zurückzuführen sind. In diesem Zusammenhang sind insbesondere drei Eigenschaften der Haut zu nennen. Da die Haut druckempfindlich reagiert, können bei unterschiedlichem Aufsatzdruck des Kamerakopfes durch Minderdurchblutung des Gewebes verschiedene Hautfärbungen resultieren. Ähnliche Effekte entstehen auch bei einer asymmetrischen Druckbelastung der Haut, da auf der einen Seite das Gewebe regulär und es auf der anderen Seite minderdurchblutet wird. Betroffen sind hier wieder insbesondere die Farbmerkmale. Die zweite Eigenschaft betrifft die Dehnbarkeit der Haut. Ein ungünstiges Aufsetzen des Kamerakopfes kann zu einer Verzerrung der Läsion führen. Die Veränderung der abgebildeten Läsionsgeometrie hat unmittelbaren Einfluß auf die Asymmetrie-Merkmale. Saisonal bedingte Veränderungen (z.B. Hautbräunung) können zu unterschiedlichen Bewertungen der Farbeigenschaften führen.

Zu den Umgebungsparametern zählt insbesondere die homogene Ausleuchtung des Aufnahmebereichs. Da sich Inhomogenitäten nicht völlig ausschließen lassen, beeinflußt dieser Parameter wiederum direkt die Farbmerkmale.

Schließlich ist zu erwarten, daß der Grad an Reproduzierbarkeit auch von der Art der Läsion abhängt. Hautveränderungen, die sehr gleichmäßig beschaffen sind und eine geringe Farb- und Strukturvielfalt aufweisen, werden wohl kleineren Schwankungen in der Reproduzierbarkeit unterliegen als sehr inhomogene Läsionen. Dies bedeutet, daß die Untersuchungen für die benigne und maligne Klasse getrennt durchgeführt werden sollten. Problematisch ist allerdings die Datenerfassung für den malignen Fall, da es Melanom-Patienten unter der psychischen Belastung nicht ohne weiteres zumutbar ist, die Aufnahme-prozedur mehrfach durchlaufen zu müssen.

Zur Sicherstellung einer weitgehenden Reproduzierbarkeit erscheint die Erstellung eines detaillierten Aufnahmeprotokolls sinnvoll. Auch eine technische Unterstützung, wie die Standardisierung des Aufsatzdrucks des Kamerakopfes durch eine gefedert gelagerte Glasplatte, kann diesem Ziel dienlich sein.




Abbildung 8.32: Links ist eine benigne und rechts eine maligne melanozytäre Hautveränderung dargestellt. Exemplarisch wird anhand dieser beiden Läsionen der Einfluß der Segmentierung auf die Merkmalsquantifikationen und den abgeleiteten Gesamtscore untersucht. Die 21 verschiedenen Segmentierungen sind in der unteren Reihe abgebildet.

Einfluß der Segmentierung

Bei vielen Hautveränderungen ist eine definitive Festlegung der Läsionsgrenze schwierig, wenn der Übergang von der Läsion zur umgebenden Haut sehr weich verläuft. Daher ist zu untersuchen, inwieweit diese Segmentierungsproblematik Einfluß auf die Merkmalsquantifikation und den Gesamtscore hat. Exemplarisch wird diese Fragestellung an einer benignen und einer malignen melanozytären Hautveränderung untersucht, die in Abbildung 8.32 dargestellt sind. Die benigne Hautveränderung zeichnet sich durch eine einfache Strukturierung aus, da die Läsion bezüglich Farben und Strukturelementen relativ homogen ist. Im Gegensatz dazu weist die maligne Läsion eine Vielzahl an Farben und Strukturen auf. Des Weiteren ist gerade der Läsionsrand sehr inhomogen. Durch diese Eigenschaften eignen sich diese Läsionen für die folgenden Untersuchungen, da sie als prototypisch für regelmäßige und unregelmäßige Hautveränderungen anzusehen sind.

Grundlage der schwellwertbasierten Segmentierung (Abschnitt 8.6, Seite 95) ist eine Minimumssuche im auf das Intervall $[0, 255]$ linear skalierte Grauwert-Histogramm der Blau-Komponente des RGB-Bildes. Zu einer systematischen Untersuchung des Einflusses der Segmentierung wird die gefundene Segmentierungsschwelle in 5er-Schritten je 10 mal in die positive und negative Richtung bezüglich der Grauwertskala verschoben (vgl. Abbildung 8.32). Für alle dieser 21 so segmentierten Bilder werden nun die 13 Merkmalsbewertungen sowie der abgeleitete Gesamtscore berechnet. Anschließend wird für jedes Merkmal die Standardabweichung der berechneten Scores σ_M^S und die Standardabweichung der Merkmalsquantifizierungen σ_M bezüglich aller vorhandenen 749 melanozytären Hautveränderungen bestimmt. Als Maß für die Variabilität V_M der Scores wird der Quotient der beiden Standardabweichungen verwendet:

$$V_M = \frac{\sigma_M^S}{\sigma_M} \quad (8.8)$$

Ein geringer Wert von V_M weist somit auf eine hohe Reproduzierbarkeit des untersuchten Merkmals hin. In Tabelle 8.4 sind die Einzelergebnisse aufgeführt. Die Größe der beiden Läsionen schwankt mit einem Wert von 0.21 bzw. 0.25. Bei der benignen melanozytären Hautveränderung ist der Variabilitäts-Score V_M lediglich bei den Merkmalen *Asymmetrie*, *Form* und *Kontur*, *Homogenität* wesentlich größer als der der Größe. Dies ist gerade bei der *Kontur* verständlich, da die Segmentierung die Konturform direkt beeinflusst. Die Gleichförmigkeit der benignen Hautveränderung ist auch an dem niedrigen Variabilitäts-Score der *Berandung* ersichtlich. Demgegenüber sind beim malignen Melanom die Variabilitäts-Scores von sieben Merkmalen höher als der des Merkmals *Größe*. Sehr hoch ist dieser Score bei dem Merkmal *Asymmetrie*, *Konvexität*, was durch die vielfältigen "Ausstülpungen" bei den verschiedenen Segmentierungen zu erklären ist (vgl. untere Reihe von Abbildung 8.32). Auch das Merkmal *Kontur*, *Homogenität* weist wie bei der benignen Läsion einen relativ hohen Variabilitäts-Score auf. Die beobachtete Ungleichmäßigkeit des Übergangs von der Läsion zur Haut ist auch an den erhöhten Werten der *Berandungeigenschaften* abzulesen. Die Merkmale *Farbhomogenität* und *Strukturvielfalt* variieren ebenfalls relativ stark. Die Werte dieser Scores hängen insbesondere davon ab, ob der relativ helle und wenig Struktur enthaltende Randbereich mitsegmentiert wurde. Auffallend ist bei beiden Läsionen, daß die Merkmale *Farbasymmetrie* und *Farbvielfalt* geringe Variabilitäts-Scores aufweisen. Da diese bei der Berechnung des abgeleiteten Gesamtscores die größten Gewichte haben (vgl. Gleichung 8.6, Seite 148), ist

Merkmal	benigne HV	maligne HV
Asymmetrie, Form	0.42	0.23
Asymmetrie, Konvexität	0.22	0.82
Asymmetrie, Farbverteilung	0.17	0.04
Asymmetrie, Strukturverteilung	0.08	0.35
Berandung, Struktur	0.20	0.35
Berandung, Homogenität	0.13	0.43
Kontur, Krümmung	0.15	0.24
Kontur, Homogenität	0.41	0.61
Farbvielfalt	0.09	0.04
Farbhomogenität	0.18	0.60
Strukturvielfalt	0.04	0.83
Strukturhomogenität	0.05	0.17
Größe	0.21	0.25
Abgeleiteter Gesamtscore	0.10	0.13

Tabelle 8.4: *Variabilität der Scores bei unterschiedlichen Segmentierungen*: Für die beiden Läsionen aus Abbildung 8.32 wurde die Variabilität der berechneten Merkmalsquantifizierungen nach Gleichung 8.8 bestimmt.

bei beiden Läsionen die Variabilität des Gesamtscores deutlich geringer als der Referenzwert (Größe). In Abbildung 8.33 sind die einzelnen Werte des Gesamtscores für die maligne und benigne Läsion dargestellt. Bei der benignen Hautveränderung (Quadrat-Symbole) ist ein stetiges Ansteigen des Scores zu beobachten, was insbesondere in der zunehmenden Farbvielfalt durch die Pixel am Läsionsrand begründet ist. Die bereits beschriebene Variabilität des abgeleiteten Gesamtscores bei der malignen Läsion (Sternchen-Symbole) ist auch im Diagramm erkennbar. Bei diesen beiden Läsionen ändert sich trotz der starken Größenveränderungen nicht die Klassifikation (der dazugehörige Klassifikationsschwellwert ist im Diagramm gestrichelt eingetragen). In Anbetracht der relativ starken Größenunterschiede der einzelnen Segmentierungen ist der berechnete Gesamtscore als relativ stabil zu betrachten. Dies gibt zu der begründeten Hoffnung Anlaß, daß die Reproduzierbarkeit des Gesamtscores bei verschiedenen Aufnahmen derselben Läsion ebenfalls relativ gut ist. Nicht einbezogen sind bei den Untersuchungen allerdings die Faktoren, die die Farbeigenschaften der Läsion insgesamt beeinflussen.

Interessant ist auch die Frage, wie sich diese Variabilitätsscores V_M bei Untersegmentierung (Schwellwert ist zu klein) und Übersegmentierung (Schwellwert ist zu groß) verhalten. Die entsprechenden Werte sind in Tabelle 8.5 gelistet und basieren auf den im vorhergehenden Abschnitt beschriebenen Versuchen. Bei den beiden verschiedenartigen melanozytären Hautveränderungen sind unterschiedliche Tendenzen bei V_M zu beobachten. Bei der benignen Läsion führt eine Übersegmentierung in ca. 60% der Merkmale zu einem geringeren Variabilitätsscore als bei Untersegmentierung, also zu einem stabileren Ergebnis. Der Unterschied beim abgeleiteten Gesamtscore zwischen Unter- und Übersegmentierung ist aber gering (0.06




Abbildung 8.33: *Abhängigkeit des abgeleiteten Gesamtscores von der Segmentierungsschwelle*: Mit Sternchen werden die Gesamtscores der malignen und mit Quadraten die der benignen Läsion symbolisiert. Die horizontale Linie bezeichnet den Schwellwert der Klassifikation (Gleichung 8.7, Seite 148).

vs. 0.05). Demgegenüber führt bei der malignen Läsion eine Untersegmentierung bei 85% der Merkmale zu einem geringeren Variabilitätsscore. Dieser Unterschied scheint darin begründet zu sein, daß bei der malignen Läsion mit zunehmenden Schwellwert die hellen Areale am Läsionsrand mitsegmentiert werden und sich damit die Merkmalsbewertungen relativ stark verändern. Auch beim abgeleiteten Gesamtscore ist V_M bei einer zu kleinen Segmentierung geringer (0.04 vs. 0.12). Da der Wert von V_M des abgeleiteten Gesamtscores bei der benignen Läsion nur 0.06 beträgt, scheint es im Sinne der Reproduzierbarkeit des Diagnosevorschlags günstiger zu sein, einen eher kleinen Schwellwert zur Segmentierung zu verwenden.

8.9 Zusammenfassung der Ergebnisse

In diesem Kapitel wurde die Früherkennung des malignen Melanoms als Anwendungsbeispiel der nachvollziehbaren quantitativen Bildanalyse beschrieben. Entscheidend für die Prognose des Patienten ist die frühzeitige Diagnose des Melanoms. Gerade die Diagnose unterliegt einigen Schwierigkeiten. Diese Problematik wird durch eine seit Jahren anhaltende Erhöhung der Erkrankungsrate (Inzidenz) verschärft. Als gängiges diagnostisches Hilfsmittel hat sich die Dermatoskopie und die dazugehörige dermatoskopische ABCD-Regel erwiesen, die semi-quantitativ die Merkmale Asymmetrie, Berandung, Farbe und Differentialstrukturen bewertet. Deren korrekte Anwendung erfordert allerdings viel Expertenwissen und Erfahrung. Durch digitale Bildverarbeitung kann der Dermatologe in seiner Diagnosefindung unterstützt

Merkmal	benigne HV		maligne HV	
	untersegmentiert	übersegmentiert	untersegmentiert	übersegmentiert
Asymmetrie, Form	0.26	0.17	0.08	0.18
Asymmetrie, Konvexität	0.13	0.08	0.49	0.24
Asymmetrie, Farbverteilung	0.12	0.03	0.01	0.05
Asymmetrie, Strukturverteilung	0.03	0.08	0.29	0.39
Berandung, Struktur	0.22	0.10	0.31	0.31
Berandung, Homogenität	0.15	0.08	0.45	0.34
Kontur, Krümmung	0.12	0.06	0.13	0.15
Kontur, Homogenität	0.35	0.31	0.53	0.72
Farbvielfalt	0.06	0.03	0.00	0.05
Farbhomogenität	0.06	0.12	0.23	0.51
Strukturvielfalt	0.01	0.06	0.02	0.70
Strukturhomogenität	0.02	0.07	0.04	0.13
Größe	0.09	0.12	0.11	0.16
Abgeleiteter Gesamtscore	0.06	0.05	0.04	0.12

Tabelle 8.5: *Variabilität der Scores bei Unter- und Übersegmentierung*: Die Variabilität der Merkmalscores (Gleichung 8.8) ist in dieser Tabelle getrennt für einen zu kleinen Schwellwert (Untersegmentierung) und einen zu großen Schwellwert (Übersegmentierung) angezeigt (verwendet wurden die Läsionen aus Abbildung 8.32).

werden. Allerdings wird die Ausgabe lediglich eines Diagnosevorschlags im allgemeinen nicht akzeptiert, da dem Arzt die Entscheidungsgründe nicht transparent und objektnah wiedergegeben werden. Dies gilt insbesondere in der dermatologischen Diagnostik, bei der die visuelle Information eine große Rolle spielt. Daher eignet sich dieses Problemfeld für eine nachvollziehbare quantitative Bildanalyse. Ziel ist also eine möglichst gute Trennung der beiden Klassen der benignen und malignen melanozytären Hautveränderungen, wobei die Entscheidungsgründe für den Diagnosevorschlag dem Dermatologen nachvollziehbar dargestellt werden sollen.

Den Untersuchungen liegt ein Datensatz von 560 benignen und 189 malignen melanozytären Hautveränderungen zu Grunde. Die Bilder liegen im RGB-Format (Farbtiefe: 8 bit pro Kanal) vor und haben eine Auflösung von 512×512 Pixel. Dies entspricht einer Fläche von $11.6 \text{ mm} \times 11.6 \text{ mm}$ in vivo.

Die Beschreibung des Analyseprozesses von der Bildakquisition bis zur Klassifikation folgt dem in Kapitel 2 beschriebenen Schema. Die Bildaufnahme erfolgt unter reproduzierbaren Bedingungen. Es wird eine Hintergrundkompensation (Shading-Korrektur) und ein Farbgleich auf die Farben Weiß und Schwarz durchgeführt. Die Aufnahme der melanozytären Hautveränderung wird bei konstantem Vergrößerungsfaktor durchgeführt. Nach einer Detektion von Haaren wird die Läsion segmentiert. Der schwellwertbasierte Segmentationsalgorithmus erlaubt eine Korrektur des Ergebnisses durch den Experten. Nachdem die Läsion im

digitalen Bild identifiziert ist, kann sie quantitativ beschrieben werden. Basierend auf den in Kapitel 3 bis 6 beschriebenen Verfahren wurden 13 Merkmale, die sich an der dermatoskopischen ABCD-Regel orientieren, quantifiziert. Zu jedem der untersuchten Merkmale werden eine vergleichende Übersicht mit aus der Literatur bekannten Verfahren, eine Kurzbeschreibung der Quantifikation und der verwendeten Parameter, eine Darstellung der Separierungseigenschaften sowie drei Beispiele zur Visualisierung gegeben. Die Merkmale, die sich auf die Farbeigenschaften der Hautveränderung beziehen, erlauben die beste Separierung der Klassen der benignen und malignen Hautveränderungen. Faßt man die Einzelmerkmale zu den in der dermatoskopischen ABCD-Regel vorhandenen Gruppen zusammen, so gleichen sich in etwa die Separierungsfähigkeiten der computerbasierten und der dermatoskopischen Merkmale.

Der Klassifikator wurde auf der Basis der linearen Diskriminanzanalyse (LDA) bestimmt. Die Merkmalsauswahl wurde eng mit der Klassifikationsleistung gekoppelt (*wrapper*-Ansatz). Weiterhin wurde sie unter Trennung der Daten in Trainings- und Testdatensatz bei 10facher Crossvalidierung durchgeführt. Die sechs ausgewählten Merkmale bilden einen relativ niedrig dimensionierten Merkmalsraum. Sie repräsentieren alle in der dermatoskopischen ABCD-Regel vorhandenen Gruppen. Die Klassifikationsleistung bei unbekanntem Daten wurde auf 93% bei einer Sensitivität von 91.5% und einer Spezifität von 93.4% abgeschätzt. Damit entspricht sie der eines erfahrenen Dermatologen. Unter Berücksichtigung der Klassifikationsleistung, der Anzahl der vorhandenen Bilddaten und der Evaluierung bezüglich eines Testdatensatzes sind diese Ergebnisse den bislang publizierten überlegen.

Eine Evaluierung der Visualisierungen wurde im Rahmen dieser Arbeit nicht durchgeführt. Im Rahmen eines Feldtests sollen diese in einer gesonderten Studie einer genaueren Untersuchung unterzogen werden. Es bleibt jedoch festzuhalten, daß sich das so entstandene Diagnoseunterstützungssystem auch durch eine von der Merkmalsquantifizierung bis zur Klassifikation durchgehende Nachvollziehbarkeit auszeichnet.

Kapitel 9

Zusammenfassung

Dieses Kapitel faßt die Zielsetzung und die Ergebnisse dieser Arbeit, getrennt nach allgemeinen und anwendungsbezogenen Teil, zusammen. Es schließt mit einem Ausblick auf weitere, sich aus dieser Arbeit ableitende Fragestellungen.

Übersicht

Diese Arbeit beschäftigt sich mit der nachvollziehbaren quantitativen Bildanalyse, die sich anhand zweier Ziele charakterisieren läßt. Die primäre Aufgabe besteht in der Abbildung der ein Objekt beschreibenden Eigenschaften auf mathematische Parameterskalen. Mit dem zweiten Ziel wird gefordert, daß das Ergebnis dieser Abbildung durch den menschlichen Experten nachvollzogen werden kann. Dies setzt die objektnahe visuelle Umsetzbarkeit des berechneten Scores in der Art voraus, daß diese Visualisierung der Wahrnehmungsweise des menschlichen Experten entspricht. Damit wird eine unmittelbare Überprüfbarkeit des Analyseergebnisses erreicht. Ein solches System ist im allgemeinen nicht Teil eines vollautomatisierten Prozesses. Als praktisches Anwendungsbeispiel dient in dieser Arbeit die Früherkennung des malignen Melanoms, also der Differenzierung von benignen und malignen melanozytären Hautveränderungen. Der abgeleitete Klassifikationsvorschlag ist als computergenerierte *second opinion* für die Diagnosefindung des Dermatologen zu verstehen.

Allgemeiner Teil

Einleitend wurde ein allgemeines Schema zur Bildverarbeitung vorgestellt, anhand dessen die erforderlichen Rahmenbedingungen für eine nachvollziehbare quantitative Bildanalyse erarbeitet werden. Wesentliche Aspekte hierfür sind die standardisierte Akquisition des digitalen Bildmaterials und eine Nachvollziehbarkeit, die sich durch den gesamten Analyseprozeß von der Merkmalscharakterisierung bis zur Klassifikation erstreckt.

Im Zentrum des allgemeinen Teils der vorliegenden Arbeit steht die Entwicklung von Verfahren, die eine quantitative Beschreibung von elementaren Objekteigenschaften wie Symmetrie, Homogenität, Struktur, Farbe und Berandung unter der Nebenbedingung der objektnahen Visualisierbarkeit erlauben. Da viele der extrahierten Maße dimensionslos sind, erlangen sie erst im Vergleich mit Referenzbeispielen eine Bedeutung. Aus dieser Kontextualität folgt, daß zu ihrer Interpretation ein Referenzdatensatz nötig ist.

Zur Beurteilung der Homogenität der Verteilung eines Merkmals (z.B. Farbe) über das Objekt wird ein translations- und rotationsinvariantes Verfahren vorgestellt. Für die quantitative Charakterisierung der Symmetrieeigenschaften bezüglich eines Merkmals werden zwei Varianten vorgeschlagen, die sich in ihrem Skalenbezug unterscheiden. Diese nehmen auf den Umstand Rücksicht, daß ein Vergleich von pixelbezogenen Scores in achsensymmetrischer Lage bei bestimmten Merkmalen unzureichend ist. Da die angegebenen Verfahren nicht für jedes mögliche Objekt anwendbar sind, werden zu deren korrekten Einsatz entsprechende Kriterien definiert.

Zur Detektion und quantitativen Beschreibung von Strukturen werden Verfahren vorgestellt, die auf strukturellen Komplexitätsmaßen basieren und sich inhärent für den Einsatz in einem nachvollziehbaren quantitativen Bildanalyzesystem eignen. Realisiert werden sie in der Skalierungs-Index-Methode (SIM) und ihren Derivaten. Das Verfahren findet in dieser Arbeit im *fuzzy*-SIM-Ansatz (fSIM) eine Verallgemeinerung. Mit fSIM läßt sich bei Binärbildern neben der quantitativen Charakterisierung von Linienstrukturen auch eine Unterscheidung von unterschiedlich dicken Linien vornehmen, was mit SIM nicht möglich ist. Diese Eigenschaft ist auch auf andere Strukturelemente, wie zum Beispiel punktartige Strukturen, übertragbar. Anhand zweier Grauwertbilder konnte gezeigt werden, daß die Detektion von Strukturen in verrauschten Bildern eine deutliche Verbesserung erfährt. Dem erhöhten Rechenaufwand

kann durch Verwendung von *look-up*-Tabellen entgegengewirkt werden. Neben der analytischen Formulierung von fSIM wird auch die Architektur eines äquivalenten neuronalen Netzes zusammen mit einem auf Backpropagation basierenden Lernverfahren vorgestellt. Die Plastizität des neuronalen Ansatzes ermöglicht eine adaptive und damit an das Problem angepasste Strukturcharakterisierung. Mit dem TDE-SIM genannten Verfahren ist eine quantitative Charakterisierung von Strukturen möglich, die sich in den Grauwerten nur geringfügig vom Hintergrund unterscheiden. Ein Nachteil des Verfahrens ist allerdings die erhöhte Rauschempfindlichkeit.

Bei der Charakterisierung der Randeigenschaften wird zwischen dem Randbereich und der Kontur des Objekts unterschieden. Dazu werden Algorithmen vorgestellt, die den Randbereich extrahieren und hinsichtlich seiner strukturellen Zusammensetzung sowie der Homogenität seines Aufbaus charakterisieren. Auch für die Kontur werden diese beschreibenden Maße definiert.

Die Farbvielfalt eines Objekts wird in einem dreidimensionalen Farbraum mittels eines Entropiemaßes bestimmt. Für die dazu notwendige Partitionierung wurden drei Ansätze vorgeschlagen. Weiterhin wird in dieser Arbeit unter den Farbeigenschaften eines Objekts auch die Homogenität und Symmetrie verstanden. Basierend auf den oben beschriebenen Verfahren werden Algorithmen zur Quantifizierung der Farbvielfalt und -symmetrie formuliert.

Im Rahmen der Darstellung der Merkmalsauswahl wurden exemplarisch vier häufig verwendete Klassifikationsverfahren hinsichtlich ihrer Möglichkeiten untersucht, sie in einem nachvollziehbaren Bildanalyzesystem einzusetzen. Als besonders geeignet haben sich Nearest-Neighbor-Verfahren und Entscheidungsbäume herausgestellt, da sie es erlauben, den Klassifikationsprozeß durch das Anzeigen von Referenzbeispielen bzw. durch eine sprachliche Begründung transparent darzustellen.

Anwendungsbezogener Teil

Die Früherkennung des malignen Melanoms mit Hilfe der nachvollziehbaren quantitativen Bildanalyse wird als Anwendungsbeispiel untersucht. Die prototypische Eignung dieser Problematik ist in der diagnostischen Schwierigkeit und in der Maßgabe begründet, die Verantwortung für die Diagnose beim Dermatologen zu belassen. Aufbauend auf dem oben genannten allgemeinen Schema zur Bildverarbeitung wurde der Analyseprozeß von der Bildakquisition bis zur Klassifikation beschrieben. Die Merkmalsquantifizierungen basieren auf der sogenannten dermatoskopischen ABCD-Regel, die in der heutigen dermatologischen Praxis Verwendung findet.

Für jedes einzelne der 13 untersuchten Merkmale wird neben einer vergleichenden Darstellung und der Diskussion der Quantifizierungsergebnisse jeweils ein Visualisierungsvorschlag zusammen mit drei Beispielen gegeben. Der Vergleich der Fähigkeit der einzelnen Merkmale, die Klassen der benignen und malignen melanozytären Hautveränderungen zu separieren, gleicht derjenigen der dermatoskopischen ABCD-Regel.

Bei der Konstruktion des Klassifikators wurde die Merkmalsauswahl basierend auf der Klassifikatorleistung bei 10facher Crossvalidierung vorgenommen, wobei das Prinzip der Trennung der Daten in Trainings- und Testmenge Beachtung gefunden hat.

Das so entstandene bildanalytische System zeichnet sich durch folgende Merkmale aus:

Nachvollziehbarkeit Die untersuchten Merkmale orientieren sich an der Sichtweise der Der-

matologen und die abgeleiteten Maße werden mittels Visualisierungen dem Dermatologen objektnah begründet. Der Klassifikationsprozeß wird durch Verwendung von nur sechs Merkmalen und Verwendung eines in der dermatologischen Praxis etablierten Klassifikationsverfahrens transparent gestaltet.

Klassifikationsleistung Die Klassifikationsleistung des abgeleiteten Klassifikators bei bislang unbekanntem Bilddaten wurde auf über 90% abgeschätzt.

Berücksichtigt man darüberhinaus den Umfang des Datenmaterials und die vorgenommene Trennung in Trainings- und Testdaten, so ist ein System entstanden, das Dermatologen effektiv bei der Befundung melanozytärer Hautveränderungen unterstützen kann.

Diskussion und Ausblick

Besonderes Augenmerk für weitere Forschungen sollte auf das fSIM-Modell gelegt werden. Eine systematische Untersuchung der Wahl der Zugehörigkeitsfunktion unter Berücksichtigung des Rauschanteils sowie der Art des Rauschens erscheint zum tieferen Verständnis des Verfahrens sinnvoll. Weitere Fragestellungen leiten sich auch aus der neuronalen Formulierung ab. Im Zentrum der Untersuchungen sollte eine Bestimmung der detektierbaren Strukturformen und eine Quantifizierung der gegenüber fSIM erreichten Reduzierung der Rauschempfindlichkeit stehen. Des weiteren sollte fSIM sowie sein neuronales Analogon auch hinsichtlich Gebiete außerhalb der Bildverarbeitung wie beispielsweise der Zeitreihenanalyse untersucht werden.

Bei der Anwendung der entwickelten Verfahren auf die Früherkennung des malignen Melanoms konnte gezeigt werden, daß mit diesem nicht-invasiven Verfahren die Diagnosefindung des Dermatologen erleichtert und verbessert werden kann. Da im abgeleiteten Klassifikator alle Komponenten der dermatoskopischen ABCD-Regel enthalten sind, kann er als konsistent mit dieser klinischen Regel bezeichnet werden. Der Erfolg eines nachvollziehbaren quantitativen Bildanalysesystems ist nicht nur an der erreichten Klassifikationsrate zu messen. Im Rahmen dieser Arbeit konnte die Akzeptanz der Visualisierungen bezüglich der Melanom-Problematik nur an relativ kleinen Bildmengen evaluiert werden. Um zu einer systematisch begründeten Einschätzung zu gelangen ist ein multizentrischer Feldtest mit dem System durchzuführen, bei dem auch die Klassifikationsleistung bei unbekanntem Bildmaterial bestimmt werden kann. Aus medizinischer Sicht ist eine Untersuchung von Interesse, ob sich bei Dermatologen bei der Melanom-Früherkennung durch die digitale Diagnoseunterstützung die Sichtweise und Bedeutung der einzelnen Merkmale verändern.

Die Frage der Reproduzierbarkeit der Merkmalsquantifikationen sowie der Klassifikation konnte in dieser Arbeit leider aus Mangel an Datenmaterial nicht quantitativ beantwortet werden. Es wurden lediglich Faktoren herausgearbeitet, die die Reproduzierbarkeit beeinflussen. Untersucht werden konnte dagegen der Einfluß der Segmentierung auf den abgeleiteten Gesamtscore. Die beobachtete Stabilität der Gesamtbewertung kann allerdings nicht auf die Klassifikation verschiedener Aufnahmen derselben Hautveränderung übertragen werden. Die erhöhte Abhängigkeit der Berandungsscores von der Segmentierung kann als Anlaß zu weiteren Arbeiten mit dem Ziel der Minimierung dieses Einflusses genommen werden. Eine Untersuchung des Themas Reproduzierbarkeit muß aus diesen Gründen einen Schwerpunkt weiterer Arbeiten bilden.

In einem anderen Themenkomplex sollte untersucht werden, ob durch den Einsatz von telemedizinischen Techniken eine weitere Verbesserung der Diagnostik erreicht werden kann. Dabei könnte das in dieser Arbeit entstandene System diejenigen Hautveränderungen herausfiltern, deren Bewertungen im Grenzbereich zwischen benigner und maligner Klasse liegen. Diese Aufnahmen könnten dann durch das Internet an Expertenzentren zur weiteren Befundung weitergeleitet werden.

Sinnvoll erscheint auch die quantitative Analyse nicht-melanozytärer Hautveränderungen auf Basis der hier erarbeiteten Verfahren. Damit würde das System eine hilfreiche Verbreiterung des Anwendungsfeldes in der Melanom-Früherkennung erfahren. Für eine breite Evaluierung der vorgestellten Verfahren ist auch deren Anwendung auf andere Problemfelder wie beispielsweise der Beurteilung der Wundheilung zu untersuchen.

Literaturverzeichnis

- [Abm94] Abmayr W. *Einführung in die digitale Bildverarbeitung*. Teubner Verlag, 1. Auflage, 1994.
- [APB⁺95] Andreassi L, Perotti R, Burroni M, Dell'Eva G und Biagioli M. Computerized image analysis of pigmented lesions. *Chronica Dermatologica*, 1:11–24, 1995.
- [APR⁺99] Andreassi L, Perotti R, Rubegni P, Burroni M, Cevenini G, Biagioli M, Taddeucci P, Dell'Eva G und Barbini P. Digital Dermoscopy Analysis for the Differentiation of Atypical Nevi and Early Melanoma. *Arch Dermatol*, 135:1459–1465, Dezember 1999.
- [Bel61] Bellman R. *Adaptive Control Process: A Guided Tour*. Princeton University Press, 1961.
- [BG82] Bauer F und Goos G. *Informatik*. Springer Verlag, 3. Auflage, 1982.
- [BJFS84] Breimann L, JH Friedmann RO und Stone C. *Classification and Regression Trees*. Wadsworth and Brooks, 1984.
- [BMR⁺89] Breitbart E, Mohsenian F, Roser M, Schiers C, Wiebecke G, Reimitz P und Höhne K. Untersuchungen zur klinischen Erkennbarkeit der Frühformen des malignen Melanoms. *Onkologie*, 12(6):265–268, 1989.
- [Bos87] Boss N. *Roche Lexikon Medizin*. Hoffmann-La Roche AG and Urban&Schwarzenberg, 2. Auflage, 1987.
- [Bra97] Braun H. *Neuronale Netze*. Springer Verlag, 1 Auflage, 1997.
- [BSMM95] Bronstein I, Semendjajew K, Musiol G und Mühlig H. *Taschenbuch der Mathematik*. Verlag Harri Deutsch, 2. Auflage, 1995.
- [CBB⁺97] Cristofolini M, Bauer P, Boi S, Cristofolini P, Micciolo R und Sicher M. Diagnosis of cutaneous melanoma: accuracy of a computerized image analysis system (Skin View). *Skin Research and Technology*, 3:23–27, 1997.
- [Cen99] Center TGRSD. <http://www.dfd.dlr.de/app/sea/temps/>, 1999. Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR).

- [CFB⁺92] Cascinelli N, Ferrario M, Bufalino R, Zurrida S, Galimberti V, Mascheroni L, Bartoli C und Clemente C. Results obtained by using a computerized image analysis system designed as an aid to diagnosis of cutaneous melanoma. *Melanoma Research*, 2:163–170, 1992.
- [CHKA92] Claridge E, Hall P, Keefe M und Allen J. Shape analysis for classification of malignant melanoma. *Journal of Biomedical Engineering*, 14:229–234, 1992.
- [DSC⁺93] Durg A, Stoecker W, Cookson J, Umbaugh S und Moss R. Identification of Variegated Coloring in Skin Tumors. *IEEE Engineering in Medicine and Biology*, 12(3):71–74, 1993.
- [EFS98] Ebeling W, Freund J und Schweitzer F. *Komplexe Strukturen: Entropie und Information*. Teubner Verlag, 1998.
- [EG94] Eldracher M und Geiger H. Adaptive topologically distributed encoding. In *Proceedings of the International Conference on Artificial Neural Networks (ICANN'94)*, S. 771–774. may 1994.
- [Eld96] Eldracher M. *Planung kinematischer Trajektorien für Manipulatoren mit Hilfe von Subzielen und Neuronalen Netzen*, Band 111 von *DISKI - Dissertationen zur Künstlichen Intelligenz*. Infix-Verlag, Sankt-Augustin, 1996.
- [ESP97] Eldracher M, Staller A und Pompl R. Adaptive Encoding Strongly Improves Function Approximation with CMAC. *Neural Computation*, 1(9):403–417, 1997.
- [Flo78] Flook A. The use of dilation logic on the quantiment to achieve fractal dimension characterisation of textured and structured profiles. *Powder Technology*, 21(1):295–298, 1978.
- [FvD82] Foley J und van Dam A. *Fundamentals of Interactive Computer Graphics*. Addison-Wesley, 1982.
- [GB97] Graham D und Barrett A. *Knowledge-Based Image Processing Systems*. Springer-Verlag, 1997.
- [Gei90] Geiger H. Storing and Processing Information in Connectionist Systems. In R Eckmiller, Herausgeber, *Advanced Neural Computers*, S. 271–277. Elsevier Science Publishers B.V., Amsterdam, 1990.
- [GKESK97] Gutkowicz-Krusin D, Elbaum M, Szwaykowski P und Kopf A. Can early malignant melanoma be differentiated from atypical melanocytic nevus by in vivo techniques? Part II: Automatic machine vision classification. *Skin Research and Technology*, 3:15–22, 1997.
- [GMM⁺91] Green A, Martin N, McKenzie G, Pfitzner J, Quintarelli F, Thomas B, O'Rourke M und Knight N. Computer image analysis of pigmented skin lesions. *Melanoma Research*, 1:231–236, 1991.

- [GMM⁺94] Green A, Martin N, McKenzie G, Pfitzner J, O'Rourke M und Knight N. Computer image analysis in the diagnosis of melanoma. *Journal of the American Academy of Dermatology*, 31(6):958–964, 1994.
- [Gra95] Grauel A. *Fuzzy Logic*. BI Wissenschaftsverlag, 1. Auflage, 1995.
- [GW92] Gonzalez R und Woods R. *Digital Image Processing*. Addison-Wesley, 1. Auflage, 1992.
- [Haf99] Hafner W. *Segmentierung von Video-Bildfolgen durch Adaptive Farbklassifikation*. Fachreihe Informatik. Utz Verlag, München, 1999.
- [Han97] Hand D. *Construction and Assessment of Classification Rules*. John Wiley and Sons, 1997.
- [HLMZ78] Hoppe W, Lohmann W, Markl H und Ziegler H, Herausgeber. *Biophysik*. Springer, 1978.
- [Hoe71] Hoel P. *Introduction to Mathematical Statistics*. John Wiley and Sons, 4th Auflage, 1971.
- [Hor97] Horsch A. Von der manuellen Bildbeurteilung zur computergestützten bildgebenden Diagnostik und Therapieverlaufskontrolle. In B Arnolds, H Müller, D Saupe und T Tolxdorff, Herausgeber, 5. *Workshop Digitale Bildverarbeitung in der Medizin*, S. 100–105. 1997.
- [Hor98] Horsch A. *Computergestützte Diagnostik für Hautkrebsfrüherkennung, Ösophagustumorstaging und Gastroskopie*. Habilitationsschrift, Technische Universität München, 1998.
- [HSN⁺97] Horsch A, Stolz W, Neiß A, Abmayr W, Pompl R, Bernklau A, Bunk W, Dersch D, Gläßl A, Schiffner R, Schoner W und Morfill G. Improving Early Recognition of Malignant Melanomas by Digital Image Analysis in Dermatology. In C Pappas, N Maglavera und J Scherrer, Herausgeber, *Medical Informatics Europe '97*, S. 531–535. IOS Press, 1997.
- [HSS⁺94] Harms H, Stolz W, Schindewolf T, Abmayr W, Schiffner R, Albert R, Pillet L und ter Meulen V. Analyse melanozytärer Läsionen mit Hilfe der Farbbilddauswertung. BMFT Forschungsbericht, Förderkennzeichen 01Z08005, März 1994.
- [KEP97] Kopf A, Elbaum M und Provost N. The use of dermoscopy and digital imaging in the diagnosis of cutaneous malignant melanoma. *Skin Research and Technology*, 3:1–7, 1997.
- [Kin90] Kinder M. *Repräsentation mehrdimensionaler, funktionaler Abhängigkeiten in neuronalen Netzen*. Diplomarbeit, Technische Universität München, Institut für Informatik, November 1990.

- [KK95] Kollhoff D und Kempe H. Verfahren zur farbmtrischen Kalibrierung. In V Rehrmann, Herausgeber, *1. Workshop Farbbildverarbeitung*, S. 5–8. 1995.
- [Koe85] Koecher M. *Lineare Algebra und Analytische Geometrie*. Springer Verlag, 2. Auflage, 1985.
- [KS92] Kerl H und Sterry W. Moderne Diagnostik des malignen Melanoms. *Deutsche Medizinische Wochenschrift*, 117:223–227, 1992.
- [KTU⁺95] Kjoelen A, Thompson M, Umbaugh S, Moss R und Stoecker W. Performance of AI Methods In Detecting Melanoma. *IEEE Engineering in Medicine and Biology*, 14(4):411–416, 1995.
- [LB94] Loistl O und Betz I. *Chaostheorie: Zur Theorie nichtlinearer dynamischer Systeme*. Oldenbourg, 2. Auflage, 1994.
- [LB96] Leffell D und Brash D. Sunlight and Skin Cancer. *Scientific American*, 7, 1996.
- [LKP94] Leven R, Koch B und Pompe B. *Chaos in dissipativen Systemen*. Akademie Verlag, 2. Auflage, 1994.
- [Lon98] Loncaric S. A Survey of Shape Analysis Techniques. *Pattern Recognition*, 31(8):983–1001, 1998.
- [LOPR97] Lehmann T, Oberschelp W, Pelikan E und Repges R. *Bildverarbeitung für die Medizin*. Springer Verlag, 1. Auflage, 1997.
- [MD88] Moody J und Darken C. Learning with Localized Receptive Fields. Research report YALEU/DCS/RR-649, Yale University, Dep of CS, 1988.
- [MD89] Moody J und Darken C. Fast learning in networks of locally-tuned processing units. *Neural Computation*, 1:281–294, 1989.
- [Mil56] Miller G. The magical number seven, plus or minus two: Some limits on our capacity for processing information. *Psychological Review*, 63:81–97, 1956.
- [PBB93] Parry-Barwick S und Bowyer A. Symmetry Analysis And Geometric Modelling. In *Digital Image Computing: Techniques and Applications*. Australian Pattern Recognition Society, 1993.
- [PBD⁺98] Pompl R, Bunk W, Dersch D, Horsch A, Stolz W, Abmayr W, Brauer W, Gläbl A, Schiffner R und Morfill G. Charakterisierung der Berandungseigenschaften melanozytärer Hautveränderungen zur Unterstützung der Früherkennung des malignen Melanoms. In MW E Greiser, Herausgeber, *Methoden der Medizinischen Informatik, Biometrie und Epidemiologie in der modernen Informationsgesellschaft*, S. 309–312. 43. Jahrestagung der GMDS, MMV Medien und Medizin Verlag, 1998.

- [PBD⁺99] Pompl R, Bunk W, Dersch D, Horsch A, Stolz W, Abmayr W, Brauer W, Gläbl A, Schiffner R und Morfill G. Charakterisierung der Farbeigenschaften melanozytärer Hautveränderungen zur Unterstützung der Früherkennung des malignen Melanoms. In H Evers, G Glombitza, T Lehmann und H Meinzer, Herausgeber, *Bildverarbeitung für die Medizin 1999*, S. 160–164. Springer Verlag, 1999.
- [PBH⁺99] Pompl R, Bunk W, Horsch A, Abmayr W, Morfill G, Brauer W und Stolz W. Computer Vision of Melanocytic Lesions using MELDOQ. In *6th Congress of the International Society for Skin Imaging*, S. 150. Skin Research and Technology 1999; 5(2), 1999.
- [PBH⁺00] Pompl R, Bunk W, Horsch A, Stolz W, Abmayr W, Brauer W, Gläbl A und Morfill G. MELDOQ: Ein System zur Unterstützung der Früherkennung des malignen Melanoms durch digitale Bildverarbeitung. In A Horsch und T Lehmann, Herausgeber, *Bildverarbeitung für die Medizin 2000*, S. 234–238. Springer Verlag, 2000.
- [PFTV92] Press W, Flannery B, Teukolsky S und Vetterling W. *Numerical Recipes: The Art of Scientific Computing*. Cambridge University Press, 2nd Auflage, 1992.
- [PK94] Plewig G und Kaudewitz P. *Empfehlungen zur Diagnostik, Therapie und Nachsorge Maligner Melanome*. Tumorzentrum München, 4. Auflage, 1994.
- [Pom94] Pompl R. *Adaptive topologisch verteilte Kodierungen zur Musterklassifikation mit neuronalen Netzen*. Diplomarbeit, Fakultät für Informatik, Technische Universität München, August 1994.
- [Qui90] Quinlan J. Induction of Decision Trees. In JW Shavlik und TG Dietterich, Herausgeber, *Readings in Machine Learning*, S. 57–69. Morgan Kaufmann Publishers, 1990.
- [Rad93] Radig B, Herausgeber. *Verarbeiten und Verstehen von Bildern*. Oldenbourg, 1993.
- [Rät97] Rätth C. *Analyse statischer Strukturen mit strukturellen Komplexitätsmaßen erster und zweiter Stufe*. Dissertation, Ludwig-Maximilians-Universität München, 1997.
- [RM86] Rumelhart D und McClelland J, Herausgeber. *Parallel Distributed Processing*, Band 1. MIT Press, 1986.
- [RM97] Rätth C und Morfill G. Texture detection and texture discrimination with anisotropic scaling indices. *Journal Opt. Soc. Am. A*, 14(12):3208–3215, 1997.
- [RMS⁺97] Rao B, Marghoob A, Stolz W, Kopf A, Slade J, Wasti Q, Schoenbach S, De-David M und Bart R. Can early malignant melanoma be differentiated from atypical melanocytic nevi by in vivo techniques? Part I: Clinical and dermoscopic characteristics. *Skin Research and Technology*, 3:8–14, 1997.

- [Roj93] Rojas R. *Theorie der neuronalen Netzwerke*. Springer Verlag, 1. Auflage, 1993.
- [SAS⁺93] Schindewolf T, Albert R, Stolz W, Abmayr W und Harms H. Klassifikation melanozytärer Hautveränderungen anhand makroskopischer Farbaufnahmen. In S Pöpl und H Handels, Herausgeber, *Mustererkennung 1993*, S. 436–443. Springer Verlag, 1993.
- [SB97a] Scherf M und Brauer W. Feature Selection by Means of a Feature Weighting Approach. Technical Report FKI-221-97, Technische Universität München, 1997.
- [SB97b] Scherf M und Brauer W. Improving RBF Networks by a Two-Step Feature Selection Approach. In *Progress in Connectionist based Information Systems*, S. 249–252. Proc. ICONIP'97, Dunedin, New Zealand, Springer Verlag, 1997.
- [SBD⁺95] Seidenari S, Burroni M, Dell'Eva G, Pepe P und Belletti B. Computerized evaluation of pigmented skin lesion images recorded by a videomicroscope: comparison between polarizing mode observation and oil/slide mode observation. *Skin Research and Technology*, 1:187–191, 1995.
- [SBFBL93] Stolz W, Braun-Falco O, Bilek P und Landthaler M. *Farbatlas der Dermatoskopie*. Blackwell Wissenschaft, 1. Auflage, 1993.
- [Sch95] Schuster R. *Objektverfolgung in Farbbildfolgen*. Dissertation, Technische Universität München, 1995.
- [Sch98] Scherf M. *Distanzbasierte Merkmalsbewertung*. Dissertation, Technische Universität München, 1998.
- [SDK96] Schmitt A, Deussen O und Kreeb M. *Einführung in graphisch-geometrische Algorithmen*. Teubner Verlag, 1. Auflage, 1996.
- [SLM92] Stoecker W, Li W und Moss R. Automatic Detection of Asymmetry in Skin Lesions. *Computerized Medical Imaging and Graphics*, 16(3):191–197, 1992.
- [SM92] Stoecker W und Moss R. Editorial: Digital imaging in dermatology. *Computerized Medical Imaging and Graphics*, 16(3):145–150, 1992.
- [SPB⁺98] Stolz W, Pompl R, Burgdorff T, Horsch A, Bunk W, Schiffner R, Gläbl A, Morfill G und Abmayr W. Computerisierte Verlaufskontrolle und bildanalytische Auswertung pigmentierter Hautveränderungen. *Zeitschrift für Dermatologie*, 184(4):170–175, 1998.
- [SPP98] Seidenari S, Pellacani G und Pepe P. Digital videomicroscopy improves diagnostic accuracy for melanoma. *Journal of the American Academy of Dermatology*, 39(2):175–181, 1998.
- [SRC⁺94] Stolz W, Riemann A, Cognetta A, Pillet L, Abmayr W, Hölzl D, Bilek P, Nachbar F, Landthaler M und Braun-Falco O. ABCD rule of dermatoscopy: a new practical method for early recognition of malignant melanoma. *European Journal of Dermatology*, 4(7):521–527, 1994.

- [SSA⁺93a] Schindewolf T, Stolz W, Albert R, Abmayr W und Harms H. Classification of melanocytic lesions with color and texture analysis using digital image processing. *Analytical and Quantitative Cytology and Histology*, 15(1):1–11, 1993.
- [SSA⁺93b] Schindewolf T, Stolz W, Albert R, Abmayr W und Harms H. Comparison of classification rates for conventional and dermatoscopic images of malignant and benign melanocytic lesions using computerized colour image analysis. *European Journal of Dermatology*, 3:299–303, 1993.
- [SSP⁺96] Stolz W, Schiffner R, Pillet L, Vogt T, Harms H, Schindewolf T, Landthaler M und Abmayr W. Improvement of monitoring of melanocytic skin lesions using a computerized acquisition and surveillance unit with a skin surface microscopic television camera. *Journal of the American Academy of Dermatology*, 35(2):202–207, 1996.
- [Ste93] Steinbrecher R. *Bildverarbeitung in der Praxis*. Oldenbourg Verlag, 1. Auflage, 1993.
- [Ste96a] Steger C. Extraction of curved lines from images. In *13th International Conference on Pattern Recognition*, Band II, S. 251–255. 1996.
- [Ste96b] Steger C. An unbiased detector of curvilinear structures. Technical Report FGBV–96–03, Forschungsgruppe Bildverstehen (FG BV), Informatik IX, Technische Universität München, Juli 1996.
- [Sto89] Stoer J. *Numerische Mathematik 1*. Springer Verlag, 5. Auflage, 1989.
- [UMS91] Umbaugh S, Moss R und Stoecker W. Applying Artificial Intelligence to the Identification of Variegated Coloring in Skin Tumors. *IEEE Engineering in Medicine and Biology*, 10(4):57–62, 1991.
- [VS91] Voss K und Süße H. *Praktische Bildverarbeitung*. Carl-Hanser-Verlag, 1991.
- [Wac95] Wackerbauer R. *Komplexitätsmaße: Klassifikation und Anwendung auf dynamische Systeme*. Dissertation, Ludwig-Maximilians-Universität München, 1995.
- [WAM97] Wettschereck D, Aha D und Mohri T. A Review and Empirical Evaluation of Feature Weighting Methods for a Class of Lazy Learning Algorithms. *Artificial Intelligence Review*, 11:273–314, 1997. Special Issue on “Lazy Learning”.
- [Wer92] Werner J. *Biomathematik und Medizinische Statistik*. Urban und Schwarzenberg, 2. Auflage, 1992.
- [WS82] Wyszeski G und Stiles W. *Color Science: Concepts and Methods, Quantitative Data and Formulae*. John Wiley and Sons, New York, USA, 1982.
- [WSV97] Wiedenmann G, Scheingraber H und Voges W. Source detection with the scaling index method. In VD Gesu, M Duff, A Heck, M Maccarone, L Scarsi und H Zimmermann, Herausgeber, *Proceedings of the Fifth Workshop on Data Analysis in Astronomy*, S. 203–211. World Scientific Publishing Co., 1997.

- [Zin90] Zink C. *Pschyrembel Klinisches Wörterbuch*. Walter de Gruyter, 256. Auflage, 1990.
- [ZPA95] Zabrodsky H, Peleg S und Avnir D. Symmetry as a Continuous Feature. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 17(12):1154–1166, 1995.

Danksagung

An dieser Stelle möchte ich all denjenigen meinen herzlichen Dank aussprechen, die zum Gelingen dieser Arbeit beigetragen haben.

Bei meinem Doktorvater Prof. Dr. Dr. h. c. Wilfried Brauer möchte ich mich für sein großes Engagement bei der Betreuung dieser Arbeit bedanken. Die Diskussionen mit ihm und seine Anregungen waren für mich sehr wertvoll.

Prof. Dr. Gregor Morfill hat mir die Chance gegeben dieses Thema zu bearbeiten. Stets ansprechbar, habe ich bei ihm immer Unterstützung erhalten. Er bot mir die Möglichkeit, selbstständig zu arbeiten, war aber auch stets zu Diskussionen bereit, aus denen viele wertvolle Anregungen entstanden.

Besonders herzlich möchte ich mich bei Dr. Wolfram Bunk bedanken, der diese Arbeit kritisch und konstruktiv begleitet hat. Dieser Dank bezieht sich nicht nur auf seine wertvolle fachliche Mitarbeit, sondern auch auf seine freundschaftliche Art, die ein ideales Arbeitsklima ermöglichte. Danke!

Aus der kollegialen Zusammenarbeit mit PD Dr. Alexander Horsch konnte ich viele wertvolle Anregungen gewinnen. Prof. Dr. Wilhelm Stolz schulde ich Dank für die sehr angenehme Zusammenarbeit und seine Geduld, einem Nicht-Mediziner die dermatologischen Hintergründe der Melanom-Problematik näherzubringen. Prof. Dr. Wolfgang Abmayr gebührt mein Dank für seine Anregungen in der Bildverarbeitung, Stefan Hergeth für die gute Zusammenarbeit sowie für seine wertvollen Hinweise bei den Bildverarbeitungsalgorithmen. Auch wenn er die vorliegende Arbeit nur kurz begleitet hat, möchte ich meinen Dank auch an Dr. Dominik Dersch, mittlerweile in Australien, richten. Mit Dr. Christoph Räth konnte ich viele anregende Diskussionen nicht nur über Strukturcharakterisierung führen. In den Gesprächen mit Dr. Matthias Scherf habe ich wertvolle Hinweise für den Themenbereich Klassifikation und Merkmalsauswahl erhalten. Aus den Diskussionen mit Dr. Till Brychcy konnte ich tiefere Erkenntnisse über neuronale Netze gewinnen. "Danke" auch an meine Zimmerkollegin Dr. Andrea Bernklau, die mit ihrer freundlichen Art den Büroalltag angenehm gemacht hat. Das *Deutsche Zentrum für Luft- und Raumfahrt* hat das Projekt im Rahmen des Technologietransferprogramms finanziell unterstützt. Insbesondere danke ich Dr. Bachem für sein Engagement!

Dem *Burghauser Kreis* möchte ich danken, auch wenn er in fachlicher Hinsicht mit dieser Arbeit nichts zu tun hatte. Aber gerade der private Ausgleich war für mich in dieser Zeit sehr wichtig. Danke also an Roland, Nina, Peter, Esther, Guido und Petra!

Schließlich möchte ich mich sehr herzlich bei meinen Eltern bedanken, bei denen ich stets Geduld und Unterstützung gefunden habe.