




Adaptive Verfahren zur automatischen Bildverbesserung kernspintomographischer Bilddaten als Vorverarbeitung zur Segmentierung und Klassifikation individueller 3D-Regionen des Gehirns

Joaquin Castellanos

Forschungszentrum Jülich GmbH
Zentralinstitut für Elektronik (ZEL)

**Adaptive Verfahren zur automatischen
Bildverbesserung kernspintomographischer
 Bilddaten als Vorverarbeitung zur
Segmentierung und Klassifikation
individueller 3D-Regionen des Gehirns**

Joaquin Castellanos

Schriften des Forschungszentrums Jülich
Reihe Gesundheit / Health

Band / Volume 9

ISSN 1866-1785

ISBN 978-3-89336-539-5

Bibliografische Information der Deutschen Nationalbibliothek.
Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der
Deutschen Nationalbibliografie; detaillierte Bibliografische Daten
sind im Internet über <<http://dnb.d-nb.de>> abrufbar.

Herausgeber Forschungszentrum Jülich GmbH
und Vertrieb: Zentralbibliothek, Verlag
 D-52425 Jülich
 Telefon (02461) 61-5368 · Telefax (02461) 61-6103
 e-mail: zb-publikation@fz-juelich.de
 Internet: <http://www.fz-juelich.de/zb>

Umschlaggestaltung: Grafische Medien, Forschungszentrum Jülich GmbH

Druck: Grafische Medien, Forschungszentrum Jülich GmbH

Copyright: Forschungszentrum Jülich 2008

Schriften des Forschungszentrums Jülich
Reihe Gesundheit / Health Band / Volume 9

D 188 (Diss., FU Berlin, 2008)

ISSN 1866-1785
ISBN 978-3-89336-539-5

Vollständig frei verfügbar im Internet auf dem Jülicher Open Access Server (JUWEL)
unter <http://www.fz-juelich.de/zb/juwel>

Alle Rechte vorbehalten. Kein Teil des Werkes darf in irgendeiner Form (Druck, Fotokopie oder
in einem anderen Verfahren) ohne schriftliche Genehmigung des Verlages reproduziert oder
unter Verwendung elektronischer Systeme verarbeitet, vervielfältigt oder verbreitet werden.

Inhaltsverzeichnis

Inhaltsverzeichnis	i
Abstract	v
Kurzfassung	vi
1 Einleitung	1
1.1 Überblick	1
1.2 Zielsetzung der Arbeit	4
2 Grundlagen	5
2.1 Magnetresonanztomographie (MRT)	5
2.1.1 <i>Physikalische Grundlagen</i>	5
2.1.2 <i>Räumliche Kodierung des MR-Signals</i>	10
2.1.3 <i>Untersuchungstechniken (Bildgebungssequenzen)</i>	12
2.1.4 <i>Bildgewichtung</i>	15
2.1.5 <i>Rauscheigenschaften der MRT</i>	16
2.2 Rauschunterdrückungsmethoden in der Bildverarbeitung	19
2.2.1 Lineare Rauschunterdrückungsmethoden	20
2.2.2 Nichtlineare Rauschunterdrückungsmethoden	20
3 Untersuchung anisotroper Diffusionsfilter	22
3.1 Stand der Forschung (Technik)	22
3.1.1 <i>Perona-Malik Funktionen</i>	23
3.1.2 <i>Weitere Diffusionsfunktionen</i>	25
3.1.3 <i>Diskrete Implementierung</i>	27
3.2 Rauschunterdrückung	30
3.3 Parameter der anisotropen Diffusionsfilter	32

3.3.1	<i>Methode zur Parameterjustierung</i>	33
4	Entwurf und Implementierung einer automatischen Rauschunterdrückungsmethode	36
4.1	Überblick	36
4.1.1	<i>Applikationen adaptiver Filter</i>	37
4.1.2	<i>Eigene Konfiguration</i>	37
4.2	Implementierung des Verfahrens und Softwaresystem	47
4.2.1	<i>Adaptive Filterung</i>	48
4.2.2	<i>Evaluierung der Bildverbesserung</i>	49
4.2.3	<i>Parameteroptimierung</i>	51
4.2.4	<i>Rechenzeit</i>	53
5	Evaluation der Methode anhand von Testdaten	54
5.1	Testdaten	54
5.2	Bewertungsmethoden	56
5.3	Ergebnisse und Diskussion	58
5.3.1	<i>Ergebnisse des automatisierten Verfahrens im Vergleich zu anderen Rauschunterdrückungsfiltren</i>	58
5.3.2	<i>Nachweis der optimalen Parameter bezüglich der Ergebnisse der Evaluierungsfunktion</i>	60
5.3.3	<i>Einfluss der Anzahl von untersuchten Schichten im Verfahren</i>	61
5.3.4	<i>Einfluss der „festgelegten“ Filterparameter in der Parameteroptimierung</i>	63
5.3.5	<i>Ergebnis der multispektralen Filterung</i>	69
5.3.6	<i>Untersuchung anhand realer MRT-Bilddaten</i>	71
5.3.7	<i>Zusammenfassung und Diskussion</i>	73
6	Evaluation der Methode anhand realer Bilddaten von Patienten und Kleintieren	78

6.1	Filterung und Auswertung realer MRT-Patientenbilddaten	78
6.1.1	<i>Auswertung</i>	80
6.2	Vorverarbeitung diffusionsgewichteter Bilder zur Hirninfarkt-Segmentierung	81
6.3	Vorverarbeitung von Epilepsie-Datensätzen für die medizinische Visualisierung	83
6.4	Vorverarbeitung der MRT-Daten für die Segmentierung kortikaler und subkortikaler Strukturen	85
6.5	Semiautomatische Segmentierung von ROIs/VOIs in Kleintierbilddaten	87
6.6	Diskussion	89
7	Zusammenfassung und Ausblick	90
	Literaturverzeichnis	93

Abstract

State-of-the-art digital image noise reduction does not have a procedure or algorithm combination with predefined parameters capable of reliably and successfully processing complex medical images of different image content, so that noise in the image is reduced while the anatomical structures are preserved. However, precisely this preprocessing step is required by segmentation, classification or visualization algorithms of medical images to allow greater flexibility when using such algorithms. Most of the currently used de-noising procedures depend on manual adjustment of the parameters. Only a few attempts were made to automate this adjustment, by defining the filter parameters according to the results of different estimation procedures.

This thesis describes an iterative noise suppression procedure which can provide a fully automatic adjustment of the filter parameters by using a new optimization method. The filters used to process the medical images were anisotropic diffusion filters. These filters were designed to smooth images while preserving the edges between image regions. The evaluation method used determines image improvement indirectly by comparing the characteristics of the already suppressed noise to those from the acquisition system.

This procedure can process 2D and 3D data sets and also offers the possibility of using multispectral information for better edge preservation.

Synthetic and real MRI data were used to evaluate this automatic method. In a first step, T1-weighted averaged and mathematically generated T1-, T2- and PD-weighted software phantoms were used to test the main characteristics and performance of the procedure. The results were then compared to those of other commonly used non-linear filters. As a final step, samples from real data sets of different medical studies were processed and analyzed to demonstrate the advantage of this automatic procedure in practical applications.

Kurzfassung

Der Stand der Technik im Bereich der Rauschunterdrückung in digitalen Bildern erlaubt es nicht, ein Verfahren oder eine Kombination von mehreren Algorithmen mit einer festen Parametereinstellung zuverlässig und erfolgreich auf unterschiedliches medizinisches Bilddatenmaterial mit komplexeren Inhalten anzuwenden, so dass das Rauschen unterdrückt wird, ohne die signifikanten anatomischen Strukturen zu modifizieren. Genau dies ist aber als Vorverarbeitungsschritt zur Segmentierung, Klassifikation und Visualisierung medizinischer Bilddaten gefordert, um eine hohe Flexibilität in der Anwendung solcher Algorithmen zu ermöglichen. Die meisten der bisher verwendeten Rauschunterdrückungsverfahren sind auf eine manuelle Parametrierung angewiesen. Nur wenige Ansätze existieren, um diesen Vorgang zu automatisieren und die Filterparameter anhand verschiedener Schätzverfahren einzustellen.

In dieser Dissertation wird ein iteratives Rauschunterdrückungsverfahren vorgestellt, welches voll automatisch die Parametrierung der digitalen Filter durch eine neue Optimierungsmethode bereitstellen kann. Zur Glättung der Bilder werden anisotrope Diffusionsfilter angewendet, die für die Kantenerhaltung während der Rauschunterdrückung entwickelt wurden. Die Evaluierungsfunktion ermittelt in indirekter Weise die Bildverbesserung, indem die Eigenschaften des bereits unterdrückten Rauschens mit den Eigenschaften des Rauschens des Bildgebungsverfahrens verglichen werden. Das Verfahren ist in der Lage, 2D und 3D Bilddatensätze zu verarbeiten, und bietet die Möglichkeit, auch multispektrale Informationen zu nutzen, um eine bessere Erhaltung der Bildkanten zu erreichen. Zur Evaluierung der automatischen Methode wurden sowohl synthetische als auch reale MRT-Daten verwendet. Zunächst wurden reale T1-gewichtete Daten (gemittelte Referenz aus 25 Aufnahmen) und mathematisch generierte T1-, T2- und PD-gewichtete Softwarephantome verwendet, um die Leistung und Eigenschaften des automatischen Verfahrens zu testen. Die erzielten Ergebnisse wurden dann mit den Ergebnissen anderer häufig verwendeter nichtlinearer Rauschunterdrückungsmethoden verglichen. Abschließend wurden Beispiele realer Datensätze verschiedener medizinischer Fragestellungen verarbeitet und evaluiert, um die Nutzung des automatischen Verfahrens in praktischen Anwendungen zu demonstrieren.

1 Einleitung

1.1 Überblick

Ein fundamentales Werkzeug in der Analyse medizinischer Bilddaten ist die Segmentierung. Die Anwendungsbereiche schließen unter anderem die Detektion von Tumoren, die chirurgische Planung und Simulation, die Vermessung von Tumorarealen und deren Überwachung während der Therapie ein [1-21]. In einigen Anwendungsgebieten werden die Bildelemente (Pixel bzw. Voxel) anatomischer Regionen segmentiert [2, 3, 6-10, 19-21], während in anderen Anwendungsbereichen die Elemente pathologischer Regionen, wie z.B. von Tumoren oder Multiple Sklerose Läsionen, erfasst werden [11-18].

Für die Neurowissenschaften und die Diagnostik von Hirnerkrankungen ist die Entwicklung von Algorithmen zur automatischen und semiautomatischen Segmentierung anatomischer und pathologischer Strukturen des Gehirns ein wichtiger Forschungsschwerpunkt der medizinischen Bildverarbeitung geworden. So werden zahlreiche Projekte durchgeführt, wie z. B. zur Generierung von Template Atlanten [3, 9], die Entwicklung von Methoden und Algorithmen zur automatischen Segmentierung [10-13, 19-21] und zur Generierung individueller 3D Atlanten des menschlichen Gehirns auf Basis T1-gewichteter oder multispektraler kernspintomographischer (MRT) Bilddaten [19-21] oder die automatische Segmentierung von Gehirnfarkten anhand diffusionsgewichteter MRT-Bilddaten [13, 14, 22]. Wegen der herausragenden Differenzierbarkeit des Weichteilgewebes, der hohen Volumenauflösung und der Tatsache, dass keine Strahlenbelastung auftritt, werden die MRT-Aufnahmen gegenüber anderen bildgebenden Techniken, wie der Computertomographie (CT), bevorzugt. Da die Segmentierungsergebnisse die Grundlage funktioneller, pathologischer oder morphometrischer Analysen darstellen, ist deren Exaktheit von entscheidender Bedeutung für die Genauigkeit der hierauf beruhenden Analysen.

Unglücklicherweise sind viele Segmentierungsverfahren besonders empfindlich gegenüber Bildstörungen wie Bewegungsartefakten, Inhomogenitäten oder Bildrauschen [23]. Diese Störungen verringern die Genauigkeit und Reproduzierbarkeit der gewonnenen Ergebnisse. Aus diesem Grund werden häufig Vorverarbeitungsverfahren angewandt, um die Qualität

der Daten zu verbessern. Zur Rauschunterdrückung sind zahlreiche Verarbeitungsalgorithmen und Techniken entwickelt worden. Diese umfassen aufnahmebasierte Rauschunterdrückungsmethoden [24] sowie die Anwendung digitaler Bildglättungsfilter [25]. Bildglättungsfilter haben den deutlichen Vorteil, unabhängig vom physikalischen Aufnahmesystem (MRT, CT, usw.) arbeiten zu können, da nur Information über die Eigenschaften des Rauschens beim jeweiligen Bildgebungssystem nötig ist.

Digitale lineare Verfahren zur Rauschunterdrückung, wie z.B. Tiefpassfilter [26], die eine globale Glättung der Bilddaten bewirken, führen zu Unschärfen besonders im Bereich der komplexen Grenzen anatomischer Regionen und damit zu späteren Detektions- und Lokalisationsproblemen. Nichtlineare Verfahren, wie z.B. Median [27] oder K-Nearest-Neighbour (KNN) Filter [28], erlauben eine erkennbare Verbesserung in der Rauschunterdrückung, jedoch stellen die begrenzten Parametrierungsmöglichkeiten eine Einschränkung für die Optimierung der Bildergebnisse dar.

Anisotrope Diffusionsfilter ermöglichen andererseits eine Rauschunterdrückung bei besserer Kantenerhaltung dank ihrer Glättung, die nicht über die Kanten hinaus geht. Die anisotrope Diffusion wurde von Perona und Malik [29] im Jahre 1990 eingeführt, wobei die Bildglättung vom physikalischen Prozess der Wärmeleitung (Diffusion) abgeleitet wurde [30]. Die Intensitätswerte jedes Elementes eines Bildes (Pixel bzw. Voxel) werden anhand der Intensität der benachbarten Pixel berechnet, wobei die Diffusionsfunktion den Einfluss der benachbarten Pixel in Abhängigkeit der lokalen Gradienten bestimmt. So werden die homogenen Regionen geglättet, während die Glättung im Bereich der Kanten gestoppt wird.

Gerig et al. [31] nutzten die Perona-Malik Diffusionsfunktionen, um das Rauschen in kernspintomographischen Bilddaten zu unterdrücken. Black et al. [32] beschrieben in ihrer Arbeit die Beziehung zwischen der anisotropen Diffusion und der Theorie der „robusten Statistik“. Eine robuste Diffusionsfunktion auf Basis des „Tukey’s biweight estimator“ ist aus dieser Arbeit entstanden. Weitere Diffusionsfunktionen wurden von Charbonnier [33], Weickert [34] und Monteil [35] vorgeschlagen. Alle diese Diffusionsfunktionen bewirken die Homogenisierung der Intensitätswerte innerhalb der Bildregionen und verhindern die Glättung über die Regionengrenzen hinaus.

Die Diffusionsfilter haben zwei wesentliche Parameter, nämlich den *Diffusionsfaktor* und die *Anzahl der Iterationen*. Der *Diffusionsfaktor* legt das Intensitätsniveau des Gradienten fest, bei dem die stärkste Glättung erfolgt. Um die Diffusionsfilter effektiv als Rauschunterdrückungsfilter anzuwenden, sollte der *Diffusionsfaktor* in Abhängigkeit des Rauschniveaus mit Rücksicht auf die Gradientenintensität der Kanten der interessierenden anatomischen Strukturen definiert werden [32, 36]. Andererseits bestimmt der Parameter *Anzahl der Iterationen* wie oft der Diffusionsprozess auf das Bild angewendet werden soll.

Eine erfolgreiche Rauschunterdrückung hängt von der optimalen Parametrierung des Filters ab. In der Literatur wird der *Diffusionsfaktor* in der Regel durch eine Abschätzung des Rauschniveaus genähert. Diese Abschätzung wird entweder durch eine statistische Auswertung der globalen Eigenschaften der Bilddaten oder durch die Berechnung der Intensitätsvarianz innerhalb verschiedener homogener Bereiche des Bilddatensatzes durchgeführt [32, 35, 37]. Die Abschätzung des Rauschens hängt dabei stark von der Komplexität des Bildinhaltes und von der Selektion der homogenen Regionen ab. Die *Anzahl der Iterationen* wurde in einigen Untersuchungen [32, 38] durch ein automatisches Abbruchkriterium festgelegt, welches die Konvergenzeigenschaften bestimmter Diffusionsfunktionen benutzt, um anhand der Anzahl der geänderten Bildelemente zwischen sukzessiven Filterungsiterationen die Filterung zu stoppen. Dies führte jedoch nicht unbedingt zu einem optimalen Ergebnis, da ein Teil der Information verloren ging. Außerdem wurde in der Literatur häufig eine manuelle Justierung der Filterparameter beschrieben.

Zurzeit existiert keine etablierte Methode, die es erlaubt, die beiden wesentlichen Parameter eines anisotropen Diffusionsfilters auf eine zuverlässige Art und Weise zu bestimmen. Deswegen werden diese Parameter meistens manuell justiert. Nachteil dieser manuellen Justierung ist, neben dem erforderlichen Zeitaufwand, die Abhängigkeit der erzielten Ergebnisse von der Qualifikation und Erfahrung der Benutzer.

Eine Bildverarbeitungsmethode, die eine automatisierte Unterdrückung des Rauschens ermöglicht und gleichzeitig eine hohe Variabilität des zugrunde liegenden Datenmaterials zulässt, sowie eine Adaptivität hinsichtlich der lokalen Bildeigenschaften gewährleistet, gibt es bisher nicht und stellt die Herausforderung dieser Arbeit dar.

1.2 Zielsetzung der Arbeit

Das Ziel der vorliegenden Arbeit ist die Entwicklung eines dreidimensional arbeitenden, adaptiven Rauschunterdrückungsverfahrens auf Basis anisotroper Diffusionsfilter zur automatischen Bildverbesserung von MRT-Bilddaten des Gehirns als Vorverarbeitungsschritt zur Segmentierung von Hirnregionen. Das Verfahren soll das Signal-Rausch-Verhältnis verbessern, ohne die Grenzen der unterliegenden anatomischen Strukturen zu ändern. Eine hohe Adaptivität soll hinsichtlich des zu verarbeitenden Datenmaterials gewährleistet werden, da die Bilddaten verschiedener Anwendungen, Institute und Kliniken verarbeitet werden sollen. Gleichzeitig sollen die lokalen Bildeigenschaften berücksichtigt werden, jedoch ohne anatomische Vorkenntnisse einzubringen, die die Flexibilität der Algorithmen einschränken könnte.

Die automatische Justierung der Filterparameter stellt dabei eine besondere Schwierigkeit dar, weil zur Optimierung der Parameter quantitative Maße zur Bestimmung der qualitativen Bildverbesserungen erforderlich sind, die zuerst entwickelt werden sollten. Besonders für medizinische Bilddaten stellt dies eine Herausforderung dar, da aufgrund der hohen anatomischen Variabilität von Individuum zu Individuum, der Variabilität der Bildeigenschaften anhand der Vielzahl von Sequenzen und Parameterkonfigurationen und der Variabilität des anatomischen Inhaltes, keine eindeutigen Referenzen zur Verfügung stehen.

Die Arbeit ist in sieben Kapitel untergegliedert. Im zweiten Kapitel werden die Grundlagen der Magnetresonanztomographie und die Mechanismen zur Entstehung des Rauschens zusammen mit einer Beschreibung der häufigsten Rauschunterdrückungsmethoden vorgestellt. In Kapitel 3 werden die theoretischen Grundlagen anisotroper Diffusionsfilter anhand der Funktionen, Implementierung und Haupteigenschaften zusammen mit den in der Literatur beschriebenen Methoden zur Justierung der Parameter präsentiert. In Kapitel 4 werden die Komponenten des entwickelten automatischen Verfahrens zur Parameterjustierung betrachtet. In Kapitel 5 werden die Untersuchungen zur Evaluierung der Leistung des Verfahrens anhand verschiedener Testdatensätze diskutiert bevor in Kapitel 6 die Anwendung der Methode anhand realer Patientenbilddaten präsentiert wird. Abschließend wird in Kapitel 7 mit einer Zusammenfassung und einem kurzen Ausblick die mögliche Erweiterung und Verbesserung des aktuellen Verfahrens diskutiert.

2 Grundlagen

2.1 Magnetresonanztomographie (MRT)

Die Magnetresonanztomographie (MRT), auch als Kernspintomographie bezeichnet, ist ein bildgebendes Verfahren zur in-vivo Abbildung des Körperinneren. Das Verfahren erlaubt die präzise und differenzierte Darstellung von Weichteilen, Organen und Gefäßen ohne schädliche Röntgenstrahlen. Das Verfahren wurde 1946 von Bloch [39] und Purcell [40] entdeckt und von Lauterbur [41] und Mansfield [42] 1973 weiterentwickelt. Das erste brauchbare Bild des menschlichen Organismus wurde im Jahr 1977 von Professor Raymond Damadian erstellt [43] und seit Anfang der 1980er Jahre wird die MRT in der medizinischen Diagnostik verwendet.

Generell ist die MRT aufgrund der hohen Kontraste von Weichteilgewebe besonders für den Nachweis tumoröser, entzündlicher und traumatischer Erkrankungen geeignet [44].

2.1.1 Physikalische Grundlagen

Die Materie besteht aus Atomen, die sich zu Molekülen zusammensetzen können. Jedes Atom besteht wiederum aus einer Elektronenhülle und dem Atomkern. Der Atomkern enthält die positiv geladenen Protonen sowie elektrisch neutrale Neutronen.

Für die Magnetresonanztomographie (MRT) spielen die Atome eine Rolle, die aufgrund ihrer ungeraden Nukleonenzahl (Protonen- und/oder Neutronenzahl) ein nach außen wirkendes magnetisches Moment besitzen. Insbesondere die in großer natürlicher Häufigkeit vorhandenen Wasserstoffatome ermöglichen die Erstellung gewebskontrastreicher medizinischer Bilder, da der größte Anteil des menschlichen Körpers aus Wasser und Fett (Fett besteht hauptsächlich aus Wasserstoff- und Kohlenstoffatomen) besteht. Außerdem lassen sich andere schwerere magnetische Kerne, wie z.B. ^{13}C , ^{19}F , ^{23}Na , ^{31}P , trotz ihrer geringeren Konzentration im biologischen Gewebe nachweisen [45].

2.1.1.1 Magnetisierung

Die Bewegung der Protonen innerhalb des Atomkerns erzeugt durch den Eigendrehimpuls $\vec{I}$ ein kleines atomares Magnetfeld. Das daraus resultierende magnetische Dipolmoment $\vec{\mu}$ ist definiert als:

$$\vec{\mu} = \gamma \hbar \vec{I} \quad (2.1)$$

γ die Proportionalitätskonstante oder gyromagnetisches Verhältnis (Tabelle 2.1).

$\hbar$ Plancksches Wirkungsquantum ($\hbar = h / 2\pi = 1.055(10)^{-34} \text{Ws}^2 / \text{rad}$)

$\vec{I}$ Kernspin mit einem Betrag gleich $\sqrt{I(I+1)}$ (I = Spinquantenzahl)

Isotope mit Kernspin	Molare Konzentration (mol / L)	Gyromagnetisches Verhältnis γ (MHz/Tesla)	Gyromagnetischer Faktor γ (rad(10) ⁶ /sTesla)	Empfindlichkeit (bezogen auf ¹ H)
¹ H	99.0	42.58	267.54	1
¹⁴ N	1.6	3.08	19.35	0.001
³¹ P	0.35	17.24	108.32	0.066
¹³ C	0.10	10.71	67.29	0.016
²³ Na	0.078	11.26	70.75	0.093
³⁹ K	0.045	1.99	12.50	0.0005
¹⁷ O	0.031	5.77	36.25	0.029
² H	0.015	6.53	41.02	0.010
¹⁹ F	0.0066	40.05	251.64	0.833

Tabelle 2.1: Im Gewebe vorhandene Isotope mit Kernspin [46].

Die Stärke des Erdmagnetfeldes (ca. 50 μTesla) reicht nicht aus, um die willkürliche Orientierung der Kernspins zu verändern. In einem Spinensemble ist jeder Atomkern von anderen magnetischen Momenten umgeben, die in stetiger thermischer Bewegung sind und ein ständig wechselndes magnetisches Störfeld erzeugen. Die makroskopische Magnetisierung $\vec{M}$, die sich aus den magnetischen Kernmomenten einer Probe ergibt, lässt sich beschreiben bezogen auf das Probenvolumen V durch:

$$\vec{M} = \frac{1}{V} \sum_{i=0}^{N-1} \vec{\mu}_i \quad (2.2)$$

Mit N der Gesamtzahl der magnetischen Momente in der Probe. Der Quotient $\rho = N/V$ gibt die Spindichte der Atomkerne der Probe an [47]. Bei Raumtemperatur ist de facto diese Magnetisierung gleich Null. Befindet sich aber der Atomkern in einem zusätzlichen

starken Magnetfeld (B_0), so richten sich die magnetischen Dipolmomente bevorzugt entlang der Orientierung des Magnetfeldes aus (Bild 2.1).




Bild 2.1: Darstellung des Einflusses des externen Magnetfeldes auf die Orientierung des Atomkerns: (a) Ausrichtung und Präzession eines einzelnen Atomdipols, (b) Ausrichtung der Atomkerne in paralleler und anti-paralleler Orientierung und Nettomagnetisierung (M_z) des Ensembles, (c) Ansicht der Präzession auf der Transversalebene.

Aufgrund der unterschiedlichen Energieniveaus der Atomkerne richtet sich nur ein Teil der magnetischen Dipolmomente in Richtung des Magnetfeldes (parallel / energiearm) aus, der Rest richtet sich in entgegengesetzter Richtung (antiparallel / höhere Energie) aus (Bild 2.1b). Die sich daraus einstellende potenzielle Energie der Atomkerne ergibt sich zu [45]:

$$E_m = -\hbar \gamma m B_0 \quad (2.3)$$

Die magnetische Quantenzahl m für Wasserstoffatome ist $\pm 1/2$ für den hohen bzw. niedrigen Energiezustand. Die Energiedifferenz zwischen beiden Zuständen beträgt:

$$\Delta E = \hbar \gamma B_0 \quad (2.4)$$

mit B_0 als Magnetfeld (Tesla) und dem gyromagnetischen Verhältnis γ (Tabelle 2.1).

Im thermischen Gleichgewicht ist innerhalb des Magnetfeldes B_0 ein leichter Überschuss an parallel (energiearmen) ausgerichteten Momenten gegeben, was zu einer makroskopischen Magnetisierung M_z in Richtung des B_0 -Feldes (Längsmagnetisierung) führt (Bild 2.1b). Das Verhältnis zwischen der Anzahl von Kernen im parallelen und antiparallelen Spinzustand wird durch die Boltzmann-Verteilung beschrieben [45]:

$$\frac{N_{\text{anti-parallel}}}{N_{\text{parallel}}} = \exp\left(-\frac{\Delta E}{kT}\right) \quad (2.5)$$

Dabei ist k als Boltzmann-Konstante ($1.3805 \cdot 10^{-23} \text{ J/}^\circ\text{K}$) und T als absolute Temperatur (Kelvin) definiert. Nachfolgend wird ausschließlich auf die Atome im Überschuss ($N_{\text{parallel}} - N_{\text{anti-parallel}}$) und ihren makroskopischen Magnetisierungseffekt Bezug genommen.

Die Ausrichtung der Atomkerne im Magnetfeld kann nie vollständig parallel zur Achse des Magnetfeldes B_0 erfolgen, da sich durch die Eigenrotation immer ein Winkel ergibt [47]. Daraus resultiert eine Präzession der Kernmagnetisierung um die Richtung des Magnetfelds mit der Resonanzfrequenz ω_L (Bild 2.1a). Diese Resonanzfrequenz, auch *Larmor-Frequenz* genannt, ist proportional mit der Feldstärke des B_0 -Feldes, sowie dem gyromagnetischen Verhältnis [45]:

$$\omega_L = \gamma B_0 \quad (2.6)$$

Die Präzessionsbewegung der Atomkerne im thermischen Gleichgewicht ist zueinander unkorreliert, dadurch heben sich die transversalen Magnetisierungskomponenten der Kernspins gegenseitig auf [47]. So entsteht unter diesen Bedingungen keine makroskopische Magnetisierung senkrecht zum Magnetfeld B_0 (Quermagnetisierung) Bild 2.1c.

2.1.1.2 Magnetresonanz und Relaxation

Durch Einstrahlung eines Hochfrequenz (HF)-Impulses, den eine Antenne senkrecht zur Magnetfeldachse erzeugt, wird ein zeitlich veränderliches äußeres Hochfrequenzfeld $\vec{B}_1$ der Frequenz $\omega_I = \omega_L$ generiert. Hierdurch wird das Gleichgewicht des Spinensembles gestört, um in der makroskopischen Magnetisierung $\vec{M}$ einen Drehwinkel α zu induzieren.

$$\alpha = \gamma B_1 \tau \quad (2.7)$$

Im Gegensatz zum atomaren magnetischen Moment, das nur diskrete Orientierungen bezüglich der Richtung des B_0 -Feldes einnehmen kann, kann die Auslenkung der Magnetisierung $\vec{M}$ beliebige Richtungen je nach eingestrahelter Energie (Amplitude (B_1) und Dauer (τ) des Anregungsimpulses) einnehmen [47].

Durch das HF-Signal wird ebenfalls die Phasenlage der Präzessionsbewegung der Kernspins synchronisiert. Das gesamte Spinensemble präzediert mit der Frequenz ω_L und so entsteht eine rotierende transversale makroskopische Magnetisierung M_{xy} .

Beide Einzelüberlegungen zusammen ergeben eine rotierende makroskopische Kernmagnetisierung $\vec{M}$, welche im ortsfesten Bezugssystem eine schraubenförmige Bahn auf einer Kugel um $\vec{B}_0$ beschreibt, dank der Überlagerung der durch das B_1 -Feld verursachten Drehbewegung und der synchronisierten Präzessionsbewegung ω_L .

Nach Abschalten des HF-Impulses relaxiert der Magnetisierungsvektor wieder in seine Gleichgewichtslage zurück. Zerlegt man die Magnetisierung $\vec{M}$ wiederum in eine zu $\vec{B}_0$ parallele (z-Richtung) und orthogonale Komponente (x-y-Ebene), so kann der Relaxationsprozeß durch die Bloch-Gleichung beschrieben werden [48]. Die Relaxation der Längs- (T_1 -Zeit) und Quermagnetisierung (T_2 -Zeit) folgt einer exponentiellen Funktion, wie die Lösung der Bloch-Gleichung [45] zeigt:

$$M_z(t) = M_0 \left(1 - e^{-(t/T_1)} \right) \quad (2.8)$$

$$M_{xy}(t) = M_0 e^{(-i\omega_L t - (t/T_2))} \quad (2.9)$$

Die Längsrelaxation (T_1 -Relaxation) entspricht dem Abfall des angeregten Systems in den Zustand des thermischen Gleichgewichts. So nimmt die Magnetisierung M_z in Richtung des Hauptmagnetfeldes B_0 zu (Bild 2.2a). Da T_1 hauptsächlich von der Abgabe der Energie an die umgebenden Teilchen (Gitter) abhängt, wird T_1 als Spin-Gitter-Relaxationszeit bezeichnet. T_1 entspricht der Zeit, in der die longitudinale Magnetisierung M_z nach einem 90° -Impuls auf 63% ihres Wertes vor der Anregung angestiegen ist [47].




Bild 2.2: Zeitlicher Verlauf der Magnetisierungskomponenten: (a) Zerfall der Längsmagnetisierung nach der Anregung, (b) Desynchronisation der Phasenlage der Quermagnetisierung und Kerninduktionssignal nach einem 90° -Impuls (Querrelaxation).

Im Gegensatz dazu beschreibt die Querrelaxation (T_2 -Relaxation) den Zerfall der Spinensemblesynchronisation, die zu einem Abfall der transversalen Magnetisierungskomponente führt (Bild 2.2b). Der Verlust an Phasenkohärenz ist durch die Interaktionen

der Spins innerhalb der Atomanordnung zurückzuführen, deswegen wird T_2 als Spin-Spin-Relaxationszeit bezeichnet. T_2 in Magnetfeldern mit sehr hoher Homogenität entspricht der Zeit, bei der die Quermagnetisierung auf 37% ihres ursprünglichen Wertes nach einer 90° -Impulsanregung zurückgegangen ist [47]. Inhomogenitäten des Magnetfeldes B_0 , die durch die Maschine selbst oder durch den Körper der untersuchten Person verursacht wurden, beschleunigen den Phasenzерfall. Diese Relaxationszeit mit dem kombinierten Effekt beider Störungen wird als T_2^* -Relaxationszeit bezeichnet [47, 49]. Die T_1 -Relaxationszeit hängt wesentlich von der Stärke des äußeren Magnetfeldes B_0 und von der Wärmeleitfähigkeit des Gewebes ab [50]. Die T_2 -Relaxationszeit ist hingegen von der chemischen Bindung der magnetischen Kerne (Wasserstoffs) [50] und von der Homogenität des Hauptmagnetfeld B_0 [47, 49] abhängig.

Durch geeignete Messsequenzen können die generierten Bilddaten bzgl. dieser Relaxationszeiten gewichtet werden. Da sich diese Relaxationszeiten in den verschiedenen Geweben unterscheiden [50], lassen sie sich bei der Bildgebung zur Generierung von Kontrasten nutzen. In Tabelle 2.2 sind die relative Spindichte ρ und die T_1 -, T_2 -Relaxationszeiten für einige wichtige biologische Gewebearten angegeben.

Gewebe	T_1 in ms	T_2 in ms	ρ (%)
Muskel	733±130	47±13	82.4
Fett	241±67	84±36	88.1
Graue Hirnsubstanz	813±138	101±13	84.4
Weißer Hirnsubstanz	683±116	92±22	69.9

Tabelle 2.2: Gewebespezifische Relaxationszeiten und relative Spindichte bei 1T-MRT [50, 51].

2.1.2 Räumliche Kodierung des MR-Signals

Um eine Bildrekonstruktion durchführen zu können, muss die Quermagnetisierung der abgestrahlten Zerfallsenergie den einzelnen Volumenelementen (Voxel) zugeordnet werden. Dazu werden magnetische Gradientenfelder (G_x , G_y , G_z) dem Hauptmagnetfeld B_0 überlagert [47]. Diese Überlagerung erzeugt eine bekannte Variation des Magnetfeldes entlang des Volumens, die wiederum eine korrespondierende Änderung der Larmorfrequenz ω_L in Richtung der Gradienten erzeugt.

Bei der schichtweisen Kodierung (2D) wird ein Schichtselektionsgradient so angelegt, dass eine Änderung der Resonanzfrequenz über das zu messende Volumen in Gradientenrichtung entsteht. Anschließend kann durch Anlegen des HF-Signals eines schmalen Frequenzintervalls eine Schicht dieses Volumens selektiert werden, die mit derselben Larmor-Frequenz schwingt (Signalkodierung) [24, 47]. Der Gradient wird normalerweise in Richtung des Hauptmagnetfeldes eingeprägt (G_z). Ein scharfer Übergang zwischen angeregter Schicht und angrenzenden nicht-angeregten Bereichen kann durch Verwendung eines geeigneten elektromagnetischen Wechselfeldes erzielt werden. Normalerweise folgt diese Anregung einer $\sin(x)/x$ Funktion [45].

Ein zweiter Gradient (G_x), der orthogonal zum z-Gradienten steht, wird nach der Anregung und vor dem Auslesen des Echosignals (Abschn. 2.1.3.1) kurz erzeugt und bewirkt eine kontrollierte Desynchronisation der Phasenlage der Magnetisierungsanteile, so dass in jeder Zeile der angeregten Schicht die Präzession der Spinpakete eine andere Phasenlage besitzen, d.h., es entsteht eine definierte Phasenverschiebung der Spinpakete zwischen den einzelnen Zeilen [47]. Auf diese Weise wird die räumliche Information entlang der X-Achse kodiert (Phasenkodierung).

Der dritte Gradient (G_y) wird während der Messung des Echosignals senkrecht zu den beiden anderen geschaltet. Er sorgt dafür, dass der Magnetisierungsanteil jeder Spalte der angeregte Schicht eine andere Resonanzfrequenz annimmt (Frequenzkodierung).

Alle drei Gradienten bewirken zusammen eine Kodierung des Signals in drei verschiedenen Raumebenen. Das empfangene Signal gehört zu einer bestimmten Schicht des Körpers (2D-MR-Tomographie) und besteht aus einer Kombination unterschiedlicher frequenz- und phasenkodierter Signalanteile. Für den Aufbau des Bildes wird die Bildgebungssequenz (Abschn. 2.1.3) N-mal für verschiedene Werte des Phasenkodiergradienten $G_x = n\Delta G_x$ ($1 \leq n \leq N$) wiederholt, wobei das Frequenzspektrum des gemessenen Resonanzsignals bei jedem Sequenzdurchgang N-mal zu den Zeiten $t_m = m\Delta t$ ($1 \leq m \leq N$) gespeichert wird [47]. Auf diese Weise entsteht eine $N \times N$ Rohdatenmatrix, die durch eine inverse 2D Fourier-Transformation in ein 2D MRT-Bild rekonstruiert wird. Dieses Verfahren kann auf das gesamte Körpervolumen erweitert werden (3D-MR-Tomographie), indem der Schicht-Selektionsgradient durch einen Phasenkodiergradienten ersetzt wird. Damit wird nicht nur eine einzelne Körperschicht, sondern das gesamte Volumen mit dem HF-Impuls angeregt [24, 47].

2.1.3 Untersuchungstechniken (Bildgebungssequenzen)

Im folgenden Abschnitt werden Untersuchungstechniken beschrieben, die eine Abfolge von HF-Anregungen, Gradientenschaltungen und Signalmessungen beinhalten, die nötig sind, um eine Darstellung des zu untersuchenden Gewebes zu generieren.

2.1.3.1 Spin-Echo-Methode

Durch die Generierung des z-Gradienten und der gleichzeitigen Einkopplung eines 90° Anregungsimpulses wird im ersten Schritt eine Schicht selektiert und die Nettomagnetisierung gekippt (M_{xy}). Die einzelnen Vorzugsrichtungen der Spins driften mit einer Zeitkonstanten T_2^* auseinander. Nach einer Wartezeit von $1/2$ TE (Echozeit) wird ein 180° -Impuls eingeprägt, um den Zerfall der Spinsynchronisation umzukehren. In dieser Phase wird die Phasenlage der Präzessionsbewegung der individuellen Spins zueinander gespiegelt (Refokussierung). Dies verursacht eine Steigerung der Quermagnetisierung und des zugehörigen in die Empfangsspule induzierten elektromagnetischen Signals (Spinecho) [47]. Die maximale Amplitude des Empfangssignals wird nach einer Echozeit (1 TE) erreicht, nachdem alle Spins wieder parallel zueinander ausgerichtet sind. Zwischen der Anregung durch den 180° -Impuls und der Messung des Echos wird der Phasenkodiergradient G_x (x-Richtung) für kurze Zeit eingeschaltet.




Bild 2.3: Schematische Darstellung des Spin-Echo-Experimentes [48]. Unmittelbar nach einem 90° -Impuls sind die Magnetisierungskomponenten parallel ausgerichtet. Im weiteren Verlauf driften die Komponenten jedoch mit der Zeitkonstante T_2^* auseinander. Durch einen 180° -Impuls werden die Magnetisierungskomponenten 180° gespiegelt und nach einer Echozeit (1 TE) kommt es zu einer erneuten Phasensynchronisation der Quermagnetisierung, die als Spinecho bezeichnet wird.

Während der Messung des Spinechos wird zusätzlich der Frequenzkodiergradient (G_y) aktiviert, um die Zuordnung der Signalanteile zur Ortsinformation der Volumenelemente zu ermöglichen. Nach der Messung muss eine Repetitionszeit TR abgewartet werden, bis das Spin-System halbwegs relaxiert ist, um eine neue Pulsfolge zu starten.




Bild 2.4: Timing-Diagramme der: a) 2D Spin-Echo-Sequenz [48], b) 2D FLASH-Sequenz [47].

2.1.3.2 FLASH-Methode

Konventionelle Bildgebungssequenzen, die durch einen 90°-Anregungsimpuls die gesamte Längsmagnetisierung in die x-y-Ebene drehen, sollten auf den Wiederaufbau der z-Magnetisierung warten, um eine neue Pulsfolge zu starten. Dieses Problem lässt sich umgehen, indem zur Anregung des Spinsystems ein HF-Impuls mit einem Flipwinkel von $\alpha < 90^\circ$ verwendet wird, so dass nur ein Bruchteil der Längsmagnetisierung M_z in die x-y-Ebene fällt, während gleichzeitig eine relativ große Quermagnetisierung zu Verfügung steht [47]. Nach wenigen Sequenzwiederholungen wird das Spinsystem einen dynamischen Gleichgewichtszustand erreichen, der vom Anregungswinkel α , von der Repetitionszeit TR sowie von der Längsrelaxationszeit T_1 abhängt.

Die FLASH-Sequenz (Fast low angle shot) gehört zu diesen Techniken und besteht aus einem einzigen HF-Impuls mit einem Anregungswinkel $\alpha < 90^\circ$, der normalerweise zwischen 15° und 50° liegt. In 2D Sequenzen bestimmen Gradientenfelder die Schichtauswahl (G_z), die Frequenz- (G_y) und Phasenkodierung (G_x). Durch die Umpolung der Schichtauswahl- und des Frequenzkodiergradienten wird die durch die beiden Gradienten hervorgerufene Dephasierung der Quermagnetisierung kompensiert, so dass ein Gradientenecho entsteht. Die verbleibende transversale Magnetisierung wird entweder nach jeder Messung durch einen sogenannten „Gradientenspoiler“ zerstört oder durch Verwendung stochastischer Phasen der HF-Pulse (HF-Spoiling) die Ausbildung eines Gleichgewichtszustands vermieden [47]. Bei 3D-Sequenzen wird das gesamte Volumen gleichzeitig angeregt. Das Schichtauswahlgradientenfeld (G_z) wird durch ein

Phasenkodiergradientenfeld ersetzt und damit die Ortslokalisierung anhand einer N^2 -Wiederholung der Messung mit unterschiedlichen Phasenkodiertengradienten und mit Hilfe einer 3D-inversen Fouriertransformation gewährleistet. Ein Vorteil der volumetrischen Anregung ist das verbesserte Signal-Rausch-Verhältnis um den Faktor $\sqrt{N}$ [20, 45]. Eine wichtige Voraussetzung für eine Gradientenechosequenz ist die Anwendung eines möglichst homogenen Magnetfeldes. So werden die Signalverluste aufgrund der durch Feldinhomogenitäten verursachten Dephasierung minimiert. Bild 2.4b zeigt die Timing-Diagramme einer 2D FLASH-Sequenz.

2.1.3.3 MP-RAGE Methode

Diese Technik ist eine schnellere 3D Variante einer Gradienten-Echo-Sequenz. Hier wird, wie bei Turbo-FLASH Sequenzen [47], die Magnetisierung mit einem Inversionspuls präpariert, und während die makroskopische Magnetisierung relaxiert, werden alle Phasenkodierschritte einer Kodiertabelle für einen festen Phasenkodierschritt der 2. Phasenkodiertabelle gemessen. Nach einer Erholzeit wird die Magnetisierung erneut präpariert und alle Phasenkodierschritte der 1. Phasenkodiertabelle mit dem nächsten Schritt der 2. Phasenkodiertabelle ermittelt [47].

Diese Technik ist geeignet, um die konventionellen T_1 -gewichteten Spin-Echo-Sequenzen zu ersetzen. Der Kontrast ist besser steuerbar, die Schichten lassen sich dünner und lückenloser wählen, womit MP-RAGE Datensätze für multiplanare Rekonstruktionen geeignet sind.




Bild 2.5: Timing-Diagramme der: a) MP-RAGE-Sequenz [47] und der b) Stejskal-Tanner DWI-Sequenz [52].

2.1.3.4 Diffusionsgewichtete Methode

Durch die Entwicklung der diffusionsgewichteten Sequenzen (DWI) ist es erstmals möglich gewesen, die Molekularbewegung im Gewebe *in vivo* zu bestimmen [53]. Die Technik gibt Auskunft über die räumliche Verteilung und Mobilität der Wassermoleküle. Das Ausmaß dieser Bewegung hängt neben der Temperatur vor allem von der natürlichen Diffusionsbarriere ab [47]. In biologischen Systemen wie z.B. der weißen Substanz wird die Beweglichkeit der Wassermoleküle durch verschiedene intra- und extrazelluläre Komponenten („Bio-Barrieren“) [53, 54], wie z.B. Zellwände, eingeschränkt. Dadurch ist die Diffusion in verschiedene Richtungen unterschiedlich. In Flüssigkeiten dagegen können Wassermoleküle frei nach allen Richtungen diffundieren.

In der diffusionsgewichtenden Bildgebung setzt man nach dem HF-Anregungsimpuls zwei gleich starke entgegengerichtete Gradientenpulse an, die symmetrisch um einen refokussierenden HF-Impuls platziert sind [52]. Dadurch werden die Spins der Protonen in Wassermolekülen erst dephasiert und dann rephasiert. Jede diffusive Bewegung von Wasser bewirkt einen Verlust von Signalintensität im MR-Bild, denn ihre Phasen unterscheiden sich von den unbewegten Protonen. Das Ausmaß des Signalverlustes wird durch das Maß der zufälligen Bewegung (durch den Diffusionskoeffizienten bestimmt) und durch die Stärke und Dauer der Diffusionsgradienten (=b-Wert) charakterisiert [22].

Die Erfassung diffusionsgewichteter Aufnahmen mit unterschiedlich starker Diffusionsgewichtung (gemessen als b-Werte in Sek/mm^2) ermöglicht die Berechnung des sogenannten "apparent diffusion coefficient" (ADC) [55], der ein quantitatives Maß für das Ausmaß dieser Diffusionsminderung darstellt. Bild 2.5b zeigt das Timing-Diagramm der Stejskal-Tanner DWI-Sequenz [52].

2.1.4 Bildgewichtung

Unterschiedliche Gewebe besitzen auch unterschiedliche T_1 - und T_2 -Zeiten. So kann der Bildkontrast zwischen bestimmten Gewebestrukturen durch die geeignete Auswahl der Aufnahmeparameter einer Messsequenz optimiert werden (Bildgewichtung) [47]. Das Messsignal hängt von den Gewebeparametern, d.h. den T_1 - und T_2 -Relaxationszeiten und der Protonendichte (ρ), sowie von den Messparametern, d.h. von der Repetitionszeit (TR) und Echozeit (TE), ab.

Durch Wahl der Sequenzparameter TE und TR können die Messdaten je nach Anwendungsfall bzgl. ρ , T_1 und T_2 gewichtet werden.

2.1.5 Rauscheigenschaften der MRT

Das Zufallsrauschen in einem MRT-System wird durch ohmsche Verluste im Empfangssystem und durch das Rauschmaß des Vorverstärkers verursacht [48]. Der Verlust im Empfangssystem hat zwei Bestandteile: die ohmschen Verluste in der HF-Spule selbst und diejenigen, die die Probe innerhalb der HF-Spule produziert [56]. In einem gut konstruierten System sollten die in der HF-Spule erzeugten Verluste dominieren. Unabhängig von der Rauschquelle weisen alle diese Störungen ein weißes Spektrum auf [57], welches über die Zeit die Gesamtvarianz der Spannungsfluktuationen mit gleicher Amplitude an allen durch das System feststellbaren Frequenzen einprägt.

Das Kernresonanzsignal ist von Natur aus schwach, deswegen ist die Betrachtung des Rauschens von größter Bedeutung. Im idealen Fall entspricht das Resonanzsignal der induzierten elektrischen Spannung $U(t)$, die in der Empfangsspule aufgrund der präzedierenden Kerne entstanden ist [56].

$$U(t) = K\omega_L B_i M_0 V_s \cos(\omega_L t) \quad (2.10)$$

K dient hier als Inhomogenitätskorrekturfaktor, welcher von der relativen Position zwischen den untersuchten Atomen und der Spule abhängt, und dessen Werte normalerweise nahe Eins sind. V_s ist das Volumen der Probe, ω_L ist die Larmor-Frequenz und B_i der Geometriefaktor des Nachweisspule [45]. Bei einem Volumenresonator Typ „Birdcage“ ist dieser Fluss gegeben durch [58]:

$$B_i = \frac{-\mu_0 JCD}{A + D} \quad (2.11)$$

mit μ_0 als magnetische Induktionskonstante, A und D die halbe Länge der langen und kurzen Achsen der elliptischen Spulen, C der Abstand zwischen dem Spulenleiter und J die elektrische Stromdichte.

Der Betrag M_0 (in Gleichung 2.11) der Gleichgewichtsmagnetisierung in Richtung des Hauptmagnetfeldes folgt [47]:

$$M_0 = \frac{1}{V} \sum_{i=0}^{N-1} (\mu_z)_i = \frac{N}{V} \cdot \frac{\gamma^2 \hbar^2 I(I+1) B_0}{3kT} \quad (2.12)$$

I stellt dabei die Spinquantenzahl und N die Gesamtzahl der magnetischen Momente in der Probe bezogen auf das Volumen V dar.

In der Praxis besteht das MRT Signal $U_{mess}(t)$ aus der Superposition der gewünschten Spannung $U(t)$ und dem weißen Rauschen U_R [59]:

$$U_{mess}(t) = U(t) + U_R(t) \quad (2.13)$$

Die thermische Bewegung der Elektronen (Johnson-Rauschen) in der Empfangspule, der Vorverstärker sowie die Brownsche-Molekularbewegung im Messobjekt erzeugen eine Störspannung U_R [60], die in Konkurrenz zum Kernresonanzsignal $U(t)$ steht [56].

$$U_R = \sqrt{\left(\frac{2}{\pi}\right) \cdot k \cdot T \cdot R \cdot \Delta\omega} \quad (2.14)$$

Dabei repräsentiert k die Boltzmannkonstante, T die Temperatur, R den spezifischen Widerstand der Spule sowie der Probe und $\Delta\omega$ stellt die Nachweisbandbreite des Empfangsystems dar. Dabei lässt sich die Komponente $T \cdot R$ aus der Gleichung 2.15 in eine Spulen- und Probenanteil aufspalten [45].

$$T \cdot R = T_{Spule} \cdot R_{Spule} + T_{Probe} \cdot R_{Probe} \quad (2.15)$$

Der spezifische Widerstand R_{Probe} fasst die auf den Widerstand bezogenen dielektrischen und induktiven Verluste der Probe zusammen ($R_{Probe} = R_E + R_m$) [61].

Der effektive Widerstand R_E charakterisiert die resultierenden Verluste, die eine Probe, wie z.B. der menschliche Körper, innerhalb der Spule produziert. Die Probe wirkt hier als dielektrisches Medium und stört die gleichmäßig verteilte Kapazität der Spule [61]. Auch innerhalb der Spule erzeugt das menschliche Gewebe eine reale Senkung der Durchdringung (Penetration) des HF-Feldes. Das HF-Feld ist somit gegenüber den induzierten Strömen innerhalb der Oberflächenschichten der Probe (Skineffekt) abgeschirmt. R_m stellt den relativen Zuwachs des resultierenden thermischen Rauschens dar, welches durch die induzierten Ströme erzeugt wird [56, 62].

Der Betrag der Rauschspannung U_R , die diese Rauschquellen produzieren, bleibt für alle detektierbaren Frequenzen (White Spektrum) konstant [57]. Außerdem sind diese Schwankungen im Zeitbereich statistisch unabhängig und folgen einer Gauß'schen Wahrscheinlichkeitsdichtefunktion (PDF) [63].

In vielen Kernspintomographen wird das MRT-Signal mit einem gegeneinander um 90° gedrehten Spulenpaar aufgenommen. Diese Spulen werden angelegt, um die Feldkomponente detektieren zu können, die die Transversalkomponenten der Spins produzieren. Mit Hilfe einer Quadraturdemodulation kann dieses Signal in zwei separate Kanäle (x- und y-Komponenten) aufgeteilt werden und mathematisch als komplexes Signal in einer Matrix dargestellt werden [63]. Ein reales und ein imaginäres Bild wird durch die komplexe Fouriertransformation aus den ursprünglichen Signalen rekonstruiert. Aufgrund der Linearität und Orthogonalität der Fouriertransformation werden die Rauscheigenschaften in beiden Bildern übertragen. So bleibt der Betrag des Rauschens über das gesamte Sichtfeld (eng. „Field of view“) des komplexen Bildes konstant und das Rauschen in beiden Bildern unkorreliert [64].

Diese komplexen MRT-Bilder werden in dieser Form oft nicht weiter verwendet. So werden in der Regel die komplexen Bilder in ein Betragsbild umgewandelt (Gleichung 2.16).

$$|u| = \sqrt{u_{real}^2 + u_{imaginär}^2} \quad u \in \mathbb{R}^2 \quad (2.16)$$

Durch diese nicht-lineare Transformation wird die PDF des Rauschens verändert. Das Rauschen des Betragsbildes entspricht der Rice-Dichtefunktion PDF [65]. Der Kurvenverlauf der Rice-Verteilung (Gleichung 2.17) hängt vom Term (A_0/σ) ab, der für das Signal-Rausch-Verhältnis (SNR) steht.

$$R_{PDF}(A_r|\sigma) = \frac{A_r}{\sigma^2} e^{-\frac{A_r^2 + A_0^2}{2\sigma^2}} \cdot I_0\left(\frac{A_0 \cdot A_r}{\sigma^2}\right) \quad (2.17)$$

I_0 beschreibt die modifizierte Besselfunktion nullter Ordnung, A_0 die Intensität des Bildelementes ohne Rauschen, A_r die tatsächliche Intensität des Elementes und σ stellt die Standardabweichung des Gaußschen Rauschens des komplexen Bildes dar. Bild 2.6 zeigt die Rice-Dichtefunktion als Funktion der Intensität A_r/σ . Im Fall $SNR=0$ ist die

Dichtefunktion gleich der Rayleighverteilung [66], andererseits für $\text{SNR} > 3$ nähert sich die Rice-Verteilung einer Gaußverteilung an [67].




Bild 2.6: Rice-Dichtefunktion (PDF) als Funktion des Betrages A_r/σ für verschiedene Signal-Rausch-Verhältnis SNR Werte

Diese Kenntnisse wurden als Grundlage zur Erstellung eines Modells des Rauschens genommen, um das Verfahren der automatischen Unterdrückung des Rauschens anhand digitaler Filter besser umsetzen zu können.

2.2 Rauschunterdrückungsmethoden in der Bildverarbeitung

Verschiedene Rauschunterdrückungsverfahren wurden in den letzten Jahren entwickelt, um die Qualität der Bilddaten im Hinblick auf die nachfolgenden Analyseschritte zu verbessern. In den so genannten „Aufnahmebasierten Rauschunterdrückungsmethoden“ (Eng. acquisition-based noise reduction) versucht man die Signalkomponenten des gemessenen Objektes zu verstärken, entweder durch eine mehrmalige Wiederholung der Messungen, die die unkorrelierte Information des Rauschens aufgrund der implizierten Mittelung dämpft, oder durch die Vergrößerung des Volumenelementes (Voxel), so dass die Anzahl der gemessenen Atome pro Volumen und dessen Signalintensität erhöht wird [24]. Eine Wiederholung der Messungen führt zu einer Erhöhung der Messzeit und damit zu einer Erhöhung der Patientenbelastung sowie einer Reduktion der medizinischen Ausnutzung des Systems, während die Vergrößerung der Volumenelemente zu einer Senkung der räumlichen Auflösung führt und damit die Lokalisierung feiner anatomischer Strukturen verhindert.

Die computergestützten Bildverarbeitungsverfahren stellen eine Alternative zu den zuvor erwähnten Ansätzen dar, da keiner der Aufnahmeparameter geändert werden muss. Diese

digitalen Operatoren, gleichgültig ob linear oder nicht linear, können das Rauschen ausschließlich anhand des Informationsgehaltes der bereits erfassten Bilder unterdrücken. Damit werden Nachteile der vorherigen Verfahren, wie die längere Erfassungszeit und geringere räumliche Auflösung, vermieden.

2.2.1 Lineare Rauschunterdrückungsmethoden

Lineare Filterungsmethoden können mathematisch nach dem Faltungssatz durch zwei unterschiedliche Ansätze durchgeführt werden, entweder durch Multiplikation der transformierten Bilder mit einer Transferfunktion im Ortsfrequenzraum oder, äquivalent dazu, durch eine Faltung im Ortsraum mit einem Maskenoperator (z.B. einer 3x3 Masken-Matrix). Das einfachste Beispiel eines Maskenoperators ist der Mittelwertfilter [68], da dessen Matrix nur aus Einsen besteht. Jeder Bildpixel wird dem gerundeten Mittelwert seiner durch die Maske überdeckten Nachbarpunkte zugeordnet. Im Fall des Gaußfilters [68] wird die Filtermatrix gemäß der Gaußschen Normalverteilungsfunktion gebildet, die durch die Varianz σ beschrieben wird.

Es ist es weiterhin bekannt, dass Linearfilter additives Hochfrequenzrauschen entfernen können, solange sich das Signal und das Rauschen im Frequenzbereich nicht überlappen [26, 69]. In der Bildverarbeitung enthält das Signal jedoch oft bedeutungsvolle Hochfrequenzbestandteile, wie Kanten und feine Details. Ein Tiefpass-Linearfilter würde für solche Signale die scharfen Kanten verschmieren und zu inakzeptablen Ergebnissen führen, so dass nichtlineare Filter verwendet werden müssen.

2.2.2 Nichtlineare Rauschunterdrückungsmethoden

Einige dieser Techniken sind aus dem Konzept der Rangordnung der Grauwerte einer Nachbarschaft entstanden [70]. Neben Minimum- und Maximumfilter gehören die Medianfilter [27, 71] und die „k-nearest neighbor filter“ KNN [28] in diese Kategorie. Variationen im Rangordnungskonzept verwenden der „symmetric nearest neighbor filter“ SNN [72], der „sigma-nearest neighbor filter“ σ -NN [73], der Nagao Filter [74] und der Kuwahara Filter [75]. Anwendungsbeispiele mit medizinischen Daten können bei [76-78] gefunden werden.

Eine andere Klasse von nichtlinearen Methoden nutzt die Aufspaltung der Daten in Wavelet-Domänen aus [79-81], wobei das Bild auf einen Approximationsraum und

mehrere Detailräume verteilt wird. Die Lokalitätseigenschaft, die im Gegensatz zur Fouriertransformation die Zuordnung der Frequenzmoden des Signals zu einem bestimmten Ortsbereich erlaubt, und die "Multiresolution" Eigenschaft, die die Zerlegung des Signals in mehrere Auflösungsebenen erlaubt, zeichnen diese Transformation aus.

Im Allgemeinen gehen die Wavelet-basierten Rauschunterdrückungsverfahren davon aus, dass die betragsmäßig großen Koeffizienten in den Detailräumen wesentliche Bildinformationen enthalten, während betragsmäßig kleine Koeffizienten überwiegend vorhandenes Rauschen repräsentieren. Durch eine lokale bzw. globale Schätzung des Rauschens werden Schwellwerte definiert, die die Detailkoeffizienten betragsmäßig verringern. Die anschließende Rücktransformation liefert dann das rauscharme Bild. Eine ausführliche Beschreibung solcher Verfahren und deren Anwendung in der Verarbeitung von MRT-Bilddaten können in [82] und [83] gefunden werden.

Weitere Methoden basieren auf partiellen Differentialgleichungen und der Flüssigkeitsdynamiktheorie. Dies sind „Level-Set“ Methoden [84], „Total-Variation“ Methoden [85] bzw. die nichtlineare isotrope und anisotrope Diffusion [29, 34]. Besonders letztere Methoden haben aufgrund der Anpassungsfähigkeit und der Justierbarkeit großes Interesse in der Bildverarbeitung gefunden. Sie stellen eine hervorragende Kombination zwischen Glättung und Kantenerhaltung dar und sollen im folgenden Kapitel ausführlicher diskutiert werden.

3 Untersuchung anisotroper Diffusionsfilter

3.1 Stand der Forschung (Technik)

Anisotrope Diffusionsfilter basieren auf der Skalenraum-Bilddarstellung (engl. „scale-space representation“). Die Skalenraum-Methode wurde im Gebiet der digitalen Bildverarbeitung von Witkin [86] formell eingeführt. Mit dieser Methode wird eine sukzessive Glättung der Bildinformation (Filterung) erzeugt, in der das ursprüngliche Bild $I_0(\bar{x})$ den ersten Bestandteil einer Ansammlung von hergeleiteten Bildern $I(\bar{x}, t)$ darstellt, welche durch die Faltung von $I_0(\bar{x})$ mit einer Funktion $f(\bar{x}, t)$ schrittweise generiert wird. Dabei repräsentiert der Zeitparameter t die Anzahl der Iterationsschritte, während $\bar{x}$ für die Koordinaten des Bildes (z.B. x, y, z für 3D) steht.

$$I(\bar{x}, t) = f(\bar{x}, t) * I_0(\bar{x}) \quad (3.1)$$

Wenn ein Gaußscher-Ortsfilter $G(\bar{x}, \sigma, t)$ als Funktion $f(\bar{x}, t)$ definiert ist, und die Ansammlung von hergeleiteten Bildern generiert, führt dieser auf die Lösung der Wärmeleitungsgleichung [30], z.B. für 3D Bilder:

$$\frac{\partial}{\partial t} I(\bar{x}, t) = c \nabla^2 I(\bar{x}) = c \left(\frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2} + \frac{\partial^2 I}{\partial z^2} \right) \quad (3.2)$$

wobei $I(\bar{x}, 0) = I_0(\bar{x})$ und c als thermischer Leitfähigkeitskoeffizient (Diffusionskoeffizient) definiert ist. Ursprünglich wurde der Koeffizient c als Konstante und unabhängig von der räumlichen Position definiert. Dies führt zu einer isotropen Diffusion, die unabhängig vom Bildinhalt ist und sich gleichmäßig in alle Richtungen auswirkt. Dies führt zur Kantenverschmierung, die eine direkte Anwendung in der medizinischen Bildverarbeitung einschränkt. Um die Kantenverschmierung zu vermeiden, haben Perona and Malik eine nicht konstante Funktion als Diffusionskoeffizient eingeführt [29].

$$\frac{\partial}{\partial t} I(\bar{x}, t) = \text{div}(c(\bar{x}, t) \cdot \nabla I(\bar{x}, t)) \quad (3.3)$$

$$\frac{\partial}{\partial t} I(\bar{x}, t) = \text{div}(\Phi(\bar{x}, t)) \quad (3.4)$$

Der Flussterm $\Phi(\bar{x}, t)$ beschreibt die Diffusionsstärke, die während der Wärmeübertragung in ein Medium wirkt bzw. die Glättungsstärke in der Bildverarbeitung.

Falls die Gradienten an den Kanten der Bildobjekte bekannt wären, könnte die Diffusionsfunktion $c(\bar{x}, t)$ so definiert werden, dass die Intensitätswerte innerhalb jeder Bildregion geglättet werden und die Wechselwirkung zwischen Regionen über die Grenzen hinaus minimiert wird, indem der Diffusionskoeffizient innerhalb der Regionen den Wert 1 und an den Grenzen den Werte 0 annimmt. In Wirklichkeit sind die die Bildkanten repräsentierenden Gradienten unbekannt, aber eine Abschätzung $E(\bar{x}, t)$ der Kantenstärke kann gemacht werden. Der Diffusionskoeffizient könnte mit einer geeigneten Abschätzung der Bildkanten als Funktion der Kantenstärke definiert werden mit $c = f(E(\bar{x}, t))$. Die Funktion $f(\cdot)$ ist als nichtnegative monoton fallende Kurve definiert, bei der die Randbedingungen $f(0) = 1$ und $f(\infty) = 0$ gelten. Der Gradientenoperator $\nabla I(\bar{x}, t)$ wird häufig als Kantendetektor eingesetzt, da der Betrag des Gradienten ein Maß für die Kantenstärke darstellt. Dies führt zu einer Definition der Diffusionsfunktion, die vom Betrag des Intensitätsgradienten des Bildes abhängig ist.

$$c(\bar{x}, t) = f(|\nabla I(\bar{x}, t)|) \quad (3.5)$$

Zwei dieser Funktionen wurden von Perona und Malik vorgeschlagen [29] (Abschn. 3.2.1). Jede dieser Funktionen erfüllt die oben genannten Voraussetzungen und führt zu der erwünschten intraregionalen statt interregionalen Glättung.

3.1.1 Perona-Malik Funktionen

Zur Definition des Diffusionskoeffizienten als nichtnegative monoton fallende Funktion schlugen Perona und Malik in [29] zwei Funktionen vor:

$$c_1(\bar{x}, t) = e^{-\left(\frac{|\nabla I(\bar{x}, t)|}{k}\right)^2} \quad c_2(\bar{x}, t) = \frac{1}{1 + \left(\frac{|\nabla I(\bar{x}, t)|}{k}\right)^2} \quad (3.6)$$

Die Flussfunktionen folgen der Gleichung:

$$\Phi_1(\bar{x}, t) = \nabla I(\bar{x}, t) \cdot e^{-\left(\frac{|\nabla I(\bar{x}, t)|}{k}\right)^2} \quad \Phi_2(\bar{x}, t) = \frac{\nabla I(\bar{x}, t)}{1 + \left(\frac{|\nabla I(\bar{x}, t)|}{k}\right)^2} \quad (3.7)$$

Mit c_1 für die erste (PMAD1) und c_2 für die zweite (PMAD2) Diffusionsfunktion. Der Wert des Diffusionsfaktors k definiert den Wendepunkt der Kurven in Bezug auf den Gradientenwert $|\nabla I(\bar{x}, t)|$. Bild 3.1 links stellt die Kurven dar, die beide Funktionen bezogen auf den normierten Gradientenbetrag ($|\nabla I|/k$) ergeben.




Bild 3.1: Diffusions- (links) und Flusskurven (rechts) der Perona-Malik Funktionen als Funktion des normierten Bildgradienten ($|\nabla I|/k$).

Die Flusskurven (Bild 3.1 rechts) zeigen, dass der Diffusionsprozess am stärksten wird, wenn der Gradientenbetrag im Bereich des Diffusionsfaktors $|\nabla I| \approx k$ liegt. Die Nachbarn, welche Gradienten $|\nabla I| \ll k$ oder $|\nabla I| \gg k$ besitzen, bleiben praktisch unbeachtet, da weniger Fluss erzeugt wird. Für die PMAD1 Funktion wird der größte Fluss bei etwa 70 % des k -Wertes erreicht. Die PMAD2 Funktion erreicht maximale Diffusionsstärke, wenn der Gradientenbetrag dem k -Wert entspricht ($|\nabla I| \approx k$). Die Form beider Flusskurven erklärt die unterschiedliche Wirkung beider Funktionen. Die PMAD1 Funktion bewahrt besser die Bildkanten, während die PMAD2 Funktion glattere Übergänge zwischen den verschiedenen Bildregionen erzeugt. Daher sollte der Diffusionsfaktor angepasst werden, um die erwünschten Kanten zu bewahren.

Nach den ersten Diffusionsfunktionen von Perona und Malik [29] wurden zusätzliche Funktionen von Charbonnier et. al. [33], Black et. al. [32], Weickert [34] und Monteil et. al. [35] definiert. Black und Koautoren beschreiben in ihrer Arbeit die Beziehung zwischen der anisotropen Diffusion und der Theorie der „robusten Statistik“. Damit waren sie in der

Lage, eine robuste Diffusionsfunktion auf Basis des „Tukey’s biweight estimator“ zu definieren. Diese Funktion generiert schärfere Kanten im Vergleich zu den von Perona-Malik vorgeschlagenen Funktionen und die Konvergenz des Verfahrens ermöglicht die Implementierung eines automatisierten Abbruchkriteriums, welches auf der Anzahl der zuletzt geänderten Pixel bzw. Voxel basiert. Weickert beschrieb in seinem Buch [34] die Implementierung von Diffusionsalgorithmen anhand partieller Differentialgleichungen (PDE). Mit dieser Methode gelingt es, die Wirkung der Diffusion in die verschiedenen Richtungen hinsichtlich der lokalen Geometrie der Kanten unterschiedlich und unabhängig von den natürlichen Richtungen des Pixel- bzw. Voxelgitters wirken zu lassen [34, 87-88].

Eine gute Übersicht über die Thematik der anisotropen Diffusionsfilter ist in der Arbeit von Suri und Wu [89] zu finden. Dort werden aktuelle Tendenzen auf dem Gebiet der anisotropen Diffusion zusammengefasst und ein Ausblick bezüglich zukünftiger Entwicklungen auf diesem Gebiet präsentiert.

3.1.2 Weitere Diffusionsfunktionen

Seit der Einführung der anisotropen Diffusion ist ein bedeutender Umfang an Forschung dem theoretischen und praktischen Verstehen und verwandten Methoden gewidmet worden. Weitere Diffusionsfunktionen mit besseren Eigenschaften wurden seitdem vorgeschlagen. Die bekanntesten Diffusionsfunktionen sind hier aufgelistet.

Charbonnier’s Diffusionsfunktion [33] :

$$c_3(\bar{x}, t) = \frac{1}{\sqrt{1 + \left(\frac{|\nabla I(\bar{x}, t)|^2}{k^2} \right)}} \quad (3.8)$$

Tukey’s Diffusionsfunktion (Black et. al.) [32] :

$$c_4(\bar{x}, t) = \begin{cases} \frac{1}{2} \cdot \left(1 - \left(\frac{|\nabla I(\bar{x}, t)|}{k} \right)^2 \right)^2 & \text{für } |\nabla I| \leq k \\ 0 & \text{für } |\nabla I| > k \end{cases} \quad (3.9)$$

Weickert's Diffusionsfunktionen [34] :

$$c_5(\bar{x}, t) = \begin{cases} 1 - e^{-\frac{c_m}{\left(\frac{|\nabla I(\bar{x}, t)|^2}{k^2}\right)^m}} & \text{für } |\nabla I| > 0 \\ 1 & \text{für } |\nabla I| = 0 \end{cases} \quad (3.10)$$

wobei der Koeffizient c_m vom Parameter “ m ” abhängt. Für $m=2, 3$ und 4 , ergibt sich c_m jeweils zu 2.33666 , 2.9183 , und 3.31488 [34].

Monteil's Diffusionsfunktion [35] :

$$c_6(\bar{x}, t) = \frac{1}{2} [\tanh(\gamma(k - |\nabla I(\bar{x}, t)|)) + 1] \quad (3.11)$$

γ wurde erfahrungsgemäß gleich $0,2$ eingestellt.

3.1.2.1 Diffusions- und Flusskurven

In Bild 3.2 werden die Kurven der in Abschn. 3.1.2 definierten Funktionen zusammen mit den von Perona-Malik definierten Diffusions- und Flusskurven dargestellt.




Bild 3.2: Charbonnier, Tukey, Monteil und Weickert ($m=2$) Diffusions- und Flusskurven im Vergleich mit den von Perona und Malik definierten Funktionen (PMAD1 und PMAD2). Die x Achse stellt den normierten Gradientenbetrag ($|\nabla I|/k$) dar.

Die Charbonnier Funktion erzeugt glattere Ergebnisse aufgrund ihrer breiten Diffusionskurve. Der Fluß steigt proportional zum Gradienten bis der Wert Eins erreicht ist. Deswegen sollte der Diffusionsfaktor deutlich kleiner im Vergleich zu anderen Funktionen gewählt werden, um ähnliche Ergebnisse zu erhalten. Im Vergleich mit beiden Perona-Malik Funktionen schränkt die Tukey-Funktion deutlich den Einfluss der

Bildelemente ein, deren Gradientenbetrag außerhalb des durch den k Wert definierten Schwellwert ($|\nabla I/k| > 1$) liegt. Der maximale Fluss ist bei etwa 45 % dieses k -Wertes erreicht. Deshalb wird der Diffusionsfaktorwert ungefähr doppelt so groß gewählt wie bei der PMAD1-Funktion, um an vergleichbare Ergebnisse zu kommen. Mit dieser Funktion werden die Kanten stark verschärft und die Konvergenz zu einem stabilen Bild verbessert (Bild 3.5). Die Kurven der Weickert-Funktionen zeigen die Tendenz, die Kanten zu erhalten oder zu verstärken. Das Besondere dieser Funktionen ist die konstante Gewichtung ($C5 = 1$) der Bildelemente, deren Gradientenbetrag unterhalb der Diffusionsschwelle liegen. Bei $|\nabla I| \approx k$ fängt die Diffusionsstärke an zu sinken, bis der Nullwert erreicht ist ($|\nabla I| \gg k$). Das Flussmaximum ist höher als bei den anderen Funktionen, dies führt zu einer schnellen Konvergenz und zur Entstehung von glatteren Regionen, als diejenige, die die Tukey-Funktion erzeugt. Die vorgeschlagene Funktion von Monteil und Beghdadi wirkt ähnlich wie die PMAD1 oder Tukey-Funktion. Deren Fluss erreicht ihr Maximum bei $|\nabla I| \approx k$. Der Faktor γ kontrolliert die Steigung der Diffusionskurve und als Folge die Breite der Flussfunktion [35]. Daher sollte dieser Parameter auch gezielt justiert werden.

3.1.3 Diskrete Implementierung

Gerig et al. präsentierten in ihrer Arbeit [31] eine ausführliche Beschreibung der diskreten Implementierung und haben die Funktionen von Perona-Malik für 1D-Signale, 2D- und 3D-Bilder diskret definiert. Die Anwendung auf anisotrope Pixel- bzw. Voxelgitter sowie die Erweiterung zur Verarbeitung multispektraler Daten sind in dieser Veröffentlichung ebenfalls ausführlich behandelt worden. Für die vorliegende Arbeit besonders interessant ist die Beschreibung der Anwendung der Verfahren zur Unterdrückung des Rauschens in kernspintomographischen Bilddaten.

In dieser Arbeit wird die in [31] beschriebene diskrete Implementierung der Diffusionsgleichung anhand finiter Differenzen übernommen. Beispielhaft ist im Folgenden diese diskrete Implementierung für ein zweidimensionales Bild unter Betrachtung der 4er-Nachbarschaften dargestellt:

$$\frac{\partial}{\partial t} I(x, y, t) = \frac{\partial}{\partial x} \left[c(x, y, t) \cdot \frac{\partial}{\partial x} I(x, y, t) \right] + \frac{\partial}{\partial y} \left[c(x, y, t) \cdot \frac{\partial}{\partial y} I(x, y, t) \right] \quad (3.12)$$

$$\begin{aligned}
\frac{\partial}{\partial t} I(x, y, t) \approx & \frac{1}{(\Delta x)^2} \left[c \left(x + \frac{\Delta x}{2}, y, t \right) \cdot (I(x + \Delta x, y, t) - I(x, y, t)) \right. \\
& \left. - c \left(x - \frac{\Delta x}{2}, y, t \right) \cdot (I(x, y, t) - I(x - \Delta x, y, t)) \right] \\
& + \frac{1}{(\Delta y)^2} \left[c \left(x, y + \frac{\Delta y}{2}, t \right) \cdot (I(x, y + \Delta y, t) - I(x, y, t)) \right. \\
& \left. - c \left(x, y - \frac{\Delta y}{2}, t \right) \cdot (I(x, y, t) - I(x, y - \Delta y, t)) \right]
\end{aligned} \quad (3.13)$$

$$\begin{aligned}
\frac{\partial}{\partial t} I(x, y, t) \approx & \frac{1}{(\Delta x)^2} [\Phi_{Nord} - \Phi_{Süd}] + \frac{1}{(\Delta y)^2} [\Phi_{Ost} - \Phi_{West}] \\
\frac{\partial}{\partial t} I(x, y, t) \approx & \Phi_{Nord} - \Phi_{Süd} + \Phi_{Ost} - \Phi_{West} \quad | \quad \Delta x = \Delta y = 1
\end{aligned} \quad (3.14)$$

Für die Filterung sind zwei Schritte notwendig. Zuerst sind die Flusswerte zwischen den benachbarten Pixeln zu bestimmen. Anschließend ist die Intensität jedes Bildpixels mit der gewichteten Mittelung der Flussbeiträge seiner Nachbarn zu ersetzen.

$$I(x, y, t + \Delta t) = I(x, y, t) + \Delta t \cdot (\Phi_{Nord} - \Phi_{Süd} + \Phi_{Ost} - \Phi_{West}) \quad | \quad \Delta x = \Delta y = 1 \quad (3.15)$$




Bild 3.3: Darstellung der 2D Diffusion. $I(x, y, t)$ wird durch die Beiträge der 4 bzw. 8 Nachbarn geändert:
 $\Phi_I = (\Phi_{Nord}, \Phi_{Süd}, \Phi_{West}, \Phi_{Ost})$ oder $\Phi_I = (\Phi_{Nord}, \Phi_{Süd}, \Phi_{West}, \Phi_{Ost}, \Phi_{Nordwest}, \Phi_{Südwest}, \Phi_{Nordost}, \Phi_{Südost})$.

Im 2D-Fall, in dem acht nächste Nachbarn verwendet werden, muss zusätzlich die relative Entfernung (Δd) der diagonalen Nachbarn zur Bestimmung des Flussbeitrages berücksichtigt werden.

$$\begin{aligned}
I(x, y, t + \Delta t) = & I(x, y, t) + \Delta t \cdot [\Phi_{Nord} - \Phi_{Süd} + \Phi_{Ost} - \Phi_{West} \\
& + \frac{1}{(\Delta d)} (\Phi_{Nordost} - \Phi_{Nordwest} + \Phi_{Südost} - \Phi_{Südwest})] \quad | \quad \Delta x = \Delta y = 1
\end{aligned} \quad (3.16)$$

Bilder mit anisotropen Pixeln (Voxeln) können auf eine ähnliche Weise behandelt werden. Der passende Skalierungsfaktor sollte dazu in die Formel eingefügt werden.

Der von Perona und Malik vorgeschlagene Diffusionsprozess konvergiert nicht immer gegen ein akzeptables Endergebnis. Nach langer Verarbeitungszeit würde das Bild alle seine Strukturen verlieren und nur ein konstanter Wert übrig bleiben. Nordström [90] fasst die anisotrope Diffusion und die variierende Regularisierung („variational regularization“) in einem Verfahren zusammen, in dem der ursprünglichen Diffusionsfunktion ein zusätzlicher Term hinzugefügt wurde, welcher die beschreibt. Bei einer 4er Nachbarschaft ($\Delta x = \Delta y = 1$) Abweichung zwischen dem ursprünglichen und dem geglätteten Bild ist z.B.

$$I(\bar{x}, t + \Delta t) = I(\bar{x}, t) + \Delta t \cdot [(\Phi_{Nord} - \Phi_{Süd} + \Phi_{Ost} - \Phi_{West}) + (I(\bar{x}, 0) - I(\bar{x}, t))] \quad (3.17)$$

Dieser „Bias-“Term $(I(\bar{x}, 0) - I(\bar{x}, t))$ ist für die mathematisch korrekte Darstellung [91] und die ausreichende Konvergenzeigenschaft verantwortlich [90]. Unter Verwendung dieses Zusatzterms kann der Diffusionsprozess mehrmals durchgeführt werden, bis ein stabiler Zustand erreicht wird.

Die diskrete Ausführung des anisotropen Diffusionsfilters gleicht der numerischen Integration der partiellen Differentialgleichung. Anhand dieser Annahme wurde in [31] eine elementare Analyse gezeigt, um Grenzwerte für die Integrationskonstante Δt (auch als λ : Lambda bekannt) zu finden. Diese Konstante muss innerhalb des Intervalls $(0, N]$ gewählt werden, wobei N eine positive reelle Zahl ist. Gleichung 3.18 präsentiert die Berechnung der Grenzwerte N . Hier wird angenommen, dass die orthogonalen Nachbarn gleichweit entfernt liegen (d.h. $\Delta x = \Delta y = \Delta z$). Größere Entfernungen für diagonale Nachbarn in 2D und 3D Datensätzen und die sich unterscheidenden Entfernungen in anisotropen Datensätzen werden in dieser Berechnung berücksichtigt,

$$\Delta t \leq N = \left[\frac{1}{1 + \sum_{i=1}^n \frac{1}{(\Delta d_i)^2}} \right] \quad (3.18)$$

wobei Δd_i die relative Entfernung zwischen Nachbarn und dem zentralen Pixel/Voxel darstellt. $\Delta d = 1$ gilt für direkte Nachbarn, $\Delta d = \sqrt{2}$ für diagonale Nachbarn, und $\Delta d = \sqrt{3}$ für die Ecken des würfelförmigen Volumens der Nachbarschaft. Die berechneten Grenzwerte Δt für Filter, die auf isotropen Datensätzen arbeiten, sind in Tabelle 3.1 angegeben.

Dimensionen	Nachbarn (n)	Maximum Δt (N)
1D	2	1/3
2D	4	1/5
	8	1/7
3D	6	1/7
	18	1/13
	26	1/9

Tabelle 3.1: Integrationskonstanten Δt für verschiedene Nachbarschaften [31].

3.2 Rauschunterdrückung

Mittels der richtigen Wahl des Diffusionsparameters k und der Anzahl der notwendigen Iterationen it können beide Diffusionsfunktionen (PMAD1 und PMAD2) als wirksame Rauschunterdrückungsfilter eingesetzt werden. Sie können justiert werden, um spezifische Kanten und Bildeigenschaften zu bewahren und gleichzeitig die Rauschkomponenten des Bildes zu unterdrücken. Bild 3.4 zeigt die Rauschunterdrückungswirkung beider Funktionen für ein verrauschtes 1D Signal (smoothed step edge). Das Signal wird stärker bei steigendem Wert der Iterationen geglättet. Das ursprüngliche Signal wurde mit zusätzlichem (additiven) Rauschen (Standardabweichung (STD) = 6.56, Signal-zu-Rausch Verhältnis (SNR) = 12.56) modifiziert. In diesem Beispiel wurde der Diffusionsfaktor $k=7$ für die PMAD1 Funktion und $k=4.5$ für die PMAD2 Funktion für den Bereich 1 bis 75 Iterationen festgelegt. Die zweite Funktion hat einen kleineren Diffusionsfaktor erhalten, um den starken Glättungseffekt, aufgrund seiner breiteren Flusskurve, zu kompensieren.




Bild 3.4: Verlaufskurven der iterativen Filterung des verrauschten 1D Signals. Links: Ergebnis auf Basis der ersten Perona-Malik Diffusionsfunktion ($k=7$). Rechts: Ergebnis auf Basis der zweiten Perona-Malik Diffusionsfunktion ($k=4.5$). Beide Kurven werden im Bereich [1-75] Iterationen gezeigt.

Die Abbildung zeigt, dass die erste Perona-Malik Funktion die zentrale Kante leicht verschärft. Die zweite Perona-Malik Funktion zeigt eine etwas weniger steile Kante. Beide Filter haben nach zirka 40 Iterationen das Rauschen vollständig unterdrückt.

In Bild 3.5 sind die Rauschunterdrückungsergebnisse der anderen Diffusionsfunktionen dargestellt. Wie in Bild 3.4 wird der Verlauf der Glättung entlang des Iterationsparameters [1-75] gezeigt. Die Diffusionsfaktoren für die verschiedenen Funktionen wurden manuell gewählt, um den maximale Fluß dem Rauschen anzupassen, ohne die Zentralkante zu zerstören. Die Tukey-Funktion wurde mit $k=15$, die Charbonnier-Funktion mit $k=1$, die Monteil-Funktion mit $k=5$ und die Weickert($m=2$)-Funktion mit $k=6$ justiert. Andere Parameter, wie die Integrationskonstante ($\Delta t=0.25$) oder der Regularisierungsfaktor ($\sigma=0.125$) wurden konstant gehalten.




Bild 3.5: Ergebniskurven der Rauschunterdrückung mit dem Charbonnier, Tukey, Weickert ($m=2$) und Monteil Diffusionsfilter.

Die Abbildungen zeigen, dass in allen vier Fällen die Bildkante erhalten bleibt und das Rauschen unterdrückt wird. Trotzdem ist zu erkennen, dass die Charbonnier- und Monteil-Funktion eine größere Zahl an Iterationen benötigt, um eine vollständige Unterdrückung

des Rauschens zu erreichen. Dagegen haben die Tukey und Weickert Funktionen das Rauschen schnell unterdrückt und die Steigung der Kanten leicht verschärft. Bei optimaler Wahl des k -Faktors bezogen auf das Rauschniveau erzeugen die verschiedenen Funktionstypen leicht verschiedene Resultate. Einen Teil bilden die Filter, wie die PMAD2 und Charbonnier Funktionen, die glattere Übergänge zwischen den Regionen erzeugen. Den anderen Teil bilden Filter, wie die PMAD1, Tukey, Monteil und Weickert Funktionen, die schärfere Kanten zwischen den Regionen erzeugen und zu einer genaueren Bewahrung der Kanten führen.

In der Praxis wird $c(\bar{x}, t)$ nicht direkt abhängig vom Betrag des Intensitätsgradienten berechnet. Das Rauschen würde den Koeffizienten c zu stark variieren lassen und damit auch den Diffusionsprozess stark beeinflussen. Daher berechnet man eine geglättete Version des zu verarbeitenden Bildes, welches zur Bestimmung der Stärke der Diffusion benutzt wird.

$$I_{\sigma}(\bar{x}, t) := I(\bar{x}, t) * G_{\sigma}(\bar{x}) \quad (3.19)$$

Hierbei ist $G_{\sigma}(x)$ ein Gaußfilter mit Bandbreite σ . Dann wird $c(\bar{x}, t)$ von $|\nabla I_{\sigma}(\bar{x}, t)|$ abhängig. Eine formelle Erklärung dieser Methode kann in der Arbeit von Nitzberg und Shiota [91] gefunden werden. Whitaker et al. [92] haben darüber hinaus vorgeschlagen, den Skalenparameter σ der Gaußschen-Funktion G_{σ} abhängig vom Iterationsschritt zu verkleinern, da nach den ersten Bildfilterungsschritten die Zuverlässigkeit der Kantenabschätzung steigt. Die Reduktion von σ wird proportional zur Iterationsstufe des Filters gewählt.

3.3 Parameter der anisotropen Diffusionsfilter

Die wesentlichen Parameter der Diffusionsfunktionen lassen sich durch den Diffusionsfaktor k und die Anzahl der Filteriterationen it zusammenfassen. Die Regularisierungskonstante σ (Gaußsche Varianz, die zur Berechnung eine geglätteten Gradientenbildes verwendet wird) und im Fall der diskreten Implementierung die Integrationskonstante Δt (Abschn. 3.1.3) können ebenfalls als Parameter aufgefasst werden.

Die Integrationskonstante Δt hängt von der Gestalt des Diskretisierungsgitters (z.B. isotrop oder anisotrop) ab [31]. Die Raumskala, in der der Abstand zwischen den zu untersuchenden Nachbarn definiert ist (z.B. für die höchste Auflösung werden $\Delta x, \Delta y, \dots = 1$ benutzt), spielt ebenfalls eine wichtige Rolle. Mit Hilfe der Gleichung 3.12 und der relativen Entfernung Δd_i zwischen den Nachbarn ist es möglich, die Integrationskonstante zu berechnen. Der Parameter σ , der bereits in Abschnitt 3.1 beschrieben wurde, steuert die Glättung des Gradientenbildes [91]. Damit wird die Erkennung falscher Kanten, aufgrund des Rauschens, vermieden. Dieser Parameter wird entweder konstant während des gesamten Verfahrens gewählt (z.B. 3 oder 6), oder wie in [92] proportional zum Iterationsverlauf geändert. Andere Parameter, wie der Faktor γ in der Monteil-Funktion oder die Konstante m in der Weickert-Funktion werden aufgrund der gewünschten Eigenschaften festgelegt und während des Filterungsverfahrens unverändert gehalten.

Die Hauptparameter der Diffusionsfilter sind der Diffusionsfaktor und die Anzahl der Iterationen. Der Diffusionsfaktor wird verwendet, um das Niveau des Gradientenbetrags, bei dem der Filter seine maximale Diffusionsstärke auswirkt, zu bestimmen. Die Anzahl der Iterationen bestimmt die Zahl an Wiederholungen des Diffusionsprozesses auf die Bilddaten.

3.3.1 Methode zur Parameterjustierung

In Perona-Malik's Arbeit [29] wurde die *Diffusionskonstante* k entweder manuell oder anhand einer durch Canny [93] eingeführten „Rausch-Schätzungsmethode“ gewählt, die das Bild anhand eines Gitters in Regionen aufteilt. Der Parameter *Anzahl der Iterationen* it wurde aufgrund einer visuellen Betrachtung manuell justiert.

Black und Sapiro [32] haben für die Bestimmung des Parameters k einen globalen Operator eingesetzt, um eine Abschätzung des Rauschens σ_e durchzuführen.

$$\sigma_e = 1.4826 \cdot \text{median}_I \left[\left| \nabla I(\bar{x}, t) - \text{median} |\nabla I(\bar{x}, t)| \right| \right] \quad (3.20)$$

Die „Median Absolute Deviation (MAD)“ ist ein Werkzeug der robusten Statistik [94]. Der Diffusionsfaktor für die Tukey Funktion wurde als $k = \sqrt{5}(\sigma_e)$ definiert. Dank der Konvergenzeigenschaften dieser Funktion wurde die Anzahl der Iterationen nicht genauer bestimmt, sondern groß genug gewählt, um genügend Zeit für die Konvergenz zu

garantieren. In [32] berechneten Black und Sapiro ein robustes statistisches Maß für die Gradientenveränderung und benutzten dies im Rahmen der anisotropen Diffusion, um eine Anzahl räumlich variierender Diffusionsparameter zu bestimmen. In einer späteren Arbeit [95] nutzten sie die MAD, um das Rauschen an verschiedenen Stellen des Bildes mit Hilfe eines vordefinierten Gitters zu berechnen.

Die Implementierung von Nordström [90] bewirkt dank eines Kompensierungsfaktors eine Ähnlichkeit der verarbeiteten Bilder $I(\bar{x}, t)$ zu dem ursprünglichen Bild $I_0(\bar{x})$. Deshalb wird das Problem der Parameterwahl reduziert, da nur der Diffusionsfaktor gewählt werden muss, z.B. mit Hilfe der Flusskurven (Abschn. 3.1.2.1), während die Anzahl der Iterationen hinreichend groß genug gewählt wird, um die Konvergenz zu einem stabilen Bildergebnis zu ermöglichen.

Gerig et. al. [31] haben für einige Experimente beide Filterparameter (k und it) manuell anhand eines visuellen Vergleichs der Ergebnisse gewählt. Die Bestimmung des Diffusionsfaktors konnte zusammen mit den Flusskurven anhand von Rauschintensitäts- oder Kontrastmessungen durchgeführt werden. Im Fall einer Rauschintensitätsmessung wurde der Diffusionsfaktor so klein als möglich gehalten [$1.5\sigma_{noise} - 2\sigma_{noise}$]. Des Weiteren wurde von Gerig et. al. [31] eine automatische Methode für die Einstellung des k -Faktors zur Verarbeitung von MRT-Bilddaten vorgestellt, die Ähnlichkeiten mit der Methode von Canny [93] zeigt. Wieder wurde ein Gitter von lokalen Diffusionsparametern definiert, wo der Wert für jedes Gitterelement anhand der örtlichen Rauschintensität auf Basis eines lokalen Fensters bestimmter Größe bestimmt wurde. Das Signal-zu-Rausch Verhältnis (SNR), welches zur Messung des Rauschens benutzt wird, wurde hier berücksichtigt. Neu war dagegen eine Klassifikation der Gewebetypen, bei der die Methode davon ausging, dass große homogene nicht texturierte Regionen repräsentativ für die Gewebekategorien sind. Die Intensität aller zugeteilten Regionen wurde dann in einer Reihe von festgelegten Intervallen quantifiziert, wonach der minimale SNR-Wert jedes Intervalls ausgesucht wurde. Dieser Wert wurde dann benutzt, um den Diffusionsfaktor zu bestimmen. Die Anzahl der Iterationen ($it=3$) sowie die Anzahl der Intensitätsintervalle (25) und die Größe des Fensters (8x8) wurden heuristisch bestimmt.

Li und Chen [96] haben in ihrer Arbeit eine Methode vorgeschlagen, die die Diffusionskonstante während des Diffusionsprozesses variieren lässt, indem der Parameter proportional zum Iterationsschritt abnimmt. Hinter dieser Modifizierung steht die

Annahme, dass das unkorrelierte Rauschen schneller verschwindet als die realen Bildstrukturen. Somit werden diejenigen Bildelemente, die normalerweise unter die durch k definierte maximale Diffusionsstärke fallen und zusammen mit dem Rauschen verschwinden, beibehalten. Andererseits könnte eine höhere Diffusionsstärke der Rauschkomponenten, deren Gradientenbetrag größer ist als die definierte Diffusionsstärke, auch unterdrückt werden. Daher wird am Anfang ein höherer Wert für den Parameter k angesetzt. Während der Verarbeitung wird dieser Wert verringert, so dass die Bildelemente mit niedrigen Gradienten nicht zu stark geglättet werden. In der Endphase werden die bereits geglätteten Rauschelemente weiter unterdrückt, während die Diffusionsfunktion die Kanten, die am Anfang geglättet wurden, wieder verstärkt.

Monteil und Beghdadi [35] nutzen ein Konzept, welches die Eigenschaften der Arbeiten von Li & Chen und von Canny kombiniert. Hier wird der k -Faktor in Abhängigkeit einer Abschätzung des Rauschens variiert, und nur die homogenen Blöcke der Bildstruktur für die Berechnung der Rauschintensität betrachtet. Es wird ein Gitter definiert und innerhalb dieses Gitters werden SNR-Messungen durchgeführt. Die ganze Prozedur wird nach jeder Iteration wiederholt. Zur Bestimmung der Anzahl der Iterationen wurden keine Angaben gemacht. Charbonnier et. al. [33] sowie Weeratunga und Kamath [97] haben in ihrer Arbeit den Regularisierungsparameter σ und den Diffusionsparameter k experimentell angesetzt. Über die Anzahl der Iterationen wurden keine Angaben gemacht.

Generell wurde der Diffusionsparameter entweder manuell oder anhand einer Messung des Signal zu Rausch Verhältnis gewählt, um spezifische Strukturen zu verstärken, oder um die Rauschunterdrückung anhand einer globalen oder einer lokalen Abschätzung der Rauschintensität und des maximalen Flusses zu definieren. Kriterien zur Bestimmung der Anzahl der Iterationen wurden noch seltener formuliert und häufig manuell gewählt. In einigen Ausnahmen wurde anhand eines automatischen Abbruchkriteriums, das auf Basis der Anzahl der Pixel bzw. Voxel-Änderungen während der letzten zwei Filterungsschritte abgeleitet wurde, die Anzahl der Iterationen abgeschätzt.

4 Entwurf und Implementierung einer automatischen Rauschunterdrückungsmethode

4.1 Überblick

Wie im vorherigen Kapitel beschrieben, existieren einige Möglichkeiten zur Justierung der Parameter der anisotropen Diffusionsfilter, insbesondere für den Diffusionsfaktor. Nur wenige Arbeiten haben sich mit der Justierung des Parameters *Anzahl der Iterationen* *it* beschäftigt. Vorwiegend nutzen einige die Konvergenzeigenschaften der Diffusionsfunktionen aus, wodurch der Einfluss des *it*-Parameters auf das Bildergebnis eingeschränkt wird. Dadurch wird die enge Verknüpfung dieser beiden Parameter nicht berücksichtigt, wie z.B. im Verfahren von Black et. al. mit dem vorgeschlagenen automatischen Abbruchkriterium [32]. Dort ist die Anzahl von Pixel- (Voxel-) Änderungen zwischen zwei sukzessiven Filteriterationen, die als Kriterium zum Abbruch der Filteriterationen benutzt wurde, stark von der Auswahl der Diffusionsfaktoren bzw. Struktur der Bilddaten abhängig. Somit führt die Konvergenz zu einem stabilen Ergebnis, aber es gibt keine Garantie dafür, dass die gewonnenen Bilder optimal hinsichtlich der Rauschunterdrückung oder der individuellen Wahrnehmung der Benutzer sind. In der Regel wird jedes Ergebnis visuell kontrolliert und gegebenenfalls weiterverarbeitet. Besondere Beachtung verdient die Tatsache, dass die Wahrnehmung der Bildergebnisse anhand der individuellen Erwartungen jedes Benutzers sowie der vorgesehenen Anwendung, stark variieren kann. Die Ergebnisse könnten für einen bestimmten Fall (z.B. Klassifikation oder Segmentierung des Weichteilgewebes im Gehirn) optimal erscheinen aber für andere Anwendungen könnte dies nicht der Fall sein.

In der Literatur sind bereits Verfahren zu finden, die anhand der Minimierung der Bildenergie, die Parameter zur Rauschunterdrückung bestimmen [98, 99]. Diese Parameter hängen dabei ausschließlich von den Bildeigenschaften ab. Das bedeutet nicht, dass das Ergebnis auch als Idealergebnis vom Benutzer angesehen wird, bietet jedoch eine Referenz, woran individuelle Präferenzen angeknüpft werden könnten. Aus der Sichtweise der Bildverarbeitung wäre die Nutzung solcher Referenzen sehr hilfreich und die Anstrengung in diesem Gebiet begründet, um Modelle, Referenzen (Gold Standards) und Informationsdatenbanken [100-102] zu schaffen, die als Grundlage objektiver Evaluierung

und als Vergleichspunkte gelten sollten. Es gibt einige Fälle, wie z.B. in der Bildkompression [25], wo diese Referenz von demselben Originalbild zur Verfügung steht, mit der das Ergebnis des Kompressionsverfahrens verglichen wird. Ein solcher Fall eröffnet die Möglichkeit, einen rekursiven Algorithmus zu implementieren, dessen Parameter anhand einer vordefinierten Maßangabe (z.B. eine bestimmte Abweichung vom ursprünglichen Bild) optimiert werden. Im Fall der Rauschunterdrückung existieren solche Referenzen leider nicht. Um die enge Verknüpfung der Parameter *Anzahl der Iterationen* und *Diffusionsfaktor* zu berücksichtigen und gleichzeitig ein automatisches Rauschunterdrückungsverfahren verwenden zu können, wurde in dieser Arbeit ein Verfahren auf Basis rückgekoppelter adaptiver Filter entwickelt, welches in den nachfolgenden Absätzen näher beschrieben werden soll.

4.1.1 Applikationen adaptiver Filter

Prinzipiell existieren vier grundlegende Klassen von Applikationen adaptiver Filter [103], nämlich: *Systemidentifikation*, *Inverse Modellierung*, *Prädiktion* und *Interferenzunterdrückung*. In allen wird ein Eingangssignal $x[z]$ nach der Filterung mit einem Wunschsignal („desired signal“) $y[z]$ verglichen und der resultierende Fehler $e[z]$ verwendet, um die Filterkoeffizienten abzugleichen.

4.1.2 Eigene Konfiguration

Ein erstes Blockschaltbild für das automatische Rauschunterdrückungssystem wurde anhand der zuvor genannten *Prädiktion* und *Interferenzunterdrückung* Konfigurationen entworfen (Bild 4.1). Dort stellt das *adaptive Filter* Modul einen der Diffusionsfilter dar, die in Kapitel 3 vorgestellt wurden.




Bild 4.1: Blockschaltbild der Rauschunterdrückungsmethode.

Die Darstellung stellt keinen kontinuierlichen Informationsfluss dar, wie aus der Signalverarbeitung bekannt, sondern die Iterationsschritte, die in dem geschlossenen System mehrmals mit verschiedenen Parametern verarbeitet werden sollen. Nach jedem

Verarbeitungsdurchgang (loop) werden die Filterparameter hinsichtlich der Verbesserung bzw. Verschlechterung der Ergebnisse korrigiert, bis das *Evaluierungs*-Modul erkennt, dass der Zustand des Ergebnisbildes den gesuchten optimalen Punkt erreicht hat. Der Evaluierungsblock kann in zwei Komponenten unterteilt werden. Der erste Teil, der *Beobachter*, sorgt für die kontinuierliche Überwachung der Ergebnisse des Systems. Den zweiten Teil bildet die *Steuerung*, die die Parameter der Filter in Abhängigkeit der vom *Beobachter* gelieferten Informationen justiert. Sobald die optimale Parametrierung aus Sicht der *Steuerung* gefunden wurde, wird das Ausgangsbild ermittelt. Um eine automatische Regelung überhaupt definieren zu können, war es erforderlich, das Verhalten der anisotropen Diffusionsfilter bezüglich der Änderung der Parameter zu kennen. Zur Untersuchung wurden verschiedene verrauschte Bilder (mit Gaußschem- oder Rician-Rauschen) mit einigen der Diffusionsfunktionen aus Kapitel 3 verarbeitet, bei welchen die beiden wesentlichen Parameter (Anzahl der Iterationen und Diffusionsfaktor) individuell variiert wurden. Der optimale Bereich dieser Parameter wurde aufgrund einer visuellen Beurteilung festgelegt. Somit konnte das Intervall der entsprechenden Parametervariation in geeigneter Weise definiert werden. Die gewonnenen Ergebnisse wurden analysiert und für den Entwurf der Beobachteralgorithmen verwendet.

Bereits zu Beginn der Arbeit zeichnete sich ab, dass für den *Beobachter* eine direkte Auswertung zur Verbesserung der Filterergebnisse zu komplex und zu aufwendig sein würden. Die Implementierung der menschlichen Wahrnehmung in ein Computer-Programm, womit ein subjektiv verrauschtes oder schlechtes bzw. ein unverrauschtes oder gutes Bild erkannt werden soll, ist heutzutage ein noch ungelöstes Problem [104]. Im Gegensatz dazu bietet sich eine Untersuchung des unterdrückten Rauschens an. So können, in einer indirekten Weise, Aussagen über den Zustand des Ergebnisbildes gemacht werden, ohne komplizierte oder aufwendige Verfahren durchzuführen. Die Analyse des unterdrückten Rauschens bringt den zusätzlichen Vorteil, dass die Rauscheigenschaften gering in Bezug zu anatomischen Strukturen variieren, da diese von den Bildgebungstechniken und Messbedingungen abhängig sind.

4.1.2.1 Entwürfe der Beobachter

Um die unterdrückte Komponente des Signals zu ermitteln, wurde zunächst eine einfache Bildsubtraktion zwischen dem Eingangsbild und dem resultierenden Bild durchgeführt. In Bild 4.2 ist diese Operation zusammen mit zwei Serien von berechneten Bildern

dargestellt. Die Bildreihen stellen exemplarisch drei unterschiedliche Niveaus (wenig, mittel und stark geglättet) dar.




Bild 4.2: Blockschaltbild und beispielhafte Ergebnisse der Untersuchung: Die obere Reihe stellt Ergebnisbilder (PMAD2) ansteigender Diffusionsfaktoren (50, 128, 512) dar; die untere Reihe zeigt die entsprechenden Differenzbilder. Die 2D-MRT Bilder wurden in eine geneigte 3D-Darstellung gebracht, um die Rauschunterdrückung besser zu zeigen.

Die Differenzbilder zeigen deutlich den Effekt der steigenden Glättung, verursacht durch die Änderung des Diffusionsfaktors. Das linke Bild zeigt den Fall einer leichten Rauschunterdrückung. Diese ist kaum bemerkbar in den beiden Bildern. Die Bilder in der Mitte stellen eine Glättung dar, die nah zum visuellen Optimum steht. Besonders deutlich ist die Homogenität der Textur des Rauschens im Differenzbild zu erkennen. Die Bilder rechts stellen den Fall einer starken Glättung dar, wo einige feine Strukturen bereits von dem Ergebnisbild verschwunden sind, die wiederum deutlich im Differenzbild wieder zu erkennen sind. Im idealen Fall wird erwartet, dass die Filterung die Signal- und Rauschkomponenten der Bilder sauber trennt, somit sind nur die Rauschkomponenten im Differenzbild zu suchen. In der Realität wird eine nahezu saubere Trennung der beiden Komponenten erst möglich, wenn ein geeigneter Filter gefunden und parametrisiert wurde. Um genau diese Parametrierung zu finden, könnte wie in Bild 4.2 gezeigt, der Verlauf der Differenzbilder von geringer zu starker Glättung analysiert werden. Daher wurden drei weitere Komponenten in das Beobachtermodul eingefügt, um die Textur-Änderung genauer zu verfolgen, die letztendlich in einen Rückkopplungswert umgewandelt wurde. Als eine der Komponenten wurde ein lokaler Varianzoperator (LVO) [105] definiert (LVO wird in späteren Kapiteln verwendet). Der Operator wendet ein verschiebbares Messfenster mit vordefinierter Fensterbreite $LVO=(4L+1)$ und Abtastintervall (2L) an (L: 1, 1.5, 2, 2.5), um das ganze Differenzbild abzutasten. Das resultierende Varianzbild wurde zusätzlich zwischen (0-1) normiert, so dass die Varianzergebnisse verschiedener Verarbeitungsschritte direkt verglichen werden können. Im nächsten Schritt wurde ein Histogramm

[25] eingefügt, um die Verteilung der Varianzwerte zu bestimmen. Histogramme enthalten häufig Sprungstellen oder Unterbrechungen, die aufgrund der Diskretisierung entstehen. Daher wurden mit Hilfe eines Glättungsfilters (Abschn. 4.2.2) die Ergebnisse nochmals verarbeitet. Die Elemente mit den Werten gleich Null wurden bei der Auswertung von der Berechnung ausgeschlossen, da diese keine Information über das Rauschen beinhalten. Bild 4.3 zeigt eine Darstellung der drei Komponenten des *Beobachters* zusammen mit fünf Ergebnissen einer Sequenz von unterschiedlich stark geglätteten Bildern.




Bild 4.3: Blockschaltbild des Diffusionsfilterblocks und Teil der Module zur Beobachtung zusammen mit fünf Ergebnissen eines zunehmend stärker geglätteten, transaxialen T1-gewichteten MRT-Schnittbildes eines menschlichen Gehirns; Obere Reihe: Ergebnisbilder der anisotropen Diffusionsglättung (PMAD2) mit sukzessive zunehmendem Diffusionsfaktor (von links nach rechts: 64, 96, 128, 192, 256); Mittlere Reihe: Varianzbild mit einer Fensterbreite von 7x7 ($L=1.5$) Pixeln; Untere Reihe: Verteilung der Varianz anhand eines Histogramms.

Die Ergebnisse in diesem Beispiel bestätigen anhand der lokalen Varianz die in Kapitel 3 beschriebenen Tendenzen der Diffusionsfilter zur intraregionalen statt interregionalen Glättung. Die homogenen Regionen (z.B. Hintergrund) werden zunächst geglättet und schon mit niedrigen Werten der Diffusionskoeffizienten gefiltert, während die strukturreichen Regionen eine stärkere Diffusion benötigen. Die helleren Regionen des Varianzbildes stehen für höhere Varianzbeträge, während die dunkleren auf eine geringere Rauschunterdrückung hinweisen. Der Unterschied zwischen beiden Regionen wird verringert, indem der Wert des Filterparameters erhöht wird. So nähern sich die Varianzwerte der strukturreichen Regionen den anderen bis im ganzen Differenzbild ungefähr derselbe Varianzwert vorkommt (mittlere Bilder). Eine weitere Steigerung des Filterparameters verursacht die unerwünschte Glättung einiger anatomischer Strukturen. Die unterdrückten Strukturen werden im Differenzbild sichtbar (s. Bild 4.2), wodurch wiederum die lokalen Varianzwerte verändert werden. Dies erklärt die Umwandlung der

ursprünglich dunklen Region in der Mitte des ersten Bildes des lokalen Varianzoperators (Bild 4.3) in eine hellere Region des letzten Bildes der lokalen Varianz. Dasselbe Verhalten kann in der Histogrammreihe gefunden werden. Dort sind im Histogramm auf der linken Seite zwei Varianzwertpopulationen mit zwei Maxima dargestellt. Die ursprüngliche Differenz zwischen beiden Gruppen verschwindet mit zunehmender Glättung langsam, bis die Elemente beider Gruppen in einer Gaußähnlichen Glockenform miteinander verschmelzen (mittlere Bilder). An dieser Stelle zeigt das Varianzbild die ungefähre einheitliche Textur, die wiederum auf eine räumlich homogene Unterdrückung des Rauschens hinweist. Steigt der Wert der Filterparameter weiter an, werden die strukturreichen Regionen immer weiter geglättet. Die dazu entsprechenden Histogramme zeigen dies als eine erneute Trennung der beiden Varianzwertpopulationen. Dieser Prozess läuft weiter, bis wiederum zwei getrennte Maxima entstehen.

Die einzelnen Histogramme können in 3D-Kurven zusammengefasst werden, um den Verlauf der Formänderung der Histogramme bei Veränderung der Parametrierung darzustellen. Bild 4.4 und Bild 4.5 zeigen 3D-Histogrammkurven für einige der in Kapitel 3 präsentierten Diffusionsfunktionen während der Verarbeitung eines Testdatensatzes [101, 102]. In jeder dieser Kurven wurde einer der zwei wesentlichen Filterparameter geändert, um dessen Einfluss in dem Prozess besser zu erkennen. Alle gezeigten Kurven deuten auf ein einigermaßen gleiches Ansprechverhalten der Varianzverteilung. Die Bilder, in denen der Diffusionsfaktor variiert wurde, zeigen deutlich die Trennung zwischen den beiden Populationen und deren Verlauf während der Glättung.




Bild 4.4: Entwicklung der Varianzverteilung bei Anwendung verschiedener Diffusionsfunktionen und Änderung der Diffusionsfaktoren. Die Anzahl der Iterationen wurde konstant gehalten ($it=15$).




Bild 4.5: Änderung der Varianzverteilung bei Anwendung verschiedener Diffusionsfunktionen und Erhöhung der in der Filterung angewendeten Anzahl der Iterationen. Der Diffusionsfaktor jeder Diffusionsfunktion wurde bezüglich des individuellen maximalen Flusses und der Intensität des Rauschens entsprechend definiert und konstant gehalten (PMAD2 $k=18$, Tukey $k=35$, Weickert($m=2$) $k=11$, PMAD2_bias $k=21$, Tukey_bias $k=38$, Weickert($m=2$)_bias $k=13$).

Bei der Änderung der Anzahl der Filteriterationen zeigt sich dies in einigen Fällen (z.B. PMAD2) nicht so deutlich, trotzdem können die kleineren Variationen genutzt werden, um weitere Informationen über den Verlauf der Kurven zu erhalten. Bemerkenswert ist der steilere Verlauf der Kurven, der von den als *Bias* implementierten Diffusionsfunktionen [90] erzeugt wurde und eine eindeutigere Einstellung der Parameter zulässt. Die Bedeutung dieser Verlaufskurven besteht darin, dass diese mit den Verteilungskurven des idealen Falles verglichen werden können, um die optimale Verteilung des unterdrückten Rauschens zu erhalten und die optimale Parametrierung zu finden. Die in Abschnitt 2.1.5 beschriebenen Rauscheigenschaften stellen die Grundlage dazu dar, um die Evaluierung durchzuführen. Dort wurde gezeigt, dass das Rauschen innerhalb und außerhalb des gemessenen Objektes ähnlich ist, da die Molekularbewegung und das thermisch induzierte Rauschen überall vorkommt.

Im vorgestellten Verfahren würde genau das zu homogenen Varianzwerten des Differenzbildes führen. Im idealen Fall nimmt die Varianzverteilung im Histogramm die Gestalt eines Dirac-Impulses an. Daher sind im realen Fall die Parameter dem Optimum so anzunähern, dass eine schlanke und hohe glockenförmige Spitze im Histogramm entsteht. Ein Zusammenhang zwischen den Varianzbildern und der Verteilung in Histogramm ist in Bild 4.6 zu sehen. Der rote Pfeil zeigt den Punkt, an dem die Histogramm-Breite am

geringsten und die Höhe am größten ist. Dieser Punkt entspricht der erwünschten gleichmäßigen Unterdrückung des Rauschens.




Bild 4.6: Blockschaltbild des Diffusionsfilterblocks und der Module zur Beobachtung der Rauschunterdrückung. Eine Sequenz von 18 Varianzbildern (von links nach rechts und von oben nach unten) demonstriert die Veränderung der lokalen Varianzen während die 3D-Kurve den Verlauf der entsprechenden Varianzverteilung (Histogramm) zeigt.

Die Berechnung von Varianzbild und Histogramm wird anschließend für jedes erzeugte Differenzbild durchgeführt. Die Aufgabe des in Bild 4.6 eingeführten Evaluierungsmodus ist die Verteilungsinformation in einen objektiven Rückkopplungswert (M_p , "Magnitude resulted from the given parameters") umzuwandeln. Eine Reihe von Eigenschaften, wie z.B. Breite, Höhe oder Symmetrie der Histogrammkurve wurden betrachtet, um eine Funktion zu definieren, die diese Transformation durchführen soll. Bild 4.7 zeigt eine Darstellung der betrachteten Maße.




Bild 4.7: Graphische Darstellung der Komponenten, die zur Evaluierung der Varianzverteilung betrachtet wurden. Höhe, Breite bei 50% und 20% des Maximums, linke und rechte Hälfte bei 50% und 20% des Maximums und beide Flächen (A_1 , A_2).

Die aus den betrachteten Parametern vorgeschlagene Evaluierungsfunktion lautet:

$$M_p = H * \left(\frac{1}{FWHM} \right) * \left(\frac{1}{FW20\%M} \right) * \left(1 - \exp \left(- \frac{(\text{symm}_{FWHM})^m}{0.2} \right) \right) * \left(1 - \exp \left(- \frac{(\text{symm}_{FW20\%M})^m}{0.2} \right) \right) * \text{Balance} \quad (4.1)$$

Der Term Höhe (H) steht für den Betrag des Maximums des Histogramms, die Inverse der Halbwertsbreite (FWHM) und der Wert der Glockenbreite bei 20% des Maximums (FW20%M) sind Terme der Varianzstreuung, welche im Intervall zwischen Null und Eins liegen. Die zwei exponentiellen Terme spiegeln die Symmetrie des Histogramms an 50% und 20% des Maximums wieder. Die beide Variablen $\text{symm}_{\text{FWHM}}$ und $\text{symm}_{\text{FW20\%M}}$ folgen den Gleichungen:

$$\begin{aligned} \text{symm}_{\text{FWHM}} &= \frac{\text{Links}_{\text{HWHM}}}{\text{Rechts}_{\text{HWHM}}} & \text{für } \text{Links}_{\text{HWHM}} \leq \text{Rechts}_{\text{HWHM}} \\ \text{symm}_{\text{FWHM}} &= \frac{\text{Rechts}_{\text{HWHM}}}{\text{Links}_{\text{HWHM}}} & \text{für } \text{Links}_{\text{HWHM}} > \text{Rechts}_{\text{HWHM}} \end{aligned} \quad (4.2)$$

$$\begin{aligned} \text{symm}_{\text{FW20\%M}} &= \frac{\text{Links}_{\text{HW20\%M}}}{\text{Rechts}_{\text{HW20\%M}}} & \text{für } \text{Links}_{\text{HW20\%M}} \leq \text{Rechts}_{\text{HW20\%M}} \\ \text{symm}_{\text{FW20\%M}} &= \frac{\text{Rechts}_{\text{HW20\%M}}}{\text{Links}_{\text{HW20\%M}}} & \text{für } \text{Links}_{\text{HW20\%M}} > \text{Rechts}_{\text{HW20\%M}} \end{aligned} \quad (4.3)$$

Der Wert des exponentielle Terms $1 - \exp\left(-\frac{(\text{symm}_{\text{FWHM}})^m}{0.2}\right)$ kann zwischen 0.99326 (symm=1) und Null (symm=0) liegen. Der letzte Term “Balance” ist ein Quotient zwischen der linken und rechten Fläche (A1 und A2), die unter der Histogrammkurve entstanden ist (Gleichung 4.4). Im idealen Fall sollte dieser Quotient Eins ergeben.

$$\begin{aligned} \text{Balance} &= \frac{\text{Linke}_{\text{Fläche}}}{\text{Rechte}_{\text{Fläche}}} & \text{für } \text{Rechte}_{\text{Fläche}} \leq \text{Linke}_{\text{Fläche}} \\ \text{Balance} &= \frac{\text{Rechte}_{\text{Fläche}}}{\text{Linke}_{\text{Fläche}}} & \text{für } \text{Rechte}_{\text{Fläche}} > \text{Linke}_{\text{Fläche}} \end{aligned} \quad (4.4)$$

Die Gleichung 4.1 wird ihren maximalen Wert erreichen, sobald sich das Histogramm einer schmalen und hohen Gaußschen Glocke annähert.




Bild 4.8: Veränderung der lokalen Varianz und das entsprechende Ergebnis der Evaluierungsfunktion M_p .

Wie hoch insgesamt die Response M_p sein sollte, ist schwer zu sagen, da der Term H von der Anzahl der Pixel, bzw. Voxel, der Varianzbilder abhängt, die zu dem häufigsten Wert gehören. Dieser Wert ändert sich proportional zur Bildgröße (Term H : Maximalwert des Histogramms). Bild 4.8 zeigt die Ergebnisse der Evaluierungsgleichung anhand der Werte der links dargestellten Verlaufskurve. Wenn beide Filterparameter (Diffusionsfaktor k und Anzahl der Iterationen it) gleichzeitig geändert werden, entstehen die in Bild 4.9 dargestellten 3D-Plots der Funktion M_p .




Bild 4.9: Ergebnis der Evaluierungsfunktion für verschiedene Diffusionsfunktionen. Beide Filterparameter wurden in den entsprechenden Intervallen verändert.

Dort werden die Parameter, die zu hohen Werten im Kurvenverlauf gehören, als Parameterkombinationen betrachtet, die nahe der optimalen Konfiguration liegen. Diese Kurven zeigen deutlich die unterschiedlichen Effekte der verschiedenen Diffusionsfunktionen hinsichtlich der Gleichmäßigkeit der Rauschunterdrückung. Die zweite Perona-Malik Funktion (PMAD2) und die Weickert m=2 Funktion erzeugen deutlich gekrümmte Strukturen. Dies bedeutet, dass die Parameterkombinationen entlang dieser Struktur eine starke und einheitliche Rauschunterdrückung in homogenen sowie in strukturreichen Regionen bewirkt. Dagegen erzeugt die Tukey-Funktion eine schwankende Struktur, die mehrere geteilte lokale Maxima zeigt. Andererseits, aufgrund der starken Konvergenzeigenschaften der Tukey_bias-Funktion wird bereits mit kleinerer Anzahl der Iterationen ein Punkt erreicht, bei dem der maximale Wert der Evaluationsfunktion jeweils beim gleichen Wert des Diffusionsfaktors liegt. Anhand der Informationen, die diese Kurven enthalten, kann der Regelkreis geschlossen werden. Die Ergebnisse der

Evaluierungsfunktion werden mit Hilfe der Steuerungs-Algorithmen berücksichtigt, um die Filterparameter anzupassen. Im folgenden Abschnitt wird der Steuerungsteil beschrieben.

4.1.2.2 Entwürfe der Steuerung

Das vorrangige Ziel der Steuerungsalgorithmen ist die Bestimmung einer optimalen Parameterkombination, ohne die komplette Oberfläche abtasten zu müssen. Dafür wird ein schrittweises Approximationsverfahren angewandt. Die sequenzielle Abtastung erlaubt den Steuerungsregeln den Verlauf des rekursiven Prozesses mit Hilfe des Zusammenhangs zwischen den zuletzt angewandten Parametern und den entsprechenden Ergebnissen zu bestimmen. So werden die Richtung und der Betrag der Parameteränderung für jede neue Iteration festgelegt. Bild 4.10 zeigt das Blockschaltbild des automatischen Systems.





Bild 4.10: Links das Blockschaltbild des kompletten Systems (Filterung, Evaluation, Steuerung). Rechts die Ergebniskurve mit den markierten Bereichen als Produkt der Fixierung einer der beiden Filterparameter während der Suche nach der maximalen Response M_p entlang der anderen Parameterachse, um die Suche nach der optimalen Parameterkombination zu vereinfachen.

Die meisten der resultierenden Evaluierungskurven, wie die in Bild 4.9, zeigen die Existenz multipler optimaler Konfigurationen entlang der gekrümmten Struktur. Dies macht die Suche nach der optimalen Parameterkombination nicht eindeutig. Außerdem führen Nichtlinearitäten sowie viele lokale Maxima quer zum untersuchenden Intervall zu Problemen bei der Suche. Aus diesem Grund wurde das Optimierungsproblem vereinfacht, indem einer der Filterparameter festgehalten wird, während der andere Parameter variiert wird (gelbe Linien in Bild 4.10 rechts). Somit werden nur einige Intervalle it untersucht, um dort die maximale Response der Evaluierungsfunktion zu finden.

Der Parameter *Anzahl der Iterationen* it wurde aufgrund seiner diskreten Eigenschaft als der Parameter ausgewählt, der festgehalten werden soll. So kann der kontinuierliche Parameter (*Diffusionsfaktor*) variiert werden, bis für die gewählte Anzahl der Iterationen der optimale k -Faktor gefunden wird. Die Fixierung des Parameters Diffusionsfaktor ist

Zur Umsetzung der automatischen Rauschunterdrückungsmethode wurden die oben beschriebenen Verfahren in C-Routinen programmiert und in einem Programm zusammengefasst. Dabei wurde bei der Erstellung des Programms ein besonderer Schwerpunkt auf eine effiziente Implementierung hinsichtlich der Rechenzeit und Speicherauslastung gelegt. Die Bedienung des Programms soll die Eingabe von Programmparametern, wie z.B. Name des Originaldatensatzes oder die anzuwendende Diffusionsfunktion, einfach und intuitiv gestalten. Das folgende Blockschaltbild zeigt die Hauptkomponenten des Verfahrens.



Um die Rechenzeit zu verkürzen, wurde als Maßnahme während der iterativen Optimierung lediglich ein Teil des kompletten Datensatzes verwendet. Auf diese Weise wird nur eine bestimmte Anzahl der Schichten (mittlere transversale Schnitte) berück-

sichtigt, die auch die wesentlichen Informationen enthalten. Nachdem die optimalen Parameter gefunden wurden, wird der komplette Datensatz verarbeitet. Infolgedessen wurde als Eingabe ein zusätzlicher Parameter eingefügt, um dem Benutzer zu erlauben, die Größe des Ausschnittes zu definieren.

4.2.1 Adaptive Filterung

Das Modul besteht aus mehreren anisotropen Diffusionsfiltern (ADF), Routinen zur Gradientenregularisierung und den Definitionen der nicht zu optimierenden (vorgegebenen) Filterparameter. Die Parameter Diffusionsfaktor (k) und Anzahl der Iterationen (it) werden vom Steuerungsmodul zugeführt. Außerdem wird der Original- und Ergebnisdatensatz als N-dimensionale Arraystruktur ein- bzw. ausgegeben (2D Bilddaten $N=2$, 3D Bilddaten $N=3$, Multispektrale Bilddaten $N \geq 3$). Um möglichst flexible Daten verarbeiten zu können, wurden verschiedene Glättungs- sowie kantenerhaltende Diffusionsfunktionen zur Verfügung gestellt und in das Modul integriert. Zusätzlich wurden Bias-Versionen derselben Filter auf Basis der von Nordström empfohlenen Modifizierung [90] verwendet. Die Benutzer können gemäß der Anwendung auswählen, welche der Diffusionsfunktionen für die Rauschunterdrückung angewendet werden soll.

Die anisotropen Diffusionsfilter, die letztendlich in das Verarbeitungsprogramm integriert wurden, sind diejenigen, die die deutlichsten und stabilsten Evaluierungskurven produziert haben. Wie Bild 4.9 zeigt, generieren generell die zweite Perona-Malik Funktion und die Weickert Funktion in Standard und Bias Implementierungen erkennbar scharfe Strukturen, die die Suche nach der optimalen Parametrierung vereinfachen. Diese Filter wurden nach der von Gerig [31] vorgeschlagenen diskreten Implementierung anhand finiter Differenzen aufgebaut. 2D oder 3D Datensätze können verarbeitet werden (4er, 8er Nachbarschaften für 2D oder 6er, 18er, 26er Nachbarschaften für 3D). Der Anwender wählt, welche Nachbarschaft in Frage kommt. Die Anisotropie der Nachbarn ($\Delta_x, \Delta_y, \dots$) sowie der entsprechende Integrationsfaktor (Δ_i) fließen mit in die Berechnung ein.

Zur Regularisierung der Gradienten wurde ein Gaußfilter mit einer Nachbarschaft von 4 für 2D oder 6 für 3D eingesetzt. Erfahrungsgemäß wurde die Integrations-konstante kleiner als üblich gewählt ($\Delta_{IG}=0.025$) und die Anzahl der Iterationen konstant Eins gesetzt. Somit bleiben während der Glättung die meisten der feinen Strukturen (z.B. im Cerebellum) im Gradientenbild erhalten.

Die nicht zu optimierenden Parameter sowie andere Grenzwerte, die zur internen Nutzung des Verfahrens verwendet werden, sind in der Parameterdefinitionsstruktur abgespeichert worden, so dass der Anwender diese Werte nicht jedes Mal neu eingeben muss und gleichzeitig gegen Anwenderfehler vorgebeugt wird. Der Integrationsfaktor, sowie andere vorgegebene Parameter, sind statisch gesetzt und können nur intern durch eine Neukompilation des Programms geändert werden. Die verarbeiteten Daten werden sowohl dem Evaluierungsmodul zur Optimierung der wesentlichen Parameter und dem Ausgang zugeführt, um das Ergebnis zu speichern.

4.2.2 Evaluierung der Bildverbesserung

Der Beobachter enthält die zuständigen Routinen und Algorithmen, um die in Abschnitt 4.1.2.1 beschriebene Vorgehensweise zur Evaluierung der Bildergebnisse durchzuführen. Bild 4.12 zeigt eine schematisierte Darstellung des Moduls. Als Eingabe bekommt die Routine den originalen und verarbeiteten Datensatz und gibt als Ausgang das Resultat der Evaluierungsfunktion (Rückkopplungsindex M_p) weiter.




Bild 4.12: Blockschaltbild des Beobachters der automatischen Rauschunterdrückungsmethode.

Für die Extraktion der bereits unterdrückten Bildkomponenten wurde eine einfache Subtraktion von Originalbild und gefiltertem Bild angesetzt. Diese Information wird bei der Varianzoperatorroutine benutzt, um ein Bild der lokalen Rauschintensität zu gewinnen. Der lokale Varianzoperator nutzt ein sieben Element breites Fenster (2D oder 3D), um eine Messung der umliegenden Rauschintensität durchzuführen. Dieses Fenster wird auf jedes dritte Pixel bzw. Voxel angewandt, somit wird die Rechenzeit verringert, ohne die Genauigkeit der Messung zu gefährden. Die Fenstergröße und die Abtastintervalle können mit Hilfe der positiven Zahl L (1, 1.5, 2, 2.5) und den folgenden Gleichungen $F_{\text{Bereite}} = 4L + 1$, $A_{\text{Interval}} = 2L$ geändert werden. Das gewonnene Varianzbild wird anschließend mit Hilfe der Gleichung $i_{[x]} = (i_{[x]} - \text{Bild}_{\min}) / (\text{Bild}_{\max} - \text{Bild}_{\min})$ zwischen 0 und 1 normiert, wobei $i_{[x]}$ für

jedes Element des Varianzbildes steht. Die Normierungsroutine sorgt ebenfalls für eine steigende Anordnung der Intensitäten der Varianzbildelemente anhand eines Quicksort-Algorithmus und vereinfacht damit die Arbeit zur Berechnung der Histogramme. Bei der Berechnung der Histogramme wird die Intensitätsverteilung der lokalen Varianz bestimmt und mit insgesamt 120 Intervallen aufgelöst. Die Varianzelemente, deren Betrag gleich Null ist, werden nicht betrachtet, da diese keine Information über das Rauschen beinhalten. Dabei soll das Bild ausreichend homogene und strukturreiche Regionen aufweisen, damit die Veränderung der Intensitätsverteilung des Rauschens bezüglich der Justierung der Filterparameter erfasst werden kann (Bild 4.4 und Bild 4.5).

Die Histogrammergebnisse werden durch ein Mittelwertfilter geglättet, um die enthaltenen Sprungstellen oder Unterbrechungen zu beseitigen. Diese Glättung des 1D-Signals wird mit Hilfe einer Maske von 3 Elementen (1-1-1) sechsmal durchgeführt. Das Ergebnis wird zum Evaluierungsmodul weitergeleitet. In der Evaluationsroutine werden einige der Eigenschaften der Histogrammkurve mit den idealen Eigenschaften der Rauschverteilung in MRT-Bildern implizit verglichen. Dort werden die Höhe, die Halbwertsbreite, die Breite bei 20% der Höhe der linken und rechten Seite sowie die linken und rechten Flächen unterhalb der Kurve extrahiert und in die Gleichungen 4.1 bis 4.4 eingefügt, um den M_p Wert zu berechnen. Der Faktor m in der Gleichung 4.1 wurde empirisch auf den Wert 3 festgelegt und liefert damit nach unserer Erfahrung die besten Ergebnisse. Ebenso wurde die Gleichung 4.1 manuell justiert, um einige der Terme der Gleichung zu gewichten, so dass die endgültige Evaluierungsfunktion lautet:

$$M_p = 100000 * H * \left(\frac{1}{FWHM}\right)^2 * \left(\frac{1}{FW20\%M}\right) * \sqrt{1 - \exp\left(-\frac{(\text{symm}_{FWHM})^3}{0.2}\right)} * \sqrt{1 - \exp\left(-\frac{(\text{symm}_{FW20\%M})^3}{0.2}\right)} * \text{Balance}^5 \quad (4.5)$$

Die Optimierung der Gleichung 4.1 führt zu einer quadratischen Abhängigkeit des Terms $(1/FWHM)$ und einer inversen quadratischen Abhängigkeit der Symmetrieterme. Zusätzlich wurde der Balance-Term durch eine fünfte Ordnung modifiziert. Durch diese Änderung wurde das Risiko einer falschen Erkennung des Histogrammmaximus reduziert und gleichzeitig der nichtlineare Verlauf der Responsekurve verschärft. Alle dargestellten Graphiken der Funktion M_p in Bild 4.4 bis Bild 4.10 sowie die Ergebnisse des automatischen Verfahrens beziehen sich auf diese Funktion. Die Ergebnisse dieser Funktion werden zum Parameterjustierungsmodul als Rückkopplungsindex weitergegeben.

4.2.3 Parameteroptimierung

Das Steuerungsmodul kontrolliert den Verlauf der gesamten automatischen Verarbeitung, von der beginnenden Schätzung der Rauschintensität bis zur endgültigen Ausgabe des geglätteten Bildes. In Bild 4.13 ist das Blockschaltbild dieses Moduls dargestellt.




Bild 4.13: Blockschaltbild der Elemente des Steuerungsmoduls.

Es enthält verschiedene Routinen zur Bestimmung der Anfangswerte und weitere Steuerungsparameter, die während des iterativen Verfahrens optimiert werden. Der Rauschanalyseblock beinhaltet eine Routine zur robusten Messung der Rauschintensität auf Basis der *Median Absolute Deviation* (MAD) (Gl 3.20), wie von Black empfohlen [32]. Das Originalbild $x[z]$ dient hier als Eingabe und das Ergebnis wird benutzt, um die Anfangswerte des Diffusionsfaktors (k) zu bestimmen. Die durch die Rauschanalyse ermittelte Intensität des Rauschens wird zu einer ersten Schätzung des k -Faktors auf Basis der Betrachtung der entsprechenden maximalen Flusswerte (Abschn. 3.1.1 und 3.1.2) der gewählten Diffusionsfunktion (z.B. PMAD2: $k=0.5 \cdot \sigma_e$, PMAD2_bias: $k=\sigma_e$, Weickert2m: $k=0.7 \cdot \sigma_e$, und Weickert2m_bias: $k=0.5 \cdot \sigma_e$) verwendet. Diese ersten Werte des Diffusionsfaktors (k_t , k_{t-1} und k_{t-2}), die das Optimierungsverfahren benötigt, werden von der Parameterzuweisungsroutine definiert ($k_t = 1.2 \cdot k$, $k_{t-1} = k$ und $k_{t-2} = 0.8 \cdot k$). Danach werden alle drei Werte mit der entsprechenden Anzahl der Iterationen (it) kombiniert, die aus einer vordefinierten Liste von Intervallen it herangezogen wird. Diese Liste enthält die vom Programm definierten it Werte, die die zu untersuchenden Intervalle der Evaluierungskurven bestimmen (Abschn. 4.1.2.2). Jede der drei Parameterkombinationen (k , it) wird einzeln benutzt, um die zur Parameteroptimierung ausgewählten Schichten des Originalbildes zu filtern. Nach der Filterung werden die Ergebnisbilder durch das Evaluierungsverfahren verarbeitet und die entsprechenden Resultate der Evaluierungsfunktion in einem Stack des Steuerungsmoduls aufbewahrt. Ein anderer Stack beinhaltet

die zuletzt angewandten drei k -Faktoren. Die schrittweise Approximation beginnt mit der Analyse der gegebenen Parameter nachdem beide Stacks gefüllt sind. Die Steuerung analysiert die Zusammenhänge zwischen dem Betrag der Parameter und den hierauf basierenden Ergebnissen (Mp) nach drei Regeln, die die Richtung und den Betrag der Änderung der Filterparameter bestimmen:

$$\text{für } Mp(k_t) < Mp(k_{t-1}) < Mp(k_{t-2}) \Rightarrow k_{t+1} = k_{t-2} + \frac{1}{2} [(k_t - k_{t-2})] \quad (4.6)$$

$$\text{für } Mp(k_t) > Mp(k_{t-1}) > Mp(k_{t-2}) \Rightarrow k_{t+1} = k_t + \frac{1}{2} [(k_t - k_{t-2})] \quad (4.7)$$

$$\begin{aligned} \text{für } Mp(k_t) < Mp(k_{t-1}) > Mp(k_{t-2}) \Rightarrow k_{t+1} = \frac{1}{2} [(k_{t-1} + k_{t-2})] \quad \text{wenn } Mp(k_t) < Mp(k_{t-2}) \\ k_{t+1} = \frac{1}{2} [(k_{t-1} + k_t)] \quad \text{wenn } Mp(k_t) > Mp(k_{t-2}) \end{aligned} \quad (4.8)$$

Führt die Filterung beim kleinsten k -Faktor (k_{t-2}) zum höchsten Rückkopplungswert Mp und wiederum der mittlere k -Faktor (k_{t-1}) zum besseren Ergebnis als der größte k -Faktor (k_t), dann wird der Diffusionsfaktor verkleinert, um dieser abnehmenden Tendenz zu folgen. Im umgekehrten Fall, d.h. wenn die Filterung mit dem kleinsten k -Faktor (k_{t-2}) den niedrigsten Rückkopplungswert ergibt und der mittlere k -Faktor (k_{t-1}) ein schlechteres Ergebnis im Vergleich zum größten k -Faktor (k_t) erzeugt, wird der Diffusionsfaktor vergrößert, um der zunehmenden Tendenz zu folgen. Die dritte Möglichkeit ist, dass der mittlere k -Faktor das beste Ergebnis ergibt. Dann wird der Diffusionsfaktor so gewählt, dass dieser zwischen den beiden Faktoren liegt, die die besten Ergebnisse geliefert haben. Der neue Diffusionsfaktor wird ermittelt und anschließend erneut mit dem entsprechenden Parameter it zusammengeführt, um eine neue Verfahrensiteration der Optimierung zu generieren. Nach jeder neuen Analyse wird die Anordnung in beiden Stacks erneut aufgebaut, um die k -Faktoren in einer auf steigenden Reihenfolge zu haben. Die entsprechenden Ergebnisse Mp werden für die neue Anordnung entsprechend den k -Faktoren umsortiert. Das Verfahren wird mehrmals wiederholt bis eine maximale Response entsteht oder bis eine bestimmte Anzahl an Iterationen durchgeführt wurde. Normalerweise werden weniger als 14 Iterationen benötigt, um zum entsprechenden Maximum zu kommen. Der Abbruch des Verfahrens erfolgt entweder durch eine Messung der Varianz nach der siebten Iteration zwischen den zuletzt gewonnenen drei Ergebnissen, und dem Vergleich mit einem Fehlerkriterium der „minimalen Abweichung“ (0.001% des Mittelwertes der drei letzten Mp Ergebnisse), oder nach einer bestimmten Anzahl an Schleifendurchläufen. Ist die optimale Parameterkombination ermittelt, wird der nächste Wert im *Anzahl der*

Iterationen Array gewählt und das Optimierungsverfahren erneut gestartet. Das Szenario wird solange wiederholt, bis alle vordefinierten *Anzahl der Iterationen* untersucht wurden und die entsprechenden optimalen Kombinationen an Parametern zur Verfügung stehen. Die Untersuchung mehrerer Intervalle (≥ 5) wird durchgeführt, um mögliche Ausreißer, die das Optimierungsverfahren in lokale Maxima geführt haben, auszuschließen. Zum Schluss werden die Parameterkombinationen ausgewertet, um die günstigste Kombination zu ermitteln. Dies kann durch die Bewertung des Diffusionsfaktorbetrages mit Hilfe einer Medianfunktion durchgeführt werden. Der Median *k-Wert* und die entsprechende Anzahl der Iterationen *it* werden ermittelt. Eine zweite Möglichkeit ist, dies anhand eines Referenzbildes zu realisieren, welches das Mittelwertbild der Filterergebnisse alle gefundenen Parameterkombinationen darstellt. Es wird dann diejenige Kombination gewählt, die die kleinste Standardabweichung zwischen dem Bildergebnis und dem Bezugsbild generiert. Welche der beiden Parameterselektionsverfahren angewendet wird, wird intern vor der Kompilation des Programms festgelegt. Die ermittelten Parameter werden dann benutzt, um die endgültige Verarbeitung des vollständigen originalen Datensatzes durchzuführen.

4.2.4 Rechenzeit

Näherungsweise benötigt die automatische Verarbeitung eines 256x256x181 großen Datensatzes mit einem Pentium IV PC (3.2 GHz Taktfrequenz und 2GB RAM Speicher), bei einer Nachbarschaft von 6 Elementen und einer Ausschnittsdicke von 10 transversalen Schichten durchschnittlich 53 Minuten. Dieselbe Berechnung mit einer 18er Nachbarschaft beansprucht circa 151 Minuten. Wird die Anzahl der Nachbarschaft auf 26 erhöht, steigt die Rechenzeit auf etwa 200 Minuten. Diese Rechenzeiten sind auf den iterativen Charakter des Optimierungsverfahrens zurückzuführen. Für jede Iteration wird der Originaldatensatz erneut mit dem entsprechenden Parameter gefiltert (normalerweise mit mehreren Filteriterationen) und das Ergebnis im Evaluierungsverfahren ausgewertet. Dabei wird dieser Schritt mehrmals während der ganzen Prozedur wiederholt (~ 70). Die Anzahl der Wiederholungen ergibt sich aus dem Produkt *Anzahl der Optimierungsiterationen zur Justierung der Filterparameter* und *Anzahl der vordefinierten Intervalle*. Nach Festlegung der optimalen Parameter wird der komplette Datensatz mit dieser Parametrierung geglättet. Diese endgültige Glättung erhöht die Verarbeitungszeit. Im Gegensatz dazu ist mit einer Erhöhung der Rechenzeit um einen Faktor 5 zu rechnen, wenn eine komplette Abtastung der gesamten Responsekurve *Mp* (Bild 4.9) zur Optimierung der Filterparameter durchgeführt wird.

5 Evaluation der Methode anhand von Testdaten

Um die Leistung des automatischen Verfahrens zu untersuchen und gleichzeitig die Robustheit gegenüber der Änderung der Werte der festgelegten Parameter zu bestimmen, wurden verschiedene Untersuchungen mit Hilfe dreidimensionaler MRT-Datensätze (McConnell Brain Imaging Centre (BIC), Montréal Neurological Institute, McGill University) [102] durchgeführt. Für einige dieser Untersuchungen wurden die Daten mit Rice Rauschen beaufschlagt, da dieses in MRT-Datensätzen vorkommt (Abschn. 2.1.5). Mit diesen Datensätzen wurde es möglich, die Ergebnisse des automatischen Verfahrens zu evaluieren und gegenüber den Ergebnissen anderer linearer und nicht-linearer Filter zu vergleichen. Eine Reihe von Fehlermaßen und Qualitätsmerkmalen wurden für die Evaluierung der Ergebnisse angewandt, in denen der Originaldatensatz als Referenz („ground truth“) benutzt wurde. Zur Untersuchung der Robustheit des Verfahrens wurden folgende Parameter untersucht:

- die Anzahl der Schichten, die im iterativen Optimierungsverfahren zur Wahl der Filterparameter benutzt wurde (Abschn. 4.2).
- die Anzahl der Iterationen zur Regularisierung des Gaußschen Filters (Abschn. 4.2.1).
- die Größe des Kerns, der in der Evaluierung zur Bestimmung der lokalen Varianz benutzt werden (Abschn. 4.2.2).
- die Anzahl von Nachbarelementen, die bei Anwendung der anisotropen Diffusionsfilter berücksichtigt werden (Abschn. 3.1.3).

In den folgenden Absätzen wird eine detaillierte Beschreibung der Eigenschaften der angewandten Datensätze, der Bewertungsmaßstäbe, sowie der Untersuchungen und deren Ergebnisse vorgestellt.

5.1 Testdaten

Die erzeugten Testdaten wurden aus der Kombination aus einem T1-gewichteten Datensatz und einem additiven Rice-Rauschen unterschiedlicher Intensität zusammengestellt. Der erste Datensatz ist ein aus 27 Untersuchungen gemitteltes 3D-Bild eines einzelnen Probanden, aus der Datenbank des Montréal Neurological Institutes der McGill Universität

[102]. Die Dimensionen des T1-gewichteten Datensatzes sind 256x256x181 Voxel groß. Die isotropen Voxel sind 1mm^3 groß und das Intensitätsintervall streckt sich von 0 bis 254.

Eine Segmentierung mit einem automatischen Verfahren [19, 20] ergibt in der ersten Stufe des Verfahrens die Unterteilung des Referenzdatensatzes in fünf Intensitätsstufen, die sich direkt auf die entsprechenden Gewebetypen zurückführen lassen. Hintergrund, Gehirn-Rückenmarkflüssigkeit, Fettgewebe sowie graue und weiße Substanz sind in Bild 5.1 zu sehen. Die Intensitätsintervalle und Mittelwerte dieser Gewebetypen lauten:

- (HG) Hintergrund: 0-15 (7.5)
- (Liquor) Gehirn-Rückenmarksflüssigkeit: 16-62 (39)
- (GS) Graue Substanz: 63-96 (79.5)
- (WS) Weiße Substanz: 97-128 (112.5)
- (Fett) Fettgewebe: 129-254 (191.5)

In der zweiten Stufe dieses Segmentierungsverfahrens erfolgt die endgültige Segmentierung von zerebralen und extrazerebralen Regionen. Diese zweite Stufe des Verfahrens wurde jedoch nicht für die nachfolgende Verarbeitung der Bilddaten zugrunde gelegt. Das Rauschen mit Rice-Verteilung wurde anhand folgender Gleichung generiert:

$$\text{verraushtes_Bild} = \sqrt{(I_0 + n_1(\sigma))^2 + (n_2(\sigma))^2} \quad (5.1)$$

wobei I_0 für das Originalbild und $n_1(\sigma)$ bzw. $n_2(\sigma)$ für zwei voneinander unabhängige Null-zentrierte Gaußsche-Verteilungen des Rauschens stehen.




Bild 5.1: a) Transversaler Schnitt des Referenzdatensatzes; b) entsprechendes Histogramm mit den unterschiedlichen Intervallen der Gewebeklassifikation farbkodiert.

Die Werte der Standardabweichung (σ) wurden aus den Mittelwerten der Intervalle der klassifizierten Gewebetypen berechnet, so dass bestimmte Überlappungsverhältnisse im Histogramm (25%, 50%, 75% und 100%) zwischen der weißen, grauen Substanz und dem

Liquor gezielt generiert wurden ($\sigma = 0.5 * \left[\left(\overline{GS} - \overline{WS} \right) + \left(\overline{Liquor} - \overline{GS} \right) * \text{Überlappung} \right]$). Diese Verhältnisse ergaben die folgende σ Werte: 4.58, 9.16, 13.74 und 18.33. Die sich hieraus ergebenden verrauschten Bilder sind im Bild 5.2 dargestellt.




Bild 5.2: Transversaler Schnitt der generierten Test-Datensätze von leicht zu stark verrauscht (von links nach rechts) zusammen mit den entsprechenden Histogrammen ($\sigma = 4.58, 9.16, 13.74$ und 18.33).

Für die multispektrale Evaluierung wurden T1-, T2- und PD-gewichtete synthetische Datensätze von der „Simulated Brain Database“ (www.bic.mni.mcgill.ca/brainweb) [101] angewendet. Die Bilder wurden von der WebServer Anwendung selbst mit einem Rauschen von 7% und einer Inhomogenität („RF“) von 0% generiert. Die Datensätze sind $181 \times 217 \times 181$ Pixel groß, mit isotropen Voxeln von 1mm^3 und einem Intensitätsintervall für alle Datensätze von 0 bis 4095.

5.2 Bewertungsmethoden

Die Filterung der verrauschten Daten mit dem automatisierten Verfahren und anderen Rauschunterdrückungsfiltern wurde mit statistischen Messgrößen [106-108] evaluiert. Die Hälfte dieser Messgrößen sind Fehlerwerte (MAE, MSE, RMSE), während die andere Hälfte Größen darstellen, die eine Aussage über das Verhältnis vom Signal zum Rauschen (SNR, PSNR) machen oder die Ähnlichkeit gegenüber der Referenz beurteilen (SSIM) [109]. Die Gleichungen dieser Messgrößen für den dreidimensionalen Fall ergeben sich zu:

MAE - Mittlere absolute Abweichung (engl. „mean absolute deviation“)

$$\text{MAE} = \frac{1}{\text{MNP}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \sum_{z=0}^{P-1} |I_0(x, y, z) - I(x, y, z)| \quad (5.2)$$

MSE – Mittlerer quadratischer Fehler (engl. „mean squared error“)

$$\text{MSE} = \frac{1}{\text{MNP}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \sum_{z=0}^{P-1} (I_0(x, y, z) - I(x, y, z))^2 \quad (5.3)$$

RMSE - Wurzel aus mittlerem quadratischen Fehler (engl. „root mean square error“)

$$\text{RMSE} = \sqrt{\frac{1}{\text{MNP}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \sum_{z=0}^{P-1} (I_0(x, y, z) - I(x, y, z))^2} \quad (5.4)$$

SNR - Signal-Rausch-Verhältnis (engl. „signal-to-noise ratio“)

$$\text{SNR} = \frac{S}{\text{MSE}} = 10 \cdot \log_{10} \left(\frac{\sigma^2}{\sigma_e^2} \right) \quad \left| \begin{array}{l} \sigma^2 = \text{Bild - Varianz ohne Rauschen (Signal S)} \\ \sigma_e^2 = \text{MSE} \end{array} \right. \quad (5.5)$$

PSNR - Peak Signal-Rausch-Verhältnis (engl. „peak-signal-to-noise ratio“)

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{(\max(I_0(x, y, z)) - \min(I_0(x, y, z)))^2}{\sigma_e^2} \right) \quad (5.6)$$

SSIM - Structural SIMilarity (SSIM) Index [109]

$$\text{SSIM} = l(I_0, I) \cdot c(I_0, I) \cdot s(I_0, I) = \frac{(2\mu_{I_0}\mu_I + C_1)(2\sigma_{I_0, I} + C_2)}{(\mu_{I_0}^2 + \mu_I^2 + C_1)(\sigma_{I_0}^2 + \sigma_I^2 + C_2)} \quad (5.7)$$

wobei, $l(I_0, I)$ eine Funktion der Bildhelligkeit darstellt

$$l(I_0, I) = \frac{(2\mu_{I_0}\mu_I + C_1)}{(\mu_{I_0}^2 + \mu_I^2 + C_1)} \quad C_1 = (K_1 L)^2 \quad (5.8)$$

und $c(I_0, I)$ eine Funktion des Bildkontrastes,

$$c(I_0, I) = \frac{(2\sigma_{I_0}\sigma_I + C_2)}{(\sigma_{I_0}^2 + \sigma_I^2 + C_2)} \quad C_2 = (K_2 L)^2 \quad (5.9)$$

bzw. $s(I_0, I)$ eine Funktion der strukturellen Ähnlichkeit zwischen beiden Bildern.

$$s(I_0, I) = \frac{(\sigma_{I_0, I} + C_3)}{(\sigma_{I_0}\sigma_I + C_3)} \quad C_3 = C_2 / 2 \quad (5.10)$$

M, N und P sind die Dimensionen des Datensatzes, $K_1 = 2 \cdot 10^{-6}$, $K_2 = 2 \cdot 10^{-6}$. L steht für die Anzahl der Quantisierungsstufen im Bild, μ_{I_0} und μ_I sind die Intensitätsmittelwerte des Bildes, $\sigma_{I_0}^2$ und σ_I^2 stehen für die entsprechenden Bildvarianzen und $\sigma_{I_0, I}$ steht für die Kovarianz zwischen beiden Bildern. I_0 und I repräsentieren jeweils das Referenz- und das zu evaluierende Bild.

5.3 Ergebnisse und Diskussion

5.3.1 Ergebnisse des automatisierten Verfahrens im Vergleich zu anderen Rauschunterdrückungsfiltern

Die generierten Testdaten wurden mit vier anisotropen Diffusionsfiltern verarbeitet. Die zweite Perona-Malik Funktion (PMAD2), die Weickert m=2 Funktion (Weickert2m) und die jeweiligen Bias Implementierungen [90] (PMAD2_bias und Weickert2m_bias) wurden aufgrund der starken und deutlichen Signale, die das Evaluierungsmodul mit diesen Funktionen produziert (Abschn. 4.1.2.1), ausgewählt. Für den Test wurden die nicht zu optimierenden Filterparameter festgelegt. Für die iterative Optimierung wurden 10 Schichten (mittlerer transversaler Bereich) vorgesehen. Eine Kerngröße von 7 wurde für die Berechnung der lokalen Varianz angenommen und eine einzige Iteration für die Regularisierungsfaltung (Gaußfilter) festgelegt.

Die Datensätze wurden mit den folgenden Rauschunterdrückungsfiltern verarbeitet:

- Median: Medianfilter [27] mit Kerngröße 3 und drei Iterationen.
- KNN: „k-nearest-neighbour“ Filter [28] mit Kerngröße 3, drei Iterationen und $k=6$.
- SNN: „symmetric nearest neighbor“ Filter [72] mit Kerngröße 3 und drei Iterationen.
- Kuwa: Kuwahara Filter [75] mit Kerngröße 5 und drei Iterationen.
- Gs: Gaußfilter [68] mit Kerngröße 5 und 3, 6 und 9 Iterationen (Gs 3it, Gs 6it, Gs 9it).

Die Parameter dieser Filter wurden anhand von Vorversuchen an Testdaten ($\sigma = 9.16$) festgelegt, wobei die beste Parametrierung auf Basis einiger der statistischen Messgrößen verifiziert wurde. Die Ergebnisbilder jedes Filters wurden dann mit den vorgestellten Messgrößen mit dem originalen Datensatz (ohne Rauschen) als Referenz verglichen. Die folgenden Graphiken zeigen die Vorverarbeitungsergebnisse zusammen mit den Ergebnissen auf Basis des verrauschten Datensatzes (Originalbild + Rauschen: O+R).




Bild 5.3: Ergebnisse auf Basis der Fehler- und der Qualitätsmaße des Vergleichs von verrauschtem und verarbeitetem Datensatz mit dem Original für die verschiedenen Rauschintensitäten (Sigma (σ): 4.58, 9.16, 13.74 und 18.33), wo P2=PMAD2, P2_b=PMAD2_bias, W2=Weickert2m, W2_b=Weickert2m_bias.

Die Graphiken zeigen, dass die Anwendung der automatisch optimierten Diffusionsfilter zu kleineren Fehlern (MAE, MSE, RMSE) und zu besseren Bildern (anhand SNR, PSNR und SSIM) im Vergleich zu anderen Filterungsverfahren (mittlere Rauschintensitäten $\sigma = 9.16, 13.74$) führt. Für die niedrigen Rauschintensitäten ($\sigma = 4.58$, 25% Überlappung) sind die RMSE-, SNR-, PSNR- und SSIM- Werte des Median-, Gauß 3it- und KNN- Filter mit den Werten der automatisch parametrisierten PMAD2 (P2) und Weickert2m (W2) Filter vergleichbar und die MSE des Gauß 3it und KNN Filters sogar besser. Dabei sind die Bias Diffusionsfilter (P2_b=PMAD2_bias, W2_b=Weickert2m_bias) bei diesem Rauschniveau gegenüber allen anderen Filtern überlegen.

Bei hoher Rauschintensität ($\sigma=18.33$) liefert der KNN-Filter ein zu den beiden Bias Diffusionsfiltern (bei MAE, SNR und PSNR) vergleichbares Ergebnis und bessere Ergebnisse als der Weickert $m=2$ Bias Filter (bei MSE und RMSE). Der Kuwahara, symmetric-nearest-neighbour (SNN) und die anderen Gaußfilter zeigen deutlich schlechtere Ergebnisse für alle Rauschniveaus und stellen keine Alternative zu den Diffusionsfiltern dar. Bild 5.4 zeigt beispielhafte Ergebnisse der Vorverarbeitung. Dort ist zu erkennen, dass die Ergebnisse der beiden Diffusionsfilter schärfere Bilder erzeugen und gleichzeitig eine deutliche Reduktion des Rauschens bewirken.




Bild 5.4: Ergebnisse einiger Filter, a) Perona-Malik Diffusionsfilter, b) Weickert $m=2$ Diffusionsfilter, c) Median Filter d) KNN Filter.

5.3.2 Nachweis der optimalen Parameter bezüglich der Ergebnisse der Evaluierungsfunktion

Es wurde eine Untersuchung zur Bestätigung der Leistungsfähigkeit der schrittweisen Approximation durchgeführt, indem die gefundenen optimalen Parameter (k , it) mit den durch das Maximum der Evaluierungsfunktion für jeden it -Wert des untersuchten Intervalls verglichen wurden. Ein Programm wurde implementiert, um die komplette Fläche innerhalb eines gegebenen Parameterintervalls mit Hilfe des Evaluierungsverfahrens (Abschn. 4.1.2.1) abzutasten. Das Programm benutzt bei der Berechnung (analog zu der Optimierungsmethode des automatischen Verfahrens) eine vom Benutzer vorgegebene Anzahl mittlerer Schichten. Die Ergebnisse dieser Routine sind in Bild 5.5 zu sehen.




Bild 5.5: Ergebnisse der Evaluierungsfunktion für eine Auswahl an Filtern angewendet auf den Test-Datensatz ($\sigma = 9.16$), a) Perona-Malik Filter, b) Weickert ($m=2$) Diffusionsfilter, c) Bias Perona-Malik Diffusionsfilter d) Bias Weickert ($m=2$) Filter.

Die Kurven wurden im Intervall zwischen 5 und 20 Iterationen berechnet und die in Bild 5.5 gezeigten Intervalle der jeweiligen k -Faktor Achse mit 21 Samples abgetastet. Aus den in Bild 5.5 dargestellten Kurven wurden die Maximalwerte bestimmt und zusammen mit den Ergebnissen des automatischen Optimierungsverfahrens (rote/schwarze rund markierte Punkte) in Bild 5.6 eingetragen. Die automatische Parameteroptimierung wurde für 10 mittlere Schichten in den Intervallen, die der Anzahl der Iterationen 12, 14, 16, 18 und 20 entsprechen, durchgeführt. Das automatisch ermittelte Optimum ist als schwarzer runder Punkt markiert.




Bild 5.6: Ergebnisse der Evaluierungsfunktion für eine Auswahl an Filtern angewendet auf den Test-Datensatz ($\sigma = 9.16$). a) Perona-Malik Filter, b) Bias Perona-Malik Diffusionsfilter c) Weickert ($m=2$) Diffusionsfilter, d) Bias Weickert ($m=2$) Filter. Die dargestellten Fehlerabweichungen entsprechen dem Maß für die Diskretisierung der Abtastintervalle und zeigen die Auflösung des vordefinierten Punktgitters in Bild 5.18.

Die vier Graphiken in Bild 5.6 zeigen, dass die automatisch ermittelten Punkte in allen Fällen in der Nähe der abgetasteten maximalen Punkte liegen. Daraus lässt sich erkennen, dass beide Programme vergleichbare Ergebnisse liefern.

5.3.3 Einfluss der Anzahl von untersuchten Schichten im Verfahren

Diese Untersuchung versucht, den Einfluss der gewonnenen Ergebnisse bezüglich der Größe des Ausschnitts des 3D-Datensatzes zu ermitteln. Wie zuvor beschrieben (Abschn. 4.2), wird aufgrund der Rechenzeit nur ein Teil des kompletten Datensatzes (mittlerer

transversaler Ausschnitt) benutzt, um die optimalen Parameter (it und k) herauszufinden. Es wurden 10, 20, 40, 60 und 80 Schichten für dieses Experiment untersucht. Ähnlich, wie in Abschnitt 5.3.2 werden hier die Ergebnisse des automatischen Verfahrens (10 Schichten betrachtet) gegenüber den Ergebniskurven des vollständig abgetasteten Evaluierungsverfahrens bei verschiedenen Ausschnittgrößen verglichen. Bild 5.7 zeigt diese Ergebnisse.




Bild 5.7: Ergebnisse der Evaluierungsfunktion für eine Auswahl an Filtern angewendet auf den Test-Datensatz ($\sigma = 9.16$) mit 10, 20, 40, 60 und 80 Schichten, a) Perona-Malik Filter, b) Bias Perona-Malik Diffusionsfilter, c) Weickert ($m=2$) Diffusionsfilter, d) Bias Weickert ($m=2$) Diffusionsfilter. Die runden Punkte zeigen die Werte des automatischen Verfahrens ermittelt bei einem Ausschnitt von 10 Schichten.

Sehr deutlich ist zu erkennen, dass die komplette Abtastung der definierten Parameterintervalle des Kurvenverlaufes der Evaluierungsfunktionen kaum von der Schichtenanzahl abhängt, und damit die automatisch ermittelten Punkte bei 10 Schichten für jede Auswahl an gewählten Schichtgrößen der vollständigen Evaluierung ähnelt. Die maximale Schichtenanzahl ist durch den Datensatz selbst vorgegeben. Der Minimalwert hängt von der Dimensionen des lokalen Varianzoperator-Fensters ($4L+1$) und dem Abtastintervall ($2L$) ab. Bei einer gewählten Fenstergröße 7 ($L=1.5$) sind 10 Schichten vorauszusetzen, damit der lokale Varianzoperator 3 Schichten zurückliefert. Nach diesem Prinzip wurde eine weitere Untersuchung durchgeführt, diesmal für unterschiedliche Rauschintensitäten. Bild 5.8 zeigt diese Ergebnisse.




Bild 5.8: Vergleich der Ergebnisse der Evaluierungsfunktion für verschiedene Rauschintensitäten ($\sigma = 4.58, 9.16, 13.74$ und 18.33). Die Kurven wurden mit der zweiten Perona-Malik Funktion generiert für 10, 20, 40, 60 und 80 Schichten.

Beide Untersuchungen zeigen nur kleine Änderungen der Evaluationskurven, wenn die Anzahl der Schichten und damit die anatomische Information erhöht wird. Damit ist davon auszugehen, dass ein Großteil der vom Evaluierungsmodul untersuchten Information durch die Komponenten des Bildrauschens bestimmt ist.

5.3.4 Einfluss der „festgelegten“ Filterparameter in der Parameteroptimierung

Verschiedene Parameter des automatischen Verfahrens könnten einen Einfluss auf die Optimierung der Diffusionsparameter k und it haben. Aus diesem Grund wurden diejenigen Parameter untersucht, für die ein Einfluss angenommen wurde. Somit wurden die Glättungsintensität des Regularisierungsfilters, die Fenstergröße des lokalen Varianzoperators (LVO) sowie die Anzahl der Nachbarn in der 3D-Filterung variiert, um mit den gewonnenen Ergebnissen eine Aussage über die Empfindlichkeit des Verfahrens bzgl. der Parameter zu treffen. Die Tabelle 5.2 zeigt die Glättungsintensität durch die Variation der Anzahl der Iterationen It_Rf der Regularisierungsfiler für PMAD2, PMAD2_bias, Weickert2m und Weickert2m_bias. Dabei wurden insgesamt drei unterschiedliche Iterationsschritte ($It_Rf = 1$, $It_Rf = 3$ und $It_Rf = 5$) in Abhängigkeit unterschiedlicher Rauschintensitäten ($\sigma = 4.58, 9.16, 13.74, 18.33$) durchgeführt. Für eine quantitative Aussage wurden die Ergebnisse durch das statistische Fehlermaß RMSE und durch die

Signalgüte SNR beurteilt und verglichen. Die Fenstergröße des lokalen Varianzoperators (LVO) wurde konstant auf dem Wert 7 ($L=1.5$) gehalten. Dabei stellen die rot gekennzeichneten Werte in der Tabelle die optimalen Ergebnisse für die Anzahl der Iterationen It_Rf in Abhängigkeit des Rauschmaßes σ bzgl. der betrachteten Filter dar.

PMAD2	RMSE				SNR			
	4r	9r	13r	18r	4r	9r	13r	18r
It Rf = 1	5.5092	7.0522	10.9027	15.3608	25.1149	24.0425	22.1504	20.6616
It Rf = 3	5.5027	7.0721	11.422	15.7208	25.12	24.0302	21.9483	20.561
It Rf = 5	5.5068	6.992	10.9775	16.2438	25.1168	24.0798	22.1207	20.4189
Std-Ab (Rf)	0.00329	0.04171	0.28073	0.44400	0.00258	0.02583	0.10912	0.12194
Median	5.5802	9.7919	14.213	18.7106	25.0593	22.6171	20.9989	19.8049
KNN	5.2973	9.3378	13.7066	18.1808	25.2852	22.8233	21.1565	19.9296

PMAD2 bias	RMSE				SNR			
	4r	9r	13r	18r	4r	9r	13r	18r
It Rf = 1	3.7484	8.185	12.875	17.5837	26.7873	23.3956	21.4283	20.0746
It Rf = 3	3.7447	8.2148	12.8904	17.4705	26.7916	23.3798	21.4231	20.1027
It Rf = 5	3.7207	8.2158	12.9296	18.4395	26.8195	23.3793	21.4099	19.8682
Std-Ab (Rf)	0.01504	0.01750	0.02815	0.52981	0.01748	0.00927	0.00949	0.12805
Median	5.5802	9.7919	14.213	18.7106	25.0593	22.6171	20.9989	19.8049
KNN	5.2973	9.3378	13.7066	18.1808	25.2852	22.8233	21.1565	19.9296

Weickert2m	RMSE				SNR			
	4r	9r	13r	18r	4r	9r	13r	18r
It Rf = 1	5.6467	7.5282	11.3321	15.8101	25.0078	23.7588	21.9826	20.5364
It Rf = 3	5.5207	7.465	11.0928	16.1018	25.1058	23.7954	22.0753	20.457
It Rf = 5	5.5327	7.4676	11.0117	17.4471	25.0964	23.7939	22.1072	20.1085
Std-Ab (Rf)	0.06954	0.03576	0.16658	0.87318	0.05407	0.02071	0.06473	0.22762
Median	5.5802	9.7919	14.213	18.7106	25.0593	22.6171	20.9989	19.8049
KNN	5.2973	9.3378	13.7066	18.1808	25.2852	22.8233	21.1565	19.9296

Weickert2m bias	RMSE				SNR			
	4r	9r	13r	18r	4r	9r	13r	18r
It Rf = 1	3.9343	8.6267	13.4857	18.3467	26.5771	23.1673	21.227	19.8902
It Rf = 3	3.9132	8.698	13.5938	18.2433	26.6004	23.1315	21.1923	19.9147
It Rf = 5	3.9383	8.785	13.9117	19.2282	26.5727	23.0883	21.0919	19.6864
Std-Ab (Rf)	0.01349	0.07928	0.22144	0.54126	0.01489	0.03956	0.07016	0.12534
Median	5.5802	9.7919	14.213	18.7106	25.0593	22.6171	20.9989	19.8049
KNN	5.2973	9.3378	13.7066	18.1808	25.2852	22.8233	21.1565	19.9296

Tabelle 5.1: Ergebnisvergleich des automatischen Verfahrens bezüglich Variationen in der Anzahl der Iterationen der Regularisierungsfiler (1, 3 und 5 Iterationen) nach der Verarbeitung der Datensätze mit unterschiedlichen Rauschintensitäten ($\sigma = 4.58, 9.16, 13.74$ und 18.33) bei konstanter Fenstergröße 7 ($L=1.5$). Die Standardabweichung der drei Variationen von It_Rf ist als Std-Ab (Rf) bezeichnet. Zum Vergleich sind die Ergebnisse der Median und KNN Filter aufgeführt.

Anhand dieser Ergebnisse soll eine Aussage über die Robustheit und Glättungscharakteristik der einzelnen Filter herausgearbeitet werden. Dazu wurden für alle Filter die

Standardabweichung der Ergebnisse des Fehlermaßes RMSE und der Signalgüte SNR über die betrachteten Iterationsschritte It_{RF} berechnet und in der Tabelle in der Zeile Std-Ab(Rf) dargestellt. Zusätzlich wurden zum Vergleich die Glättungsergebnisse für die Rauschunterdrückungsfilter Median und KNN-Filter aufgetragen, die in Abschn. 5.3.1 bereits untersucht wurden und dort durchaus optimale Ergebnisse lieferten. Alle untersuchten Diffusionsfilter zeigen bei konstanter Fenstergröße nur geringe Variationen bzgl. der Glättungsintensität, was anhand der Standardabweichung Std-Ab(Rf) erkennbar wird und auf eine Unempfindlichkeit der Filter hinsichtlich der Anzahl der Iterationen hinweist. Sicherlich lässt sich für jeden einzelnen Diffusionsfilter eine optimale Anzahl von Iterationsschritten finden die somit zum günstigsten Glättungsergebnis führt, doch zeigen die Ergebnisse in der Tabelle 5.1 sehr deutlich, dass die anisotropen Diffusionsfilter in den berechneten Fällen teilweise gleiche, doch oftmals wesentlich bessere Glättungsergebnisse erzielen als die beiden anderen untersuchten Filter.

Um eine Vorstellung zu bekommen, in welcher Größenordnung und unter welchen Bedingungen die anisotropen Diffusionsfilter dem Median- und KNN-Filter zu bevorzugen sind, wurde der Glättungsgewinn der einzelnen Filter bzgl. des Fehlermaßes RMSE bei konstanter Fenstergröße $LVO=7$ und beispielhaft bei einem Iterationsschritt $It_{Rf}=1$ in Tabelle 5.2 im Vergleich zu Median- und KNN-Filter aufgetragen (z.B. Gewinn $PMAD2 = 100 \cdot (\text{Median_RMSE} - PMAD2_RMSE) / \text{Median_RMSE}$). Zusätzlich zu den prozentualen Angaben sind die Gewinnabweichungen der einzelnen Diffusionsfilter bei $Rf = 1, 3, 5$ als Toleranzwerte angegeben (Standardabweichung[Gewinn $PMAD2$ Rf_1 , Gewinn $PMAD2$ Rf_2 , Gewinn $PMAD2$ Rf_3]). Somit ist sehr deutlich erkennbar, dass der $PMAD2$ -Filter bei geringer Rauschintensität $\sigma = 4.58$ nur um ca. 1.27% besser glättet als der Medianfilter, jedoch der $PMAD2_bias$ einen Glättungsgewinn von 32.82% verspricht. Die Abweichung zum optimalen Glättungsergebnis weicht lediglich um 0.05 bzw. 0.26% ab.

RMSE Gewinn Rf_1 (anisotrope Diffusionsfilter vs. Median Filter) %				
Rauschintensität (σ)	04r	09r	13r	18r
PMAD2	1.27	27.97	23.29	17.90
PMAD2 Toleranzen	0.05	0.42	1.97	2.37
PMAD2_bias	32.82	16.41	9.41	6.02
PMAD2_bias Toleranzen	0.26	0.17	0.19	2.83
Weickert2m	-1.19	23.11	20.26	15.50
Weickert2m Toleranzen	1.24	0.36	1.17	4.66
Weickert2m_bias	29.49	11.89	5.11	1.94
Weickert2m_bias Toleranzen	0.24	0.80	1.55	2.89

RMSE Gewinn Rf_1 (anisotrope Diffusionsfilter vs. KNN Filter) %				
Rauschintensität (σ)	04r	09r	13r	18r
PMAD2	-4.00	24.47	20.45	15.51
PMAD2 Toleranzen	0.06	0.44	2.04	2.44
PMAD2_bias	29.23	12.34	6.06	3.28
PMAD2_bias Toleranzen	0.28	0.18	0.20	2.91
Weickert2m	-6.59	19.38	17.32	13.04
Weickert2m Toleranzen	1.31	0.38	1.21	4.80
Weickert2m_bias	25.73	7.61	1.61	-0.91
Weickert2m_bias Toleranzen	0.25	0.84	1.61	2.97

Tabelle 5.2: Prozentualer RMSE Gewinn des automatischen Verfahrens für einen Iterationsschritt der Regularisierungsfiter mit der Abweichung zum optimalen Ergebnis in der Anzahl der Iterationen im Vergleich zu den Ergebnissen der Median und KNN Filter nach der Verarbeitung der Datensätze mit unterschiedlichen Rauschintensitäten ($\sigma = 4.58, 9.16, 13.74$ und 18.33) und bei konstanter Fenstergröße 7 ($L=1.5$).

Anhand dieser Darstellung ist für den Anwender die Glättungscharakteristik der anisotropen Diffusionsfilter bzgl. Median- und KNN-Filter sehr gut erkennbar. Die Bias-Filter versprechen bei einem Iterationsschritt für geringe Rauschintensitäten ($\sigma = 4.58, \sigma = 9.16$) wesentlich bessere Glättungsergebnisse und die PMAD2 bzw. Weickert2m Filter bei hohen Rauschintensitäten ($\sigma = 13.74, \sigma = 18.33$) verglichen mit den anderen Rauschunterdrückungsfiter.

Die Glättungseigenschaften des automatischen Verfahrens kann zusätzlich durch die Variation der Fenstergröße beeinflusst werden. Die Auswirkung dieses Parameters auf die zuvor untersuchten Diffusionsfilter wurde anhand des gleichen Datensatzes und bei einem Iterationsschritt ($It_Rf = 1$) untersucht. Die dazu ermittelten Ergebnisse sind in Tabelle 5.3 aufgetragen. Wie schon zuvor in Tabelle 5.1 sind die besten Glättungsergebnisse rot gekennzeichnet. Auch bei der Variation der Fenstergröße (5, 7 und 9 Pixel/Voxel) lassen sich anhand der berechneten Standardabweichung Std-Ab(Rf) keine großen Abweichungen feststellen, was auf die Robustheit des automatischen Verfahrens bzgl. der Fenstergröße schließen lässt.

PMAD2	RMSE				SNR			
	4r	9r	13r	18r	4r	9r	13r	18r
LVO = 5	6.0605	6.9853	10.8228	15.1377	24.7007	24.0839	22.1823	20.7251
LVO = 7	5.5092	7.0522	10.9027	15.3608	25.1149	24.0425	22.1504	20.6616
LVO = 9	5.5094	6.9927	10.5308	16.1417	25.1147	24.0793	22.3011	20.4463
Std-Ab (LVO)	0.31824	0.03668	0.19577	0.52719	0.23908	0.02269	0.07942	0.14613
Median	5.5802	9.7919	14.213	18.7106	25.0593	22.6171	20.9989	19.8049
KNN	5.2973	9.3378	13.7066	18.1808	25.2852	22.8233	21.1565	19.9296

PMAD2 bias	RMSE				SNR			
	4r	9r	13r	18r	4r	9r	13r	18r
LVO = 5	3.7447	8.1832	12.8011	17.4586	26.7916	23.3965	21.4533	20.1056
LVO = 7	3.7484	8.185	12.875	17.5837	26.7873	23.3956	21.4283	20.0746
LVO = 9	3.7489	8.1888	12.9486	17.5862	26.7866	23.3935	21.4035	20.074
Std-Ab (LVO)	0.00229	0.00286	0.07375	0.07296	0.00271	0.00154	0.02490	0.01807
Median	5.5802	9.7919	14.213	18.7106	25.0593	22.6171	20.9989	19.8049
KNN	5.2973	9.3378	13.7066	18.1808	25.2852	22.8233	21.1565	19.9296

Weickert2m	RMSE				SNR			
	4r	9r	13r	18r	4r	9r	13r	18r
LVO = 5	5.5465	7.5284	11.0569	15.3864	25.0856	23.7587	22.0894	20.6544
LVO = 7	5.6467	7.5282	11.3321	15.8101	25.0078	23.7588	21.9826	20.5364
LVO = 9	5.5434	7.558	11.6555	16.8474	25.088	23.7417	21.8604	20.2604
Std-Ab (LVO)	0.05877	0.01715	0.29962	0.75167	0.04563	0.00984	0.11459	0.20221
Median	5.5802	9.7919	14.213	18.7106	25.0593	22.6171	20.9989	19.8049
KNN	5.2973	9.3378	13.7066	18.1808	25.2852	22.8233	21.1565	19.9296

Weickert2m bias	RMSE				SNR			
	4r	9r	13r	18r	4r	9r	13r	18r
LVO = 5	3.9503	8.659	13.4377	18.2398	26.5594	23.1511	21.2425	19.9155
LVO = 7	3.9343	8.6267	13.4857	18.3467	26.5771	23.1673	21.227	19.8902
LVO = 9	3.9345	8.6404	13.3945	18.3349	26.5768	23.1604	21.2565	19.893
Std-Ab (LVO)	0.00918	0.01621	0.04562	0.05861	0.01013	0.00813	0.01476	0.01387
Median	5.5802	9.7919	14.213	18.7106	25.0593	22.6171	20.9989	19.8049
KNN	5.2973	9.3378	13.7066	18.1808	25.2852	22.8233	21.1565	19.9296

Tabelle 5.3: Ergebnisvergleich des automatischen Verfahrens bezüglich des lokalen Varianzoperators bei unterschiedlichen Fenstergrößen (5, 7 und 9 Pixel/Voxel) nach der Verarbeitung der Datensätze mit unterschiedlichen Rauschintensitäten ($\sigma = 4.58, 9.16, 13.74$ und 18.33) bei konstanter Anzahl der Iterationsschritte $It_Rf=1$.

Die Tabellen zeigen generell eine leichte Tendenz, dass bessere Ergebnisse für eine Fenstergröße mit dem Wert 5 erreicht werden. Für die Perona-Malik und Weickert ($m=2$) Filter wurden in 2 von 4 der Fällen die besten Ergebnisse mit der Fenstergröße 5 erreicht. Dieser scheinbar optimale Parameter zeigt sich ebenfalls bei der Perona-Malik Bias Funktion, die bei allen Rauschintensitäten für die Fenstergröße 5 die besten Ergebnisse liefert. Abweichend dazu zeigt der Weickert ($m=2$) Bias Filter die besten Ergebnisse bei der Fenstergröße 7.

Für eine genauere Analyse wurde auch bei der Variation der Fenstergröße eine Glättungsgewinn/Verlustrechnung in tabellarischer Form im Vergleich zu Median und KNN-Filter zusammengestellt (siehe Tabelle 5.4).

RMSE Gewinn LVO_7 (anisotrope Diffusionsfilter vs. Median Filter) %				
Rauschintensität (σ)	04r	09r	13r	18r
PMAD2	1.27	27.97	23.29	17.90
PMAD2 Toleranzen	5.70	0.37	1.37	2.81
PMAD2_bias	32.82	16.41	9.41	6.02
PMAD2_bias Toleranzen	0.04	0.02	0.51	0.38
Weickert2m	-1.19	23.11	20.26	15.50
Weickert2m Toleranzen	1.05	0.17	2.10	4.01
Weickert2m_bias	29.49	11.89	5.11	1.94
Weickert2m_bias Toleranzen	0.16	0.16	0.32	0.31

RMSE Gewinn LVO_7 (anisotrope Diffusionsfilter vs. KNN Filter) %				
Rauschintensität (σ)	04r	09r	13r	18r
PMAD2	-4.00	24.47	20.45	15.51
PMAD2 Toleranzen	6.00	0.39	1.42	2.89
PMAD2_bias	29.23	12.34	6.06	3.28
PMAD2_bias Toleranzen	0.04	0.03	0.53	0.40
Weickert2m	-6.59	19.37	17.32	13.03
Weickert2m Toleranzen	1.10	0.18	2.18	4.13
Weickert2m_bias	25.73	7.61	1.61	-0.91
Weickert2m_bias Toleranzen	0.17	0.17	0.33	0.32

Tabelle 5.4: Prozentualer RMSE Gewinn des automatischen Verfahrens bei einer Fenstergröße des Varianzoperators gleich 7 und die entsprechende Toleranz zu Variationen in diesem Wert (LVO Fenster gleich 5 und 9) bezüglich der Ergebnisse der Median und KNN Filter nach der Verarbeitung der Datensätze mit unterschiedlichen Rauschintensitäten ($\sigma = 4.58, 9.16, 13.74$ und 18.33) und bei konstanter Anzahl der Iterationen des Regularisierungsfilters ($R_f = 1$ Iteration).

Aus Tabelle 5.4 sind sehr deutlich die spezifischen Glättungscharakteristika der Diffusionsfilter erkennbar. Somit ist bei einem gering verrauschten Datensatz ($\sigma = 4$) die Verwendung eines PMAD2 bzw. Weickert2m Filters nicht zu empfehlen, da die zu erwarteten Glättungsergebnisse teilweise schlechter sind gegenüber dem Median und KNN-Filter. Wird hingegen ein PMAD2_Bias bzw. Weickert2m_bias Filter verwendet, erhält der Anwender um ca. 30% besser geglättete Ergebnisse als mit den anderen Rauschunterdrückungsfiltern. Auch hier ist deutlich zu erkennen, dass die Bias-Filter besonders gut bei geringen Rauschintensitäten arbeiten, wohingegen die PMAD2 bzw. Weickert Filter besonders gute Ergebnisse für stärker verrauschte Bilder liefern.

Als dritter Parameter wurde die Empfindlichkeit bezüglich der Anzahl der Nachbarn in der 3D-Filterung untersucht. In der Untersuchung wurde ein Testdatensatz ($\sigma = 9.16$) mit allen vier Diffusionsfiltern und 6, 18 und 26 Nachbarn verarbeitet. Die Tabelle 5.5 zeigt die Resultate des Wurzel aus mittlerem quadratischen Fehlers (RMSE) und des Signal-Rausch-Verhältnisses (SNR).

Rician $\sigma = 9.16$	RMSE				SNR			
	P2	P2 b	W2	W2 b	P2	P2 b	W2	W2 b
6N	7.0522	8.185	7.5282	8.6267	24.0425	23.3956	23.7588	23.1673
18N	7.3259	7.2853	7.9059	7.7666	23.8771	23.9013	23.5462	23.6234
26N	7.5601	7.1154	8.0013	7.672	23.7405	24.0038	23.4941	23.6766
Std-Ab (N)	0.25421	0.57480	0.25019	0.52602	0.15123	0.32561	0.14023	0.27995
Median	9.7919				22.6171			
KNN	9.3378				22.8233			

Tabelle 5.5: Ergebnis des automatischen Verfahrens bezüglich der betrachteten Anzahl der Nachbarelemente während der 3D-Filterung (6, 18, 26 Nachbarn) für die PMAD2 (P2), PMAD2_bias (P2_b), Weickert2m (W2) und Weickert2m_bias (W2_b) Filter. Die Ergebnisse der Median- und KNN-Filter wurden als Referenz angeführt.

Die Tabelle 5.5 zeigt, dass die 6er-Nachbarschaft die besten Ergebnisse für die beiden Standard Diffusionsfilter (PMAD2 und Weickert2m) ergab, während für die beiden Bias Implementierungen (PMAD2_bias und Weickert2m_bias) die besten Ergebnisse mit der 26er-Nachbarschaft erreicht wurden. Dies kann dadurch erklärt werden, dass die Bias Diffusionsfilter moderat auf den Einfluss der benachbarten Pixel/Voxel reagieren, während der Standard Diffusionsfilter ohne Beschränkungen arbeiten und so wiederum zur Glättung der anatomischen Strukturen führen. Ein klarer Vorteil, die 6er-Nachbarschaft anzuwenden, ist durch die kurze Rechenzeit gegeben. Abschließend kann zusammengefasst werden, dass die Standard- als auch Bias-Diffusionsfilter sehr robust sind gegenüber der Variation der Parameter Anzahl der Iterationen, Fenstergröße und Nachbarschaften. Die Diffusionsfilter zeigen jeder für sich in Abhängigkeit des Rauschmaßes besonders gute Eigenschaften. Anhand der Tabellen 5.3 und 5.5 bekommt der Anwender einen Überblick, welchen Filter er bei dem automatischen Rauschunterdrückungsverfahren verwenden sollte, um für einen leicht oder stark verrauschten Datensatz optimale Glättungsergebnisse zu erhalten. Unter dieser Voraussetzung sind die anisotropen Diffusionsfilter den übrigen getesteten nichtlinearen Rauschunterdrückungsfilter im Vorteil und zu empfehlen.

5.3.5 Ergebnis der multispektralen Filterung

Der Einfluss der multispektralen Glättung im Vergleich zur Glättung einzelner Datensätze wurde abschließend untersucht. Wie Gerig et al. in ihrer Arbeit [31] beschrieben haben, können Datensätze mit multispektralen Informationen, wie z.B. T1- und T2-gewichtete MRT Datensätze, gemeinsam verarbeitet werden, um die verschiedenen Bildregionen anhand des komplementären Bildinhaltes mehrerer Bilddaten besser zu unterscheiden. Hierzu wird in der Berechnung der lokalen Gradienten, der Betrag des Gradienten aus den Gradienten aller beteiligten Bilddatensätze berechnet (Gleichung 5.11), um eine geeignete

Funktion für den Diffusionskoeffizienten $c(\bar{u}, t) = f(\zeta_t(\bar{u}, t))$ zu definieren und auf diese Weise die Glättung des Rauschens zu erreichen, während die Kanten der Bildregionen möglichst erhalten bleiben [31, 36].

$$\zeta_t(\bar{u}, t) = \sqrt{\left(\nabla I_1^2 + \nabla I_2^2 + \dots + \nabla I_n^2 \right)} \quad (5.11)$$

In dieser Untersuchung wurden die Ergebnisse eines T_1 -, T_2 - und PD-gewichteten Testdatensatzes (Abschn. 5.1) mit den in Abschn. 5.2 definierten Fehler- und Qualitätsmaßen evaluiert (Tabelle 5.6).

		lcbm_normal_1mm_pn7_rf0					
Rauschniveau pn = 7		MAE	MSE	RMSE	SNR	PSNR	SSIM
T_1	Original+Rauschen	214.15	64520	254.01	35.674	48.088	0.96115
	ADF PMAD2	209.71	55790	236.2	35.989	48.403	0.96639
	ADF PMAD2 bias	215.47	59081	243.07	35.865	48.279	0.96378
	ADF Weickert2m	211.84	58025	240.88	35.904	48.318	0.96508
	ADF Weickert2m bias	214.74	58295	241.44	35.894	48.308	0.96451
	ADF Multi PMAD2	207.36	54493	233.44	36.040	48.455	0.96724
	ADF Multi PMAD2 bias	208.15	55306	235.17	36.008	48.422	0.96677
	ADF Multi Weickert2m	209.32	56467	237.63	35.963	48.377	0.96610
	ADF Multi Weickert2m bias	209.26	56059	236.77	35.979	48.393	0.96636
T_2	Original+Rauschen	344.21	177940	421.83	34.232	45.979	0.90412
	ADF PMAD2	341.21	171830	414.52	34.276	46.054	0.90311
	ADF PMAD2 bias	340.64	175480	418.91	34.262	46.009	0.90134
	ADF Weickert2m	340.95	174990	418.32	34.268	46.015	0.90295
	ADF Weickert2m bias	340.63	174250	417.44	34.277	46.024	0.90295
	ADF Multi PMAD2	335.13	160420	400.52	34.457	46.204	0.9129
	ADF Multi PMAD2 bias	334.56	161430	401.79	34.443	46.19	0.91183
	ADF Multi Weickert2m	341.54	170690	413.15	34.322	46.069	0.90794
	ADF Multi Weickert2m bias	334.94	160080	400.11	34.461	46.208	0.91278
PD	Original+Rauschen	609.85	483540	695.37	35.133	43.787	0.89676
	ADF PMAD2	609.92	481260	693.73	35.143	43.797	0.89741
	ADF PMAD2 bias	619.45	477170	690.77	35.162	43.816	0.89708
	ADF Weickert2m	618.47	476180	690.05	35.167	43.82	0.89774
	ADF Weickert2m bias	622.68	481980	694.25	35.14	43.794	0.89568
	ADF Multi PMAD2	609.81	463540	680.84	35.225	43.879	0.90203
	ADF Multi PMAD2 bias	611.62	462040	679.74	35.232	43.886	0.90219
	ADF Multi Weickert2m	609.98	462350	679.96	35.23	43.884	0.90244
	ADF Multi Weickert2m bias	610.46	461830	679.58	35.233	43.887	0.90252

Tabelle 5.6: Ergebnis des multispektral verarbeiteten Datensatzes verglichen mit den einzeln verarbeiteten und den unverarbeiteten Datensätzen für drei unterschiedliche Spektren (T_1 -, T_2 - und PD-gewichtet).

Die sechs Zeilen pro Spektrum zeigen die Ergebnisse für den verrauschten, einzeln verarbeiteten und multispektral verarbeiteten Datensatz, die Spalten der Tabelle 5.6 zeigen die Ergebnisse hinsichtlich der verschiedenen Messgrößen. Die rot markierten Zahlen zeigen die besten Ergebnisse.

Der Einfluss der zusätzlich verarbeiteten multispektralen Informationen wird anhand der festgelegten Messgrößen (MAE, MSE, RMSE, usw.) dargestellt, um einen Vergleich zu den zuvor untersuchten Filtern ziehen zu können. Anhand der Daten ist eine zusätzliche Reduktion des Glättungsfehlers und damit Erhöhung der Rauschunterdrückungseigenschaften der Filter, unabhängig vom verwendeten Filtertyp, festzustellen. Aufgrund dieser Tatsache ist eine multispektrale Datenverarbeitung zu bevorzugen, wenn multispektrale Daten bei der MRT-Messung aufgenommen werden können und somit zu einer Erhöhung der Bildqualität und gleichzeitig zu einer Erhöhung der Robustheit der Vorverarbeitung herangezogen werden können.

5.3.6 Untersuchung anhand realer MRT-Bilddaten

Um das automatische Verfahren validieren zu können, wurde ein realer Testdatensatz untersucht, an dem die Bestimmung der optimalen Parameter demonstriert werden soll. Eine quantitative Beurteilung der Bildergebnisse ist auf Basis des Original Datensatzes nicht möglich und es ist eine subjektive Beurteilung erforderlich, da die bearbeiteten Bilddaten keiner Referenz unterliegen, an der die Bildverbesserung durch MAE, RMSE, SNR, usw. Größen beurteilt werden kann. Aus diesem Grund wird der reale Datensatz mit derselben Prozedur verarbeitet, wie die simulierten Daten in Abschn. 5.3.2, um anhand der Ergebnisse eine Aussage über die Bildverbesserung geben zu können.

In Bild 5.9a ist der reale Original Datensatz dargestellt. Dieser wurde mit allen zur Verfügung stehenden Diffusionsfiltern verarbeitet. Exemplarisch ist in Bild 5.9c die Evaluierungsfunktion des PMAD2 Perona-Malik Diffusionsfilters dargestellt, der zu dem Ergebnisbild (Bild 5.9b) führt. Das vollständige Verfahren ermittelt hierzu die Maximalwerte der dargestellten Evaluierungsfunktion innerhalb des definierten Intervalls. Die mit den automatische Verfahren ermittelten optimalen Parameter (*it*, *k-Faktor*) sind als rote runde Punkte im Diagrammen in Bild 5.9d-g dargestellt und bilden die Grundlage zur Bestimmung der endgültigen Parameterkonfiguration (schwarzer runder Punkt) nach der in Abschn. 4.2.3 beschriebenen Vorgehensweise. Die Bestimmung auf Basis der

vollständigen Evaluierungsfunktion wurde zusätzlich für unterschiedliche Anzahlen der untersuchten Schichten durchgeführt und die Ergebnisse der Evaluierungsfunktion sind in Bild 5.9d-g dargestellt.




Bild 5.9: Untersuchung anhand realer MRT-Daten: a) Original Datensatz, b) Ergebnisse der Filterung mit Perona-Malik Diffusionsfilter, c) Evaluierungskurve der Evaluierungsfunktion für den Perona-Malik Filter und 10 Schichten, d) maximale Punkte der Evaluierungskurve des Perona-Malik Filters mit den automatisch ermittelten optimalen Parametern für verschiedene Schichtdicken. e) Ergebnisse für den Perona-Malik bias Filter, f) maximale Punkte der Evaluierungskurve den Weickert2m Filters, g) Evaluierungskurve zusammen mit den automatisch ermittelten optimalen Parametern den Weickert2m bias Filter.

Prinzipiell ist ein ähnlicher Kurvenverlauf der Evaluierungsfunktionen untereinander erkennbar. Daher ist anzunehmen, dass das automatische Verfahren gegenüber einer Variation der Schichtdicken ebenfalls robust genug ist. Anhand der Glättung eines realen Testdatensatzes konnte gezeigt werden, dass die Diffusionsfilter in der Regel zu einer

Bildverbesserung führen, wobei der Perona-Malik (PMAD2) Filter hier die besten Bildergebnisse lieferte. Trotzdem ist an dieser Stelle darauf hinzuweisen, dass im Gegensatz zu den kontrollierten Testbedingungen in realen Fällen die Bedingungen stark variieren können, da die Eigenschaften der Ergebniskurve Mp nicht immer deutlich genug oder geeignet erscheinen, wie die nächsten Beispiele zeigen.




Bild 5.10: Ergebnis der Evaluierungsfunktion (Weickert2m und Wieckert2m Bias) einiger realer Datensätze, wo mehrere lokale Maxima vorhanden sind. Die gekrümmte Struktur zeichnet sich ab, ist jedoch schwer zu erkennen.

An diesen Beispielen sind unscharfe Konturen sowie Unterbrechungen der charakteristisch gekrümmten Struktur (mehrere lokale Maxima) zu erkennen. In solchen Fällen zeigt sich die Notwendigkeit, mehrere vom Parameter it definierte Intervalle abzutasten. Damit könnten lokale Maxima ausgeschlossen werden. Die vordefinierten fünf iterative Optimierungen des Parameters k (anhand der Fixierung des Parameters it) stellt einen guten Kompromiss zwischen Robustheit und Genauigkeit bzw. der entsprechenden Rechenzeit dar.

5.3.7 Zusammenfassung und Diskussion

Die Reihe von Untersuchungen mit synthetischen Datensätzen zeigen anhand des Vergleichs der automatisch ermittelten Ergebnisse mit den Ergebnissen anderer häufig in der medizinischen Bildverarbeitung angewandter Rauschunterdrückungsfilter eine valide neue Rauschunterdrückungsmethode, die zugleich stabil ist bezüglich der Änderungen einiger interner Parameter. In den Graphiken (Abschn. 5.3.1) haben die Fehlerwerte und Qualitätsmerkmale die bessere Leistung der automatisch justierten Diffusionsfilter gegenüber den Ergebnissen anderer Filter gezeigt, insbesondere für die mittleren Intensitätsniveaus des Rauschens ($\sigma = 9.16$ und 13.74). Für eine niedrige oder höhere Rauschintensität ($\sigma = 4.58$ und 18.33) wurden einige Ergebnisse des Median, Gauß (3it) und „k-nearest-neighbour“ (KNN) Filter vergleichbar mit denen der Diffusionsfilter oder sogar besser, insbesondere die der KNN-Filter. Die Standard Perona-Malik und Weickert Filter liefern durchgehend die besten Ergebnisse bei hohen Rauschintensitäten ($\sigma=18.33$).

Die beide Bias Filter dagegen lieferten die besten Ergebnisse bei niedrigen Rauschintensitäten ($\sigma=4.58$).

Um eine Aussage treffen zu können, inwieweit die automatisch bestimmten Parameter hinreichend gut bestimmt wurden, ist die Evaluierungskurve in der beschriebenen Untersuchung mit vordefinierten Intervallen (Variation der Parameter k und it) diskret abgetastet worden, um ebenfalls durch Maximabestimmung die optimalen Parameter zu finden. Für die vier implementierten Diffusionsfilter haben beide Verfahren zur Bestimmung der optimalen Parameter bezogen auf den jeweiligen Parameter it nahezu gleiche Ergebnisse für den Diffusionsfaktor k innerhalb des vordefinierten Abtastintervalls geliefert. Bei verschiedenen Rauschintensitäten und unterschiedlicher Anzahl von verarbeiteten Schichten konnte damit die Robustheit und Leistungsfähigkeit des automatischen Verfahrens demonstriert werden. Ein Minimum von fünf iterativen Untersuchungen zur Bestimmung des optimalen k Parameters wurde für jede Bildvorverarbeitung für das automatische Verfahren vorgesehen, um Ausreißer oder fehlerhafte Untersuchungen aufgrund der Komplexität der realen Datensätze zu vermeiden. Nach dem fünften Durchgang werden die bestimmten optimalen k -Werte entweder durch die Anwendung einer Median Berechnung oder durch eine Mittelung der Ergebnisbilder und der Messung der Abweichung aller Bilder zu dieser Referenz analysiert, um eine optimale Parameterkombination für die gesamte Verarbeitung zu bestimmen.

Die Testreihe, die die Empfindlichkeit des automatischen Verfahrens gegenüber Änderungen der internen fest definierten Parameter überprüfen soll, zeigt geringe Abweichungen der Fehlerwerte und Qualitätsmerkmale. Die Rauschintensität stellt auch in dieser Testreihe den größten Einflussfaktor dar. Das Verhältnis zwischen den Filterergebnissen der Diffusionsfilter und der anderen Filter ist in diesen Experimenten ebenfalls erkennbar.

Wird die Anzahl der Iterationen der Gradientenregularisierung geändert, indem sie vergrößert wird, zeigen die Ergebnisse nur kleine Variationen, im Vergleich zu den schlechteren Ergebnissen anderer nichtlinearer Filter (Median und KNN). Ein ähnliches Ergebnis zeigen die Werte der Änderung des lokalen Varianzoperators Fenstergröße. Hier sind die Werte der Standardabweichung vergleichbar klein wie in den vorherigen Untersuchungen.

Deutliche Tendenzen zeigen sich dagegen bei der Analyse des Einflusses der betrachteten Nachbarschaften. Wird die Anzahl an Nachbarn gesenkt, so liefern beide Standard Diffusionsfilter (PMAD2 und Weickert2m) bessere Ergebnisse, wohingegen die Bias Diffusionsfilter (PMAD2_b und Weickert2m_b) eine Steigerung der Nachbarschaftspunkte bevorzugt. Wie zuvor beschrieben (Kapitel 3), tendieren die Standardfilter zu stärkeren Intensitätsdiffusionen, die zur Unterdrückung kleinerer Details und Glättung schwacher Kanten führen. Infolgedessen hilft eine eingeschränkte Anzahl an Nachbar dieses Phänomen zu kontrollieren. Die Bias Filter stellen eine gedämpfte Version der Standardfilter dar und erreichen demnach keine großen Änderungen für eine geringe Anzahl an Nachbarn. Ein wesentlicher Faktor bei der Betrachtung des Einflusses der Nachbarschaft ist hierbei die Rechenzeit des Systems. Es ist nur schwer möglich, absolute Rechenzeiten anzugeben, da diese nicht nur von der Anzahl an Pixel/Voxel eines Datensatzes, der Anzahl der untersuchten Schichten während der Optimierung und der gewählten Nachbarschaft, sondern auch von der Auswahl der Diffusionsfunktion bzw. der Intensitätsverteilung des Datensatzes abhängt.

Die Untersuchung von simulierten multispektralen Daten zeigte den Vorteil der Ausnutzung der multispektralen Information gegenüber der einzelnen Verarbeitung der Datensätze. In den drei analysierten Fällen wurde eine deutliche Verbesserung der Ergebnisse gezeigt, insbesondere für die T1- und T2-gewichteten Bilder. Eine wichtige Voraussetzung für die Verarbeitung multispektraler Daten ist eine genaue Registrierung aller beteiligten Datensätze. Stimmen diese Datensätze nicht eindeutig überein, werden Regionen aufgrund falsch detektierter Kanten nicht ausreichend gut geglättet. Diese Fehler sind dann direkt auf den Registrierungsfehler zurückzuführen.

Die durchgeführte Untersuchung der realen Daten zeigte, dass ähnliche Resultate wie bei synthetischen Datensätzen auch unter nicht kontrollierten Bedingungen mit dem automatischen Verfahren erreicht werden konnten. Eine quantitative Untersuchung anhand von Gütekriterien und Qualitätsmerkmalen konnte aufgrund des Mangels an geeigneten Referenzen nicht durchgeführt werden. Trotzdem zeigt die Übereinstimmung der automatisch ermittelten Parameter mit den auf den Maximalwerten der abgetasteten Evaluierungskurve berechneten Parametern die Gültigkeit der beschriebenen Ergebnisse. Die Untersuchung beider synthetischer und realer Datensätze mit dem automatischen

Verfahren bestätigt, dass dieses die Qualität der verarbeiteten Daten verbessert und eine optimale Parametrierung bezüglich der vorgeschlagenen Evaluierungskriterien findet.

Wird das Verfahren und die Evaluationsmethode im Detail kritisch betrachtet, so lassen sich einige Aspekte bezüglich der Methodik des Verfahrens und der Implementierung finden, die im Rahmen dieser Arbeit aufgrund des Umfangs nicht umgesetzt wurden, jedoch an dieser Stelle erwähnt werden sollten.

In den Fällen, wo der Gradientenbetrag des Rauschens vergleichbar mit dem von einigen anatomischen Strukturen ist, wird die anisotrope Diffusion entweder das Rauschen dieser Stärke nicht unterdrücken oder die Kanten der anatomischen Strukturen nicht erhalten. Daher wurde ein Regularisierungsfiler in Form eines diskreten Gaußfilters eingesetzt, um durch die Glättung des Gradientenbildes ausschließlich die Unterdrückung des Rauschens zu ermöglichen [91]. Die Auswirkung der Änderung der Glättungsstärke dieses Filters durch Variation der Anzahl der Iterationen wurde in Abschn. 5.3.4 untersucht und als „eingeschränkt“ eingestuft. Daher ist es denkbar, die Gaußfilter durch eine kanten-erhaltende Filterung, wie z.B. Median- oder KNN-Filter, zu ersetzen und so die Genauigkeit des Verfahrens zu verbessern. Eine Steigerung der Rechenzeit sollte dabei in Kauf genommen und in der Implementierung der Methode berücksichtigt werden.

Die Diffusionsfilter können das sogenannte „Salz und Pfeffer“ bzw. Impulsrauschen nicht ausreichend glätten, diese Rauschartefakte treten normalerweise nicht in MRT-Bilddaten, aber in anderen Modalitäten, wie z.B. in Ultraschallbildern auf. Eine Anwendung nacheinander manuell parametrierter Diffusions- und Medianfilter zur Glättung von durch molekulare Bildgebungsverfahren generierte Bilder wurde bereits durch Ling [110] gezeigt. Bei der Implementierung dieser Regularisierungsfiler, wäre das automatische Rauschunterdrückungsverfahren besser auf andere Modalitäten anwendbar.

Eine weitere Verbesserung wäre die Betrachtung von zusätzlichen Informationen während der Filterung, wie eine Lokalisation unterschiedlicher homogener oder texturierter Regionen innerhalb des Bildes. Diese Information könnte zur lokalen Adaptierung des Diffusionsfaktors führen. Eine voll-ständige Unterdrückung des Rauschens könnte auf diese Weise erreicht werden, die auch für die Unterdrückung einiger Bildartefakte in MRT-Bildern interessant sein könnte. In der derzeitigen Implementierung werden keine Artefakte gezielt geglättet, geglättet wird nur das homogen verteilte Rauschen.

Zusätzlich ist die Anpassung des Wertes der Diffusionskonstante im Verlaufe der Filteriterationen [96] sinnvoll. Das aktuelle Verfahren führt keine zusätzliche Anpassung des Diffusionsfaktors außerhalb der globalen Festlegung dieses Wertes durch. Es ist jedoch zu untersuchen, ob eine sinnvolle Senkung des Diffusionsfaktors einer linearen oder nicht-linearen Funktion folgt.

Weiterhin bietet die Evaluierungsfunktion ein breites Feld zu Untersuchungen und Analysen an, da die implementierte Evaluierungsfunktion hauptsächlich durch experimentelle Erfahrung aufgebaut wurde. Obwohl alle Faktoren der Evaluierungsfunktion bekannten Maßstäben, wie Höhe, Breite (FWHM), usw. aus den Bereichen der Physik und Signalübertragung entsprechen, folgt der Aufbau keinen grundlegenden oder speziellen Theorien, sondern mehr einer logischen Kombination von Faktoren, die in einem idealen Fall (homogene räumliche Verteilung des Rauschens mit gleichem Betrag) zu einem maximalen Wert führen sollte. In diesem Kontext könnte die Evaluierungsfunktion durch eine andere Funktion ersetzt werden oder durch die Anwendung von Referenzmodellen zum gesuchten Idealergebnis führen, was den Rahmen dieser Arbeit sprengen würde. In diesem Fall könnten durchaus noch bessere Ergebnisse erzielt werden. Des weiteren könnte das Evaluierungsmodul durch zusätzliche Information, wie z.B. durch die Betrachtung der spektralen Information des Differenz- oder Varianzbildes anhand der Fourier- oder Waveletanalyse, verbessert werden.

Die Anwendung von statistischen Messgrößen hat sich als ausreichende Möglichkeit gezeigt, um eine objektive Evaluierung der Leistung des Verfahrens zu erlangen. Normalerweise spiegeln solche Messgrößen die spezifischen Eigenschaften zwischen den Daten und Referenzen wieder. Aus diesem Grund wird empfohlen mehrere dieser Indikatoren anzuwenden, um ein vollständiges Bild des Verhaltens zu erhalten. Allerdings verlieren dieselben Indikatoren an Bedeutung, wenn keine Referenzen oder „Gold Standards“ zu Verfügung stehen (wie z. B. bei realen Bilddaten). In diesen Fällen könnte die Meinung von Experten hinzugezogen werden, um die Ergebnisse der verschiedenen Verfahren anhand ihrer Erfahrung zu beurteilen. Die derzeitig implementierte Version des automatischen Verfahrens wurde mit realen Bilddaten getestet und erste Ergebnisse dieser Daten werden im folgenden Kapitel vorgestellt und diskutiert.

6 Evaluation der Methode anhand realer Bilddaten von Patienten und Kleintieren

In diesem Kapitel werden verschiedene Beispiele vorgestellt, die die Leistungsfähigkeit des automatischen Rauschunterdrückungsverfahrens in der Verarbeitung realer Patientendaten demonstrieren soll. Die Vielfältigkeit der hier präsentierten Beispiele zeigen eine Auswahl der Datensätze, die von verschiedenen Instituten in der Charité Berlin, des Forschungszentrums Jülich und anderen Kooperationspartnern zur Verfügung gestellt wurden.

6.1 Filterung und Auswertung realer MRT-Patientenbilddaten

Dr. Titus Hoffmann von der Klinik für Strahlenheilkunde Charité Campus Virchow-Klinikum hat exemplarische MRT-Bilddatensätze für die Verarbeitung anhand des automatischen Verfahrens zur Verfügung gestellt. Fünfzehn Datensätze von insgesamt 10 Patienten (7 weiblich und 3 männlich im Alter zwischen 2 und 75 Jahren) wurden untersucht, die sich wie folgt aufteilen:

- 5 Patientendaten mit kontrastmittelverstärkter T1-gewichteter 3D-Gradientecho-Sequenz („3D FFE“).

Name	TR	TE	α	Schichtdicke	Aufnahmematrix	Field of view
GM-MPR	11.0965	5.0103	40	1.0 mm	512x512x130	259.43 mm
HJ-MPR	11.0965	5.0103	40	1.0 mm	512x512x130	259.43 mm
IA-MPR	12.2469	5.6025	40	1.0 mm	512x512x140	229.43 mm
LA-MPR	11.9129	5.4915	40	1.0 mm	512x512x160	229.43 mm
SW-MPR	11.0965	5.0103	40	1.0 mm	512x512x130	259.43 mm

In diesen Datensätzen sind Tumore und verschiedene Läsionen zu sehen. Sie wurden zur Planung neurochirurgischer Eingriffe aufgenommen.

- 5 Patientendaten mit TSE Doppelecho-Sequenz (jeweils Protodichte (PD) und T2-gewichtete Aufnahmen, „PD/T2 Dual Echo TSE“)

Name	TR	TE	α	Schichtdicke	Aufnahmematrix	Field of view
JN-T2PD	2460	13.3120	90	3.0 mm	256x256x44	250.11 mm
OW-T2PD	2460	13.2959	90	3.0 mm	256x256x44	250.11 mm
RS-T2	2460	13.3280	90	3.0 mm	256x256x44	250.11 mm
SB-T2PD	2460	13.3120	90	3.0 mm	256x256x44	250.11 mm
SM-T2	2460	13.3280	90	3.0 mm	256x256x44	250.11 mm

Die TSE Doppelecho-Sequenz Datensätze wurden von Patienten mit gesicherter Enzephalomyelitis disseminata aufgenommen. In beiden, T2- und PD-gewichteten Datensätzen, sind entsprechende Läsionen deutlich zu erkennen.

Alle Datensätze wurden mit den in Kapitel 3 untersuchten Diffusionsfiltern (PMAD2 , PMAD2_b, Weickert2m, Weickert2m_b) automatisch verarbeitet. Einige dieser Ergebnisse sind in den folgenden Bildern dargestellt. Bild 6.1 zeigt die Ergebnisse für zwei Tumor-Datensätze (IA-MPR und LA-MPR).




Bild 6.1: Transversale Schnittbilder zweier T1- gewichteter 3D-MPR Datensätze realer Tumorenpatienten; a) und c) originale Datensätze; b) und d) Ergebnisse der Perona-Malik Filter (PMAD2).

In beiden Datensätzen sind die Tumore im Originalbild deutlich zu erkennen. In den verarbeiteten Datensätzen sind die homogenen Regionen glatter, während die anatomischen Strukturen gut erhalten blieben. Bild 6.2 zeigt exemplarisch die Ergebnisse für einen T₂- und PD-gewichteten Datensatz. In beiden Fällen sind sowohl im Original als auch im verarbeiteten Datensatz die Läsionen deutlich zu erkennen.




Bild 6.2: a) T_2 -gewichtetes Schnittbild eines Enzephalomyelitis-Patient; b) das Ergebnis des PMAD2 Diffusionsfilters; c) PD-gewichtetes Schnittbild eines weiteren Enzephalomyelitis-Patient; d) das entsprechende Ergebnis des PMAD2 Diffusionsfilters.

6.1.1 Auswertung

Die 3D FFE Datensätze wurden zur Planung neurochirurgischer Eingriffe aufgenommen, weshalb die Art der dokumentierten Läsionen naturgemäß relativ uneinheitlich ist und vom Hauptbefund eines Tumors bis zu Nebenfunden vaskulärer Läsionen reicht. Kontinuierlich reproduzierbare kleine Strukturen wie die Hirnnerven V, VII und VIII wurden auf Identifizierbarkeit überprüft. Untersucht wurde die Nachweisbarkeit der jeweiligen Struktur bzw. Läsion, nicht bewertet wurden subjektive Eindrücke zur Bildqualität. Verglichen wurde das gesamte Neurokranium welches, durch die 15 MRT-Bilddatensätze abgedeckt wurde. Die Bewertung erfolgte unabhängig durch zwei Radiologen der Klinik für Strahlenheilkunde Charité Campus Virchow-Klinikum im Konsens.

Die Tabelle zeigt die „Trefferate“ hinsichtlich zerebraler Läsionen und Strukturen:

Beschreibung	Original	P2	P2_b	W2	W2_b
Raumfordernde bzw. neoplastische Läsionen, supratentoriell	6	6	6	6	6
Vaskuläre Läsionen	3	3	3	3	3
Gefäßanomalien (DVA)	2	2	2	2	2
Hirnnervendifferenzierung im Subarachnoidal-raum, jeweils bilaterale Analyse: N. trigeminus	10	10	10	10	10
N. facialis	7	7	7	7	7
N. vestibulocochlearis	10	10	10	10	10

Für die PD/T2 Dual Echo TSE Datensätze des Enzephalomyelitis disseminata Patienten wurde die Abgrenzbarkeit der supra- und infratentoriellen Entmarkungsherde anhand der identifizierten Läsionen bewertet.

Beschreibung	Original	P2	P2_b	W2	W2_b
PD-w	72	74	72	72	73
T2-w	58	60	57	57	58

Insgesamt zeigten sich bei der vergleichenden Beurteilung von klinischen Patienten-Bilddaten keine Unterschiede bei Zugrundelegung einer T1-gewichteten 3D-Gradientecho-sequenz und marginale Unterschiede bei der Bewertung T2- und Protonendichte-gewichteter Aufnahmen mit einer Tendenz zur verbesserten Läsionsdetektion mittels der zweiten Perona-Malik Diffusionsfilter.

Die gefilterte Version eines qualitativ relativ guten Quellbildes führt in einer visuellen Analyse selten zur Entdeckung neuer Information. Die menschliche Wahrnehmung kann die relevante Information eines Bildes von dem Rest der Informationen sehr effizient trennen. Die Untersuchung scheint diese Aussage zu bestätigen.

Jedoch ist das Hauptziel des automatischen Rauschunterdrückungsverfahrens die Unterstützung automatischer und semiautomatischer digitaler Verarbeitungsverfahren, wie in einem weiteren Beispiel gezeigt werden soll.

6.2 Vorverarbeitung diffusionsgewichteter Bilder zur Hirninfarkt-Segmentierung

Im Institut für Medizinische Informatik an der Charité - Berlin wird unter anderem an der Entwicklung von Segmentierungs- und Charakterisierungsalgorithmen für MRT-Bilder gearbeitet. Untersuchungen mit Diffusionsfiltern wurden schon in der Vergangenheit durchgeführt, um die Qualität der Segmentierung der Hirninfarkte zu verbessern [111]. Klinisches Bildmaterial für ein zur Diagnoseunterstützung eingesetztes automatisches, histogrammbasiertes Segmentierungsverfahren wurde mit Hilfe der Perona-Malik (PMAD2) Diffusionsfilter verarbeitet. Die Einstellung der Filterparameter erfolgte anhand der Auswertung ausgewählter Datensätze, die eine größtmögliche Variation der zu analysierenden Pathologie wiedergaben.

Dr. Jürgen Braun hat für die vorliegende Arbeit drei 3D CT- und 55 2D MRT-Daten mit Hirninfarkten zur Verfügung gestellt, um die Ergebnisse der automatischen Rauschunterdrückung gegenüber dem damals angewendeten automatischen Segmentierungsverfahren zu verifizieren. Die CT-Daten, die drei 8 mm dicke Schichten 512 x 512 Pixel (0.43 x 0.43 mm) beinhalten, wurden mit dem zweiten Perona-Malik Diffusionsfilter 2D verarbeitet. Obwohl dieses hier in der Arbeit vorgestellte Verfahren für MRT-Daten konzipiert wurde, weisen die gewonnenen CT-Ergebnisse eine Unterdrückung des Rauschens innerhalb der Regionen mit Weichteilgewebe auf (Bild 6.3). Der Mangel an Hintergrundrauschen in den CT-Daten hat dank des Evaluationsmoduls keine Auswirkung auf das automatische Verfahren gezeigt, da nur die Bildkomponenten mit Information des Rauschens betrachtet werden (Abschn. 4.2.2).




Bild 6.3: a) Original CT Datensatz; b) Ergebnis der automatischen Verarbeitung (PMAD2); c) Ergebnis der automatischen Verarbeitung (PMAD2) mit doppeltem Diffusionsfaktor

Dr. Braun hat die vorverarbeiteten Daten segmentiert und bewertet. Das Segmentierungsergebnis der automatisch verarbeiteten CT-Daten ergab eine geringe Verbesserung der Resultate. Auf Anfrage von Dr. Braun wurde eine stärkere Glättung durchgeführt, um die kontrastreichen Infarktregionen besser extrahieren zu können. In Bild 6.3 rechts sind die Daten, die mit einem doppelten Diffusionsfaktor-Wert geglättet wurden, dargestellt.

Die 2D MRT-Bilder (256x256), der diffusionsgewichteten (DWI) Datensätze und die Datensätze mit berechnetem apparenten Diffusions-Koeffizient (ADC), wurden ebenfalls automatisch mit der PMAD2 Diffusionsfunktion verarbeitet. Zwei dieser Ergebnisse sind in Bild 6.4 dargestellt. In beiden Fällen wurde eine sichtbare Reduktion des Rauschens erzeugt, während die gesuchten Strukturen gut erhalten blieben. Die qualitative Beurteilung der Ergebnisse war positiv, da nach Meinung von Dr. Braun eine tatsächliche Verbesserung in den Ergebnissen der Segmentierung gefunden wurde.




Bild 6.4: Apparent Diffusions Koeffizient Bilder (b -Faktor=736) zweier unterschiedlicher Hirninfarkte; a) Originalbild ein akut-chronischer Infarkt; b) Ergebnis der automatischen Rauschunterdrückung (PMAD2); c) Originalbild ein kleiner verteilter Infarkt; d) Ergebnis der PMAD2 Diffusionsfilter.

Dieses Beispiel zeigt die Nützlichkeit des automatischen Verfahrens. Einerseits werden die Filterparameter hinsichtlich der Rauschunterdrückung optimiert und die gefilterten Daten ermittelt. Andererseits können die automatisch ermittelten Parameter als Ausgangswerte genutzt werden, wenn die Erwartungen der Benutzer bezüglich der Anwendung nicht 100% erfüllt werden, um die Ergebnisse den Erwartungen anzupassen, wie es bei den CT-Beispieldaten der Fall war.

6.3 Vorverarbeitung von Epilepsie-Datensätzen für die medizinische Visualisierung

Visualisierungstools spielen eine wichtige Rolle in medizinischen Anwendungen. Insbesondere haben Radiologen, die mit den ermittelten Daten von verschiedenen Modalitäten arbeiten, oder Chirurgen, die sich mit der Untersuchung bestimmter Pathologien oder mit der Planung chirurgischer Eingriffe beschäftigen, hohe Ansprüche an die Visualisierungsalgorithmen. Diese sollten nicht nur einen guten visuellen Eindruck vermitteln, sondern auch eine besonders hohe Genauigkeit besitzen. Rauschunterdrückungsmethoden helfen dabei, diese Genauigkeit und gute Visualisierung zu gewährleisten. Im Rahmen eines Forschungsprojektes des Zentrums für Virtual Reality und Visualisierung Forschungs-GmbH (VRVIS) und der Neurochirurgischen Klinik der Medizinischen Universität Wien wurden einige Datensätze mit Dysplasien von Epilepsiepatienten zur Verfügung gestellt, um anhand der gefilterten Daten (Bild 6.5) neue Ergebnisse mit den am VRVis entwickelten Visualisierungsverfahren zu generieren und diese mit den ungefilterten Ergebnissen zu vergleichen. Basis des Visualisierungsverfahrens ist das sogenannte schattierte direkte Volumenrendering (shaded direct volume rendering). Dieses Verfahren ist extrem sensitiv gegenüber vorhandenem Bildrauschen, da die zum schattieren benötigte Gradienteninformation durch das Rauschen teilweise zerstört

wird und dies zu einer Verschlechterung der generierten Visualisierung führt. Merkmalerhaltende Glättungsalgorithmen ermöglichen eine verbesserte Rekonstruktion der Gradienten und somit auch eine Verbesserung der Visualisierung. Zwei T₁-gewichtete Datensätze (512x512x40 und 256x256x74) wurden mit allen vier Diffusionsfiltern (PMAD2, PMAD2_Bias, Weickert2m und Weickert2m_Bias) verarbeitet.




Bild 6.5: Ergebnisse der Filterung, Original Datensatz (links), automatisch geglätteter Datensatz mit PMAD2 Diffusionsfilter (Mitte), stark geglätteter Datensatz mit PMAD2 und doppeltem Diffusionsfaktor (rechts). Der hellere Bereich in der Bildmitte zeigt die Stelle der Dysplasie.

Nach visueller Beurteilung durch die Visualisierungsexperten bei VRVIS haben die Daten, die mit dem PMAD2 Filter verarbeitet wurden, ein besseres Visualisierungsergebnis erzeugt. Die Dysplasie wurde von allen Filtermethoden recht gut erhalten.




Bild 6.6: Ergebnisse der Visualisierung des Schnittbildes aus Bild 6.5, oben ungefiltert, unten stark gefiltert. Von links nach rechts: unshaded Direct Volume Rendering (DVR), shaded DVR, gradient-magnitude weighted sDVR.

Da der Schwerpunkt auf die bessere und schnellere Erkennung von Dysplasien gelegt wurde, konnten für eine detaillierte Ansicht nur Schichtbilder herangezogen werden, wohingegen das gerenderte 3D Bild einen Überblick über die Anatomie liefert und die schnelle Auffindung der Dysplasien erleichtern soll. Deswegen wurde vom Benutzer der Wunsch geäußert, die Daten nochmals mit den PMAD2 Filter und einer stärkeren Glättung zu verarbeiten (Bild 6.5 rechts). Wie bei den CT-Daten der Hirninfarkte wurde die Stärke der Glättung verdoppelt. Die Ergebnisse der Visualisierung sind in Bild 6.6 dargestellt. Nach den Kommentaren von VRVis haben die Ergebnisse recht gut den Vorstellungen entsprochen, da im Vergleich zum ungefilterten Bild eine erhebliche Verbesserung zu sehen ist.

6.4 Vorverarbeitung der MRT-Daten für die Segmentierung kortikaler und subkortikaler Strukturen

Im Rahmen des Projekts „Erforschung und Entwicklung von Algorithmen zur Generierung, Applikation und Evaluation MRT-basierter individueller dreidimensionaler Hirnatlanten“ werden in der Arbeitsgruppe Multimodale Bildverarbeitung des Zentralinstitutes für Elektronik des Forschungszentrums Jülich verschiedene automatische und semiautomatische Verfahren zur Segmentierung dreidimensionaler Strukturen des Gehirns entwickelt. Eines dieser Verfahren dient zur automatischen Segmentierung und Klassifikation T1-gewichteter Betragsbilddaten zur Gewebedifferenzierung grauer Substanz, weißer Substanz, Liquor, extrazerebralen Gewebes und Hintergrund [19, 20].

Bildrauschen erschwert die exakte Segmentierung der unterschiedlichen Gewebe, was somit zu Identifikations- und Lokalisationsproblemen führen kann. Eine Vorverarbeitung der Daten mit einem gut parametrisierten Rauschunterdrückungsfilter sollte die Grenzen zwischen den zerebralen Strukturen sowie zu ihrer Umgebung möglichst nicht modifizieren, da ansonsten die Ausdehnung kortikaler oder subkortikaler Regionen unter- oder überschätzt werden könnte.

Beispielhaft sind die Filterergebnisse für die Filter PMAD2, PMAD2_b, Weickert2m und Weickert2m_b anhand eines von Dr. Becker aus der Klinik und Poliklinik für Nuklearmedizin, Universität Leipzig (Direktor: Univ.-Prof. Dr. med. O. Sabri), zur Verfügung gestellten Patientendatensatzes ermittelt worden. Dieser Patient hat die Diagnose subkortikale vaskuläre Demenz. Der untersuchte Datensatz, eine stark verrauschte T₁-

gewichtete MRT-Aufnahme (512x512x208), wurde mit allen implementierten anisotropen Diffusionsfiltern verarbeitet. Die Ergebnisse der Filterung wurden anschließend mit der automatischen Segmentierung [19, 20] verarbeitet und gegenüber den Ergebnissen des ursprünglichen Datensatzes visuell verglichen. Bild 6.7 zeigt die Endergebnisse nach der Segmentierung für einen Ausschnitt aus einer transaxialen Schicht, die die Atrophie deutlich zeigt.




Bild 6.7: Ergebnisse des automatisierten Segmentierungsverfahrens. Links (oben und unten): Segmentierungsergebnis auf Basis des Originaldatensatzes. Oben Mitte: Segmentierungsergebnis für das mit dem PMAD2 Filter gefilterte Bild. Oben rechts: Segmentierungsergebnis für das mit dem PMAD2_bias Filter gefilterte Bild. Unten Mitte bzw. rechts: die Segmentierungsergebnisse für die mit den Weickert2m, und Weickert2m Bias Filtern gefilterten Bilder .

Die Segmentierungsergebnisse auf Basis der mit den Filtern PMAD2 und PMAD2_bias vorverarbeiteten Bilddaten zeigen deutlich glattere Strukturen als die Segmentierungsergebnisse auf Basis der ungefilterten Bilddaten, jedoch werden die kortikalen Regionen ausgedehnt, was zur Verfälschung der segmentierten Strukturen und Auslöschung feiner anatomischer Details führt. Die Ergebnisse des Weickert2m Diffusionsfilters sorgen nach der Segmentierung für glattere kortikale und subkortikale Regionen. Dabei sind einige Details ebenfalls verloren gegangen. Dagegen produziert der Weickert2m_bias Filter bessere Segmentierungsergebnisse, da ein akzeptabler Kompromiss zwischen Glättung und Erhaltung der anatomischen Regionen erreicht wurde, der insbesondere bei einer anschließenden quantitativen Bewertung der Atrophie von entscheidender Bedeutung ist.

6.5 Semiautomatische Segmentierung von ROIs/VOIs in Kleintierbilddaten

Die Segmentierung von Tumoren oder anatomischen Strukturen ist eine wichtige Voraussetzung zur quantitativen Analyse multimodaler Datensätze kleiner Tiere. Die Volumenmessung während der Behandlung von Tumoren ist ein wichtiges Werkzeug in der Krebsforschung. Die semiautomatischen Segmentierungsmethoden zeichnen sich aufgrund ihrer Flexibilität bezüglich der zu segmentierenden Regionen und der Qualität der Datensätze und wegen ihrer Genauigkeit und einfachen Bedienung aus. Zwei solcher semiautomatischen Methoden wurden in der multimodalen Bildverarbeitungsgruppe des ZEL im Forschungszentrum Jülich entwickelt [112].

Die erste Methode basiert auf der automatischen Konturfindung mittels dynamischer Programmierung ("Live Wire"-Verfahren), die zweite auf einem aktiven Konturmodell (Snake). Diese Verfahren wurden bezüglich der Segmentierung von ROIs (engl. „Regions of Interest“) / VOIs (engl. „Volumes of Interest“) in Kleintierbilddaten verglichen. Die Daten wurden mit dem automatischen Rauschunterdrückungsverfahren zusätzlich verarbeitet, um gegenüber den Segmentierungsergebnissen ungefilterter Daten Vergleiche zu ermöglichen. Bild 6.8 zeigt ausgewählte Schichten aus den Originaldatensätzen von Ratten (AVCEG, AVCEH, AVCEI) und Mäusen (Wt1rsl, App23wt, Mr288), die von Dr. Jan Sijbers aus den Vision Lab, Department of Physics, University of Antwerp und von Dipl.-Phys. Stefan Vollmer aus dem Max-Planck-Institut für neurologische Forschung, Köln, für das EU geförderte EMIL Projekt zu Verfügung gestellt wurden.




Bild 6.8: Ausgewählte Schichten aus Kleintierbilddaten. Oben: drei Aufnahmen eines Rattengehirns (AVCEG, AVCEH, AVCEI). Unten: zwei Aufnahmen eines Mausgehirns (Wt1rsl, App23wt) und eines Mauskörpers mit 3 Tumoren (Mr288) [112].

Die Datensätze der Ratten bestehen aus sechs Schnittbildern (256x256x6). Die Aufnahme des Mausgehirns (Bild 6.8 unten links) ist ein 256x512x128 isotropisierter hochauflösender MRT-Datensatz. Die anderen Mausdatensätze sind 256x256x80 bzw. 256x256x50 große MRT-Aufnahmen. Alle Daten wurden mit dem Weickert2m Bias Filter (2D Filterung für die Rattenbilddaten (AVCEG_ADF, AVCEH_ADF, AVCEI_ADF) und 3D Filterung für die Mausdaten (Wt1rsl_ADF, App23wt_ADF, Mr288_ADF)) verarbeitet, um eine leichte Glättung zu erzeugen und damit die feinen Details der Gehirnstrukturen zu erhalten. Bild 6.9 zeigt Beispiele der Segmentierung.




Bild 6.9: Beispiele der Ergebnisse (Wt1rsl) mit den zwei semiautomatischen Segmentierungsmethoden. Links: das mit dem Live-Wire-Verfahren generierte Ergebnis; Rechts: das Endpolygon des aktiven Konturmodell [112].

Die Graphiken in Bild 6.10 zeigen die quantitativen Ergebnisse der vergleichenden Untersuchung nach [112].




Bild 6.10: Ergebnisse beider Segmentierungsverfahren: Das Diagramm links zeigt die Anzahl interaktiv gesetzter Punkte für das „Live-Wire“ bzw. das Snake Verfahren. Die Graphik rechts zeigt die Ergebnisse auf Basis des Dice-Koeffizienten für beide Verfahren [112]. Das Suffix _ADF steht für die Datensätze (AVCEG, AVCEH, AVCEI, Wt1rsl, App23wt und Mr288), die geglättet wurden. Mr288a, Mr288b und Mr288c stehen für die jeweiligen 3 Tumoren in Mr288.

Durch die Filterung der Daten konnte die Anzahl der interaktiv gesetzten Punkte reduziert werden. Gleichzeitig wurde die Ähnlichkeit des Segmentierungsergebnisses erhöht, was der Dice-Koeffizient zeigt (der Wert 1 bedeutet eine Übereinstimmung der Ergebnisse).

6.6 Diskussion

In diesem Kapitel wurde gezeigt, dass das automatische Verfahren in der Lage ist, unterschiedliche medizinische Bilddaten zu verarbeiten. Das Verfahren kann problemlos auf unterschiedliche medizinische Aufgabenstellungen angewandt werden, da es nur die im Bild enthaltenen Informationen nutzt. In Fällen, wo das medizinische Personal die Bilddaten visuell beurteilen soll, hat sich die Vorverarbeitung der Daten selten als Vorteil erwiesen. Dort wird keine zusätzliche Information benötigt, die nicht bereits im Originalbild gefunden wurde. Im besten Fall hat es die Lokalisierung der Läsionen und/oder Strukturen erleichtert (Abschn. 6.1). Nur in einem Fall wurde eine leicht positive Tendenz bezüglich der Ergebnisse der Perona-Malik Filter (PMAD2) festgestellt. Für die anderen Bilddaten wurde keine Verbesserung gefunden. Im Gegensatz dazu zeigen die Ergebnisse eine klare Tendenz zu Gunsten der gefilterten Bilddaten, wenn die automatische Methode als Vorverarbeitungsschritt für ein computergestütztes Verfahren (Segmentierungsverfahren) verwendet wird. Für die eher visuell zu beurteilenden Datensätze wurde die zweite Perona-Malik (PMAD2) Diffusionsfunktion bevorzugt, besonders wenn die zu identifizierenden Strukturen von den umliegenden Regionen deutlich abgrenzbar waren. Dies war der Fall bei den Tumor-, Enzephalomyelitis-, Hirninfarkt und Dysplasie-Datensätzen. In einigen dieser Beispiele wurde eine stärkere Glättung verlangt als das automatische Verfahren geliefert hat. Dank der vorher automatisch ermittelten Parameter als Ausgangspunkt konnte dies ohne weiteres durchgeführt werden. Gegebenfalls kann das Verfahren an spezifische Anwendungen angepasst werden, in denen eine konstante Glättungsstärke verlangt wird, die sich von der automatisch ermittelten immer gleich (z.B. $k_{neu}=2k$), unterscheidet. Solche Parameteranpassungen können problemlos in das Verfahren integriert werden.

In Fällen, in denen eine genaue Erhaltung der feinen anatomischen Details und der Intensitätsverläufe zwischen den Bildregionen benötigt wird, ist der Bias Weickert $m=2$ Filter zu empfehlen. Dies war z.B. der Fall bei der automatischen Segmentierung von MRT-Bilddaten des menschlichen Gehirns in Gewebeklassen sowie bei den Ratten- und Mausdatensätzen. In beiden Beispielen wurden mit dem Weickert_2m Bias Filter sehr gute Ergebnisse erzielt. Die Segmentierung der ROIs/VOIs auf Basis der Kleintierbilddaten konnte zudem schneller und genauer durchgeführt werden als in den ungefilterten Bilddatensätzen. Es ist durchaus denkbar, das Verfahren auch für andere Bildmodalitäten zu adaptieren, wie die Verarbeitung der CT-Daten gezeigt hat.

7 Zusammenfassung und Ausblick

In dieser Dissertation wurde eine Rauschunterdrückungsmethode für MRT-Bilddaten präsentiert, welche vollautomatisch die Parameter des Rauschunterdrückungsfilters optimiert. Diese Methode verwendet anisotrope Diffusionsfilter, die für die Verarbeitung von medizinischen Bilddaten aufgrund ihrer Rauschunterdrückungs- und Kanten-erhaltungseigenschaften geeignet sind. Die Filter reduzieren das Rauschen effektiv und erhalten gleichzeitig die anatomischen Strukturen.

Eine Besonderheit des Verfahrens ist die Integration der Filterungsalgorithmen innerhalb eines geschlossenen Regelkreises, welcher anhand einer neuartigen Evaluierungsmethode die Filterparameter anpasst. Diese Evaluierungsmethode überprüft die Bildverbesserung durch den impliziten Vergleich der Eigenschaften des bereits unterdrückten Rauschens mit den typischen Eigenschaften des Rauschens des bildgebenden Verfahrens. Ergebnis dieses Verfahrens ist ein Rückkopplungsindex, der zusammen mit den zuletzt ermittelten Filterparametern angewendet wird, um die nächste Filterparameterkombination zu definieren. Die Justierungsregeln des Verfahrens versuchen den Wert dieses Rückkopplungsindex anhand von Änderungen in der Parametrierung zu maximieren, was folglich zu einer Optimierung der Bildergebnisse führt.

Die hier präsentierte Methode findet für jeden einzelnen Datensatz eine individuelle Parameterkonfiguration und damit ein Optimum im Sinne der Übereinstimmung der Eigenschaften des bereits unterdrückten Rauschens des Original-Datensatzes und des angenommenen Rauschens des bilderzeugenden Verfahrens.

Um die Leistung des Verfahrens zu überprüfen, wurden Testdaten mit unterschiedlichen Rauschintensitäten erzeugt und mit den verschiedenen Diffusionsfiltern des automatischen Verfahrens verarbeitet. Dieselben Testdaten wurden mit anderen bekannten nichtlinearen Filtern verarbeitet und ihre Ergebnisse mit den Resultaten des automatischen Verfahrens anhand häufig angewendeter Fehler- und Qualitätsmaße verglichen.

Anhand der Testdaten wurden verschiedene Untersuchungen durchgeführt, mit dem Ziel die Korrektheit und Robustheit des Verfahrens zu überprüfen. Zuerst wurde die Übereinstimmung der automatisch ermittelten Parameter mit den Maximalwerten der

Evaluierungskurven überprüft. Hierzu wurden die Kurven für die verschiedenen Diffusionsfilter und für verschiedene Rauschintensitäten berechnet und mit den entsprechenden automatisch gewonnenen Parametern verglichen. Die Übereinstimmung der Parameter wurde für alle Diffusionsfilter mit verschiedenen Anzahlen gleichzeitig untersuchter Schichten überprüft und gezeigt. Ähnliche Tests wurden später anhand realer Daten durchgeführt und erzielten vergleichbare Ergebnisse. Durch Änderungen der vorgegebenen nicht zu optimierenden Parameter des Verfahrens wurden Untersuchungen hinsichtlich der Robustheit der ermittelten Ergebnisse hinsichtlich dieser Parameter durchgeführt. Die Glättungsstärke der Gradientenregularisierung, die Fenstergröße des lokalen Varianzoperators und die Filterungsnachbarschaft bildeten die untersuchten Parameter. In Untersuchungen bezüglich der Glättungsstärke und der Fenstergröße des Varianzoperators konnten sehr kleine Abweichungen nachgewiesen werden, die besonders im Vergleich mit den davon stärker abweichenden Ergebnissen der anderen Glättungsfilter (Median, KNN) keinen bedeutsamen Einfluss auf das Endergebnis zeigen.

Bei Untersuchungen einer multispektralen Verarbeitung anhand T1-, T2- und PD-gewichteter synthetischer Daten zeigen die Ergebnisse deutlich die Vorteile dieser Vorgehensweise gegenüber der separaten Verarbeitung.

Die im letzten Kapitel präsentierten Beispiele zeigen die Fähigkeit des Verfahrens unterschiedliche Bilddaten unabhängig von Patienten, Fragestellung, Spektrum und sogar für eine andere Modalität (CT) verarbeiten zu können. In den Beispielen, in denen die erzielten Ergebnisse nicht den Erwartungen des Benutzers entsprachen, wurden zusätzliche Filterungen mit modifizierten Parametern, die anhand der automatisch ermittelten Parameter definiert wurden, durchgeführt.

In Kapitel 6 wurde, aufgrund seiner starken Glättungs- und Rauschunterdrückungseigenschaften, für eine visuelle Beurteilung der Daten meistens der zweite Perona-Malik Diffusionsfilter angewendet. Sollten hingegen kleinere anatomische Details und Intensitätsverläufe bewahrt werden, lieferte der Weickert2m_Bias-Filter die besseren Ergebnisse. Anhand der durchgeführten Untersuchungen und der gesammelten Erfahrung durch die Verarbeitung mehrerer realer Datensätze können für zukünftigen Arbeiten einige Verbesserungen und Erweiterungen für das automatische Verfahren zusammengefasst werden.

In erster Linie ist die Reduktion der Rechenzeit anhand Software- oder Hardwareimplementierungen zu empfehlen. Die parallele Berechnung der Diffusionsfaktoroptimierungsroutine und/oder der Diffusionsfilterungen könnte eine erhebliche Zeitreduktion bewirken [113]. Dies könnte anhand der Vernetzung mehrerer Rechner in einem Server-Client Schema, anhand der Anwendung von multiplen digitalen Signalprozessoren (DSPs) oder durch programmierbare Logikarrays (FPGAs) realisiert werden. Ein Nachteil dieser Lösungsvorschläge ist die Reduktion der Portabilität und Einfachheit des Verfahrens, welches in seiner jetzigen Form auf einem Standardrechner mit normalen Hardware- und Softwarekomponenten arbeitet.

Bezüglich der Methodik könnten Aspekte der Diffusionsfilterung und der Evaluationsmethoden verbessert werden. Dies sind z.B. die Einführung zusätzlicher Änderungen des Diffusionsfaktors in Abhängigkeit von den Homogenitätseigenschaften der anatomischen Strukturen oder die Senkung des Diffusionsfaktors während der iterativen Filterung, wie von Li und Chen [96] vorgeschlagen. Die Evaluationsmethode könnte ebenfalls durch die Einführung neuer Informationen, wie z.B. die relative Änderung bezüglich der zuletzt generierten Ergebnisse, verbessert werden.

Die präsentierte Verarbeitungsstrategie könnte außerdem für andere Bildgebungsverfahren von Nutzen sein. Da die Methodik, die Zwischenergebnisse zu kontrollieren, um die Filterparameter zu justieren, leicht auf andere Modellannahmen des Rauschens übertragbar ist, könnten z.B. Ultraschall- oder optische Aufnahmen auf diese Weise profitieren.

Literaturverzeichnis

- 1 Haralick R.M., Sapiro L.G.: *Image Segmentation Techniques*; Comput. Vision, Graphics, Image Processing, 29:100-132, 1985.
- 2 Cline H.E., Lorensen W.E., Kikinis R., Jolesz F.: *Three-dimensional segmentation of MR images of the head using probability and connectivity*; J. Comput.-Assist. Tomogr., 14(6):1037-1045, 1990.
- 3 Collins D.L., Peters T.M., Dai W., Evans A.C.: *Model-based segmentation of individual brain structures from MRI data*; Proc. of SPIE 1808, 10 (1992)
- 4 Bezdek J.C., Hall L.O., Clarke L.P.: *Review of MR image segmentation techniques using pattern recognition*; Med. Phys., 20:1033-1048, 1993.
- 5 Pal, N.R., Pal, S.K.: *A Review on Image Segmentation Techniques*; Pattern Recognition 26:1277-1294, 1993.
- 6 Wells W., Kikinis R., Grimson W., Jolesz F.: *Adaptive segmentation of MRI data*; In Int. Conf. on Comp. Vis., Virtual Reality and Robotics in Medicine, 59-69, 1995.
- 7 Kapur W., Grimson E.L., Kikinis R.: *Segmentation of Brain Tissue from MR Images*; in First International Conference on Computer Vision, Virtual Reality and Robotics in Medicine, 429-433, 1995.
- 8 Clarke L.P., et. al.: *MRI segmentation: Methods and applications*; Magn. Reson. Imag., 13(3):343-368, 1995.
- 9 Kikinis R., et. al.: *A Digital Brain Atlas for Surgical Planning, Model Driven Segmentation and Teaching*; IEEE Transactions on Visualization and Computer Graphics, 2(3):232-241, 1996.
- 10 Atkins M.S., Mackiewicz B.T.: *Fully automatic segmentation of the brain in MRI*; IEEE Trans. Med. Imaging 17(1): 98-107, 1998.
- 11 Kaus M.R., Warfield S.K., Nabavi A., Black P.M., Jolesz F.A., Kikinis R.: *Automated segmentation of MR images of brain tumors*; Radiology, 218(2):586-91, 2001.
- 12 Moon N., Bullitt E., van Leemput K., Gerig G.: *Automatic brain and tumor segmentation*; Lecture Notes In Computer Science (MICCAI 2002) 372 – 379, 2002.
- 13 Braun J., Bernarding J., Koennecke H.C., Wolf K.J., Tolxdorff T.: *Feature-based, automated segmentation of human cerebral infarcts including diffusion-weighted imaging*; Comp. Methods in Biomech. and Biomedical Engineering 5: 411-420, 2002.

- 14 Ehrig K., Braun J., Tolxdorff T.: *Interaktive Segmentierung von Hirninfarkten mittels Snake-Verfahren*; In Workshop Proceedings: H.-P. Meinzer, H. Handels, A. Horsch, T. Tolxdorff (Hrsg.), Bildverarbeitung in der Medizin, Springer-Verlag, 98-102, 2005.
- 15 Mitchell J.R., Karlik S.J., Lee D.H., Fenster A.: *Computer-assisted identification and quantification of multiple sclerosis lesions in MR imaging volumes in the brain*. J Magn Reson Imaging, 4(2):197-208, 1994.
- 16 Zhu Y., Yan H.: *Computerized tumor boundary detection using a Hopfield neural network*; IEEE Trans. on Medical Imaging, 16:55-67, 1997.
- 17 Simon J.H.: *Magnetic resonance imaging of multiple sclerosis lesions-Measuring outcome in treatment trials*; West J. Med., 164:502-509, 1996.
- 18 Bernarding J., Braun J., Hohmann J., Mansmann U., Stapf C., Hoehn-Berlage M., Wolf K.J., Tolxdorff T.: *Histogram-based Characterization of Healthy and Ischemic Brain Tissue using Multiparametric MR Imaging including ADC Maps and Relaxometry*; Magnetic Resonance in Medicine, 43:53-62, 2000.
- 19 Wagenknecht G., Kaiser H.J., Obladen T., Sabri O., Buell U.: *Individual 3D region-of-interest atlas of the human brain: automatic training point extraction for neural network based classification of brain tissue types*; SPIE Electronic Imaging 2000, San Jose, Proc SPIE 3962:150-161, 2000.
- 20 Wagenknecht G.: *Entwicklung eines Verfahrens zur Generierung individueller 3D-"Regions-of-Interest"-Atlanten des menschlichen Gehirns aus MRT-Bilddaten zur quantitativen Analyse koregistrierter funktioneller ECT-Bilddaten*; Reihe: Berichte aus der Informationstechnik. Aachen: Shaker, 2002.
- 21 Wagenknecht G., Kaiser H.J., Buell U., Sabri O.: *MRI-Based Individual 3D Region-of-Interest Atlases of the Human Brain. A New Method for Analyzing Functional Data*; Methods Inf. Med 43(4):383 - 390, 2004.
- 22 Ahlhelm F., Reith W.: *Moderne Diagnostik beim akuten Hirninfarkt*. Nervenarzt, 73: 736-744, 2002.
- 23 Bankman I.N. (Ed.): *Handbook of Medical Imaging*; Academic Press, 2000
- 24 Haacke E.M., Brown R.W., Thompson M.R., Venkatesan R.: *Magnetic resonance imaging: physical principles and sequence design*; Wiley, 1999.
- 25 Gonzales, R.C., Woods, R.E.: *Digital Image Processing (2nd Edition)*. Addison-Wesley, NY, 1993.
- 26 Pratt W.K.: *Digital Image Processing*; 2. Ed., John Wiley & Sons, Inc., 604-605 1991.

- 27 Nodes, T.A., Gallagher, N.C.: *Median filters: some modifications and their properties*; In IEEE Trans. on Acoustics, Speech and Signal Processing, 30(5):739-46, 1982.
- 28 Davis, L.S., Rosenfeld, A.: *Noise cleaning by iterated local averaging*; In IEEE Trans. on Systems, Man and Cybernetics, 8(9):705-10, 1978.
- 29 Perona, P., Malik, J.: *Scale-space and Edge detection using anisotropic diffusion*; IEEE Trans. In Pattern Analysis and Machine Intelligence, 12(7):629-639, 1990.
- 30 Koenderink, J.J.: *The structure of images*; Bio. Cybernetics, 50:363-370, 1984.
- 31 Gerig, G. Kubler, O., Kikinis, R. and Jolesz, F. A.: *Nonlinear anisotropic filtering of MRI data*; IEEE Trans. on Medical Imaging, 11(2):221-232, 1992.
- 32 Black, M., Sapiro, G., Marimont, D. and Heeger, D.: *Robust Anisotropic Diffusion*; IEEE Trans. Image Processing, 7(3):421-432, 1998.
- 33 Charbonnier, P., Blanc-Feraud, L., Aubert, G., and Barlaud, M.: *Two deterministic half-quadratic regularization algorithms for computed imaging*; in Proc. IEEE Intl. Conf. on Image Processing, 2:168-171, 1994.
- 34 Weickert, J.: *Anisotropic Diffusion in Image Processing*; ECMI Series, Teubner Verlag, Stuttgart, Germany, 1998.
- 35 Monteil, J., Beghdadi, A.: *A New Interpretation and Improvement of the Nonlinear Anisotropic Diffusion for Image Enhancement*; IEEE Trans. on PAMI, 21(9):940- 946, 1999.
- 36 Sijbers J., den Dekker A.J., van der Linden A., Verhoye T.M., van Dyck D.; *Adaptive Anisotropic Noise Filtering for Magnitude MR Data*, Magnetic Resonance Imaging, 17(10):1533-1539, 1999.
- 37 Kacur J., Mikula K.; *Slowed anisotropic diffusion, in Scale-Space Theory in Computer Vision*, Lecture Notes in Computer Science 1252:357-360, 1997.
- 38 Sarti A., Ortiz C., Locket S., Malladi R.: *A unified geometric model for 3D confocal image analysis in cytology*; IEEE Transactions on Biomedical Engineering, 47(12): 1600-1610, 2000.
- 39 Bloch, F., Hansen, W., Packard, M.: *Nuclear induction*; Phys. Rev., 70:460-474, 1946.
- 40 Purcell, E.M., Torrey, H.C., Pound, R.V.: *Resonance absorption by nuclear magnetic moments in a solid*; Physical Review, 69, 1946.
- 41 Lauterbur, P.C.: *Image formation by induced local interactions: examples of employing nuclear magnetic resonance*; Nature, 242:190-191, 1973.

- 42 Mansfield, P.: *Multi-planar image formation using NMR spin echoes*; J Phys C: Solid State Phys, 10:55-58, 1977.
- 43 Damadian R., Goldsmith M., Minkoff L.: *NMR in cancer: XVI. FONAR image of the live human body*; Physiol Chem Phys., 9(1):97-100, 1977.
- 44 OnVista Media, Gesundheitsportal Onmeda: *Magnetresonanztomographie (MRT)*; Köln (Accessed 18.03.2006 at <http://www.onmeda.de/arztbesuch/untersuchung/magnetresonanztomographie.html>).
- 45 Morneburg H. (Hrsg.): *Bildgebende Systeme für die medizinische Diagnostik*; Erlangen, Siemens Publicis MCD Verlag, 1995.
- 46 Philips: *Prinzipien der MR Tomographie*; Medical Systems, Eindhoven, 1988.
- 47 Reiser M., Semmler W., eds.: *Magnetresonanztomographie*; 2. Auflage, Berlin Heidelberg New York: Springer, 1997.
- 48 Vlaardingerbroek M.T., Boer J.A.: *Magnetic Resonance Imaging*; 2. Ed. Springer, 1999.
- 49 Weishaupt D, Köchli V, Marincek B: *Wie funktioniert MRI?*; Springer-Verlag, Heidelberg 4. Auflage, 2003.
- 50 Bottomley, P.A., Foster, T.H., Argersinger, R.E., Pfeifer, L.M.: *A review of normal tissue hydrogen NMR relaxation times and relaxation mechanisms: dependence on tissue type, NMR frequency, temperature, species, excision, and age*; Med Phys, 11: 425-448, 1984.
- 51 Brix, G., Schad, L.R., Lorenz, W.J.: *Evaluation of the proton density by magnetic resonance imaging: phantom experiments and analysis of multiple component proton transverse relaxation*; Phys. Med. Biol., 35(1):53-66, 1990.
- 52 Stejskal E.O., Tanner J.E.: *Spin diffusion measurements: spin echoes in the presence of a time-dependent field gradient*; J. Chem. Phys., 242:288-292, 1965.
- 53 Le Bihan D., Breton E., Lallemand D., Grenier P., Cabanis E.A., Laval-Jeantet M.: *MR imaging of intravoxel incoherent motions: application to diffusion and perfusion in neurologic disorders*; Radiology, 161:401-407, 1986.
- 54 Le Bihan D., Breton E., Lallemand D., Aubin M.-L., Vignaud J., and Laval-Jeantet M.: *Separation of Diffusion and Perfusion in Intravoxel Incoherent Motion MR Imaging*; Radiology, 168:497-505, 1988.
- 55 Cercignani M, Horsfield M.: *The physical basis of diffusion-weighted MRI*; J. Neurol Sci., 186:11-14, 2001.

- 56 Hoult DI., Richards R.E.: *The signal-to-noise ratio of the nuclear magnetic resonance experiment*; Journal of Magnetic Resonance, 24:71–85, 1976
- 57 McVeigh E.R., Henkelman R.M., Bronskill M.J.: *Noise and filtration in magnetic resonance imaging*; Med Phys, 12(5):586-591, 1985.
- 58 Li S., Collins C.M., Dardzinski B.J., Chin C.L., Smith M.B.: *A method to create an optimum current distribution and homogeneous B1 field for elliptical birdcage coils*; Magn Reson Med., 37(4):600-8, 1997.
- 59 Parker D.L., Gullberg G.T.: *Signal-to-noise efficiency in magnetic resonance imaging*; Medical Physics, 17(2):250-257, 1990.
- 60 Johnson J.B.: *Thermal Agitation of Electricity in Conductor*; Physical Review, 32:97-109, 1928.
- 61 Hoult, D.I., Lauterbur, P.C.: *The Sensitivity of the Zeugmatographic Experiment Involving Human Samples*; Journal of Magnetic Resonance, 34:425-433, 1979.
- 62 Libove JM and Singer JR: Resolution and signal-to-noise relationships in NMR imaging in the human body Journal of Physics E Sci. Instrum., 13:38-44, 1980.
- 63 Henkelman, R.M.: *Measurement of signal intensities in the presence of noise in MR images*; Med. Phys. 12 (2):232-233, 1985.
- 64 Gudbjartsson, H., Patz, S.: *The Rician distribution of noisy MRI data*; Magnetic Resonance in Medicine, 34:910-914, 1995.
- 65 Edelstein W.A., Bottomley P.A., Hart H.R., Smith L.S.: *Signal, noise, and contrast in NMR imaging*; J. Comp. Assist. Tomogr. vol. 7(3):391-401, 1983.
- 66 Edelstein W.A., Bottomley, P.A., Pfeifer, L.M.: *A signal-to-noise calibration procedure for NMR imaging systems*; Medical Physics, 11(2):180-185, 1984.
- 67 J. Sijbers: *Signal and noise estimation from Magnetic Resonance Images*; Universit t Antwerpen PhD thesis, defended on May 18, 1998
- 68 Lehmann, T., Oberschelp, W., Pelikan, E., Repges, R.: *Bildverarbeitung f r die Medizin*; Springer Verlag, Berlin, 1997.
- 69 Kalman, R.E.; *A new approach to linear filtering and prediction problems*; Transactions of ASME, Journal of basic engineering, 35-45, 1960.
- 70 Butz, A.R.: *A class of rank order smoothers*; In IEEE Transactions on Acoustics, Speech and Signal Processing, 34(1):157-65, 1986.

- 71 Lee, Y.H., Kassam, S.A.: *Generalized median filtering and related nonlinear filtering techniques*; In IEEE Trans. on Acoust., Speech and Signal Proc., 33(3):672-83, 1985.
- 72 Harwood, D., Subbarao, M., Hakalahti, H., Davis, L.S.: *A new class of edge-preserving smoothing filters*; In Pattern Recognition Letters, 6(3):155-62, 1987.
- 73 Lee, J.S.: *Digital image smoothing and the sigma filter*; In Computer Vision, Graphics, and Image Processing, 24(2):255-69, 1983.
- 74 Nagao, M., Matsuyama, T.: *Edge preserving smoothing*; In Computer Graphics and Image Processing, 9(4):394-407, 1979.
- 75 Kuwahara, M., et al.: *Processing of RI-angiocardigraphic images*, in Digital Proc. of Biomedical Images, Preston and Onoe Ed., Plenum Press, NY., 187-203, 1976.
- 76 Schulze M.A.: *Biomedical Image Processing with Morphology-Based Nonlinear Filters*; Ph.D. Dissertation, The University of Texas at Austin, 1994.
- 77 Hilt, M., Duzenli, C.: *Image filtering for improved dose resolution in CT polymer gel dosimetry*; Med Phys., 31(1):39-49, 2004.
- 78 Wang, H., Sturm, P., Schmitt, F., Pries, L.: *Improved segmentation of MR brain images including bias field correction based on 3D-CSC*; in Proc. of VISAPP 2006.
- 79 Unser, M., Aldroubi, A.: *A Review of Wavelets in Biomedical Applications*; Proceedings of the IEEE, 84(4):626-638, 1996.
- 80 Wang, J.: *Wavelets and Imaging Informatics: A review of the literature*; Journal of Biomedical Informatics, 34(2):129-141, 2001.
- 81 A. Pizurica, A., Wink, A.M., Vansteenkiste, E., Philips, W., Roerdink J.: *A review of wavelet denoising in MRI and ultrasound brain imaging*; Current Medical Imaging Reviews, 2(2):247-260, 2006.
- 82 Nowak, R.D.: *Wavelet based Rician noise removal for magnetic resonance images*; IEEE Trans Image Processing, 10:1408-1419, 1999.
- 83 Bao, P., Zhang, L.: *Noise reduction for magnetic resonance images via adaptive multiscale products thresholding*; IEEE Trans. Med. Imaging, 22(9):1089-1099, 2003.
- 84 Malladi, R., Sethian, J.A.: *Level Set Methods for Curvature Flow, Image Enhancement, and Shape Recovery in Medical Images*; Proc. of Conf. on Visualization and Mathematics, Springer Verlag, Heidelberg, 329-345, 1997.
- 85 Keeling, S.L.: *Total variation based convex filters for medical imaging*. In Applied Mathematics and Computation, 139(1):101-19, 2003.

-
- 86 Witkin, A.P.: *Scale-space filtering*; Int. Joint. Conf. Artificial Int., 1019-1021, 1983.
 - 87 Coulon O., Alexander D., Arridge S.: *Diffusion tensor magnetic resonance image regularization*; Med Image Analysis, 8(1):47-67, 2004.
 - 88 Lee J.E.; Chung, M.K.; Alexander, A.L.; *Evaluation of anisotropic filters for diffusion tensor imaging*; Biomedical Imaging: Macro to Nano, IEEE: 77-78, 2006.
 - 89 Suri, J.S., Wu, D.: *A Comparison of State-of-the-Art Diffusion Imaging Technologies for Smoothing Medical/Non-Medical Image Data*; Pat. Rec. Proc., 1:508-511. 2002.
 - 90 Nordström, N.: *Biased anisotropic diffusion - a unified regularization and diffusion approach to edge detection*; Image and Vision Computing, 8:318-327, 1990.
 - 91 Nitzberg, M., Shiota, T.: *Nonlinear image filtering with edge and corner enhancement*; IEEE Trans. Pat. Anal. and Mach. Intell., 14(8):826-833, 1992.
 - 92 Whitaker, R.T., Pizer, S.M.: *A multi-scale approach to non uniform diffusion*; CVGIP: Image Understanding, 57(1):99-110, 1993.
 - 93 Canny, J.: *A Computational Approach to Edge Detection*; IEEE Trans. Pattern Analysis and Machine Intelligence, 8(6):679-698, 1986.
 - 94 Wang, H., Suter, D.: *Robust Scale Estimation from True Parameters of Model*; Dept. of Elect. and Comp. Eng. Monash Uni. Tech. Report MECSE-2-2003.
 - 95 Black, M.J., Sapiro, G.: *Edges as outliers: Anisotropic smoothing using local image statistics*; Scale-Space Theories in Computer Vision, Second Int. Conf., Scale-Space '99, Corfu, Greece, LNCS 1682, Springer, 259-270, 1999.
 - 96 Li, X., Chen, T.: *Nonlinear Diffusion with Multiple Edginess Thresholds*; Pattern Recognition, 27(8):1029-1037, 1994.
 - 97 Weeratunga, S.K., Kamath, C.: *PDE-based non-linear diffusion technologies for denoising scientific and industrial images: An empirical study*; Proc., Image Processing: Algorithms and Systems, SPIE Electronic Imaging, 279-290, 2002.
 - 98 Kingsbury, N.G.: *Design of Q-shift complex wavelets for image processing using frequency domain energy minimization*; ICIP, (1):1013-1016, 2003.
 - 99 Vese L.A., Osher S.J.: *Image Denoising and Decomposition with Total Variation Minimization and Oscillatory Functions*; Journal of Math. Imag. and Vision, 20 (1-2): 7-18, 2004.
 - 100 Shepp L.A., Logan B. F.: *The Fourier reconstruction of a head section*; IEEE Trans. Nucl. Sci., (21):21-43, 1974.

- 101 Cocosco C.A., Kollokian V., Kwan R.K.-S., Evans A.C.: *BrainWeb: Online Interface to a 3D MRI Simulated Brain Database*; Proceedings of 3-rd International Conference on Functional Mapping of the Human Brain, NeuroImage, 5(4):425, 1997.
- 102 Collins D.L., Zijdenbos A.P., Kollokian V., Sled J.G., Kabani N.J., Holmes C.J., Evans A.C.: *Design and Construction of a Realistic Digital Brain Phantom*; In IEEE Transactions on Medical Imaging, 17:463-468, 1998.
- 103 Haykin S.: *Adaptive Filter Theory*; Prentice Hall, 3. Ed. 1996.
- 104 Jaynes C.O.: *Seeing is Believing: Computer Vision and Artificial Intelligence*; Crossroads, Association for Comp. Mach. (ACM) Student Magazine/ Artificial Int. (Accessed 25.02.2005 at <http://www.acm.org/crossroads/xrds3-1/vision.html>).
- 105 Beauchemin M., Fung K.B., Geng X.: *A method based on local variance for quality assessment of multiresolution image fusion*; In Proc. IAPRS, 34(B-32):32-35, 2002.
- 106 Saffor A., Ramli R., Kwan N.G.: *A Comparative Study of Image Compression Between JPEG and Wavelet*; Malaysian J. of Comp. Sci., 14(1):39-45, 2001.
- 107 Aguirre A., Cabrera S.D., Lucero A.: *Compression of Three-Dimensional Medical Image Data based on JPEG 2000*; Proceedings of the 17th IEEE Symposium on Computer-Based Medical Systems (CBMS'04), 116-121, 2004.
- 108 Samet A., Ayed M.A.B, Masmoudi N., Khriji L.: *New Perceptual Image Quality Assessment Metric*; Asian Journal of Information Technology 4(11):996-1000, 2005.
- 109 Wang Z., Bovik A.C.: *A Universal Image Quality Index*; IEEE Signal Processing Letters, 9(3):81-84, 2002.
- 110 Ling, J., and Bovik, A. C.: *Smoothing low SNR molecular images via anisotropic median-diffusion*; IEEE Transactions on Medical Imaging, 21(4):377-384, 2002.
- 111 Laumans M.L.: *Anisotrope Diffusion zur Glättung von MR-Bilddaten und Anwendung zur automatischen histogrammbasierten Segmentierung von Hirninfarkten*; Charité Universitätsmedizin Berlin. Inaugural-Dissertation, Promoviert 2.4.2004.
- 112 Wagenknecht G., Belitz H., Wolff R., Castellanos J.: *Segmentation of ROIs/VOIs from small animal images for functional analysis*; ITBS2005, Nuclear Instruments and Methods in Physics Research, Section A, 2:481-487, 2006.
- 113 Bruhn A., Jakob T., Fischer M., Kohlberger T., Weickert J., Brüning U., Schnörr C.: *Designing 3-D Nonlinear Diffusion Filters for High Performance Cluster Computing*; Pattern Recognition Springer LNCS, 2449:290-297, 2002.

Danksagung

Die vorliegende Arbeit entstand in den Jahren 2003-2006 während meiner Tätigkeit in der Arbeitsgruppe Multimodale Bildverarbeitung am Zentralinstitut für Elektronik (ZEL) des Forschungszentrums Jülich. Ermöglicht wurde sie durch die finanzielle Unterstützung vom Deutschen Akademischen Austausch Dienst (DAAD) und durch ein anschließendes Promotionsstipendium des Forschungszentrums Jülich GmbH.

Für seine Unterstützung meiner Arbeit und die Übernahme des Referats möchte ich zunächst dem Institutsleiter des Instituts für Medizinische Informatik, Biometrie und Epidemiologie am Campus Benjamin Franklin der Charité Berlin Herrn Prof. Dr. rer. nat. Thomas Tolxdorff herzlich danken.

Herrn Prof. Dr. med. Dr. h. c. R. Felix, Direktor der Klinik für Strahlenheilkunde am Campus Virchow-Klinikum der Charité Berlin danke ich für die Unterstützung.

Ich danke für die Übernahme des Korreferats und sein Interesse an dieser Arbeit Herrn Prof. Dr. med. Thomas Albrecht aus der Klinik und Hochschulambulanz für Radiologie und Nuklearmedizin, Campus Benjamin Franklin, Charité - Universitätsmedizin Berlin.

Besonders dankbar bin ich Frau Dr.-Ing. Gudrun Wagenknecht, Gruppenleiterin der Arbeitsgruppe Multimodale Bildverarbeitung des Zentralinstitutes für Elektronik am Forschungszentrum Jülich, für die Möglichkeit der Bearbeitung dieser interessanten Aufgabenstellung sowie für die Betreuung der Arbeit, die wertvollen Ratschläge, die kritischen Diskussionen und das Korrekturlesen der Arbeit.


Herrn Prof. Dr. Karl Rohr, Leiter der Forschungsgruppe Biomedical Computer Vision (BMCV) an der Universität Heidelberg und am DKFZ Heidelberg, möchte ich für die kontinuierliche Unterstützung meiner Arbeit und seine Bereitschaft zur fachlichen Diskussion danken.

Herrn Dr. Titus Hoffmann von der Klinik für Strahlenheilkunde, Charité-Campus Virchow-Klinikum, Herrn Dr. Jürgen Braun vom Institut für Medizinische Informatik, Biometrie und Epidemiologie am Campus Benjamin Franklin der Charité Berlin, Frau Dr. Katja Bühler und Frau Dipl.-Ing. Johanna Beyer von der Arbeitsgruppe Medical

Visualization des Zentrums für Virtual Reality und Visualisierung Forschungs-GmbH in Wien, sowie Herrn Dr. Becker von der Klinik und Poliklinik für Nuklearmedizin, Universität Leipzig, danke ich für die Unterstützung durch die zur Verfügung gestellten Patientendaten und die Evaluierung der gewonnenen Ergebnisse.

Mein besonderer Dank gilt Tom Neubert, Dr. Heinz Rongen, Peter Kämmerling, Prof. Dr. Stephan Appelt, Lydia Fuckardt, Prof. Dr. H. Halling und Dr. Karl Ziemons sowie den anderen Mitarbeitern des ZEL für deren Freundschaft und starke Unterstützung in all diesen Jahren.

1. **Methoden zur integrierten Analyse metabolischer Netzwerke unter stationären und instationären Bedingungen**
von S. A. Wahl (2008), 245 Seiten
ISBN: 978-3-89336-506-7
2. **Strukturelle Untersuchungen an membranassoziierten Proteinen: NMR-Strukturen des HIV-1 Virus Protein U (39-81) und des humanen CD4 (372-433)**
von M. Wittlich (2008), XVIII, 185 Seiten
ISBN: 978-3-89336-510-4
3. **Identifizierung von physiologischen und artifiziellen Liganden von GABARAP und Charakterisierung der resultierenden Interaktionen**
von J. Mohrlüder (2008), V, 158 Seiten
ISBN: 978-3-89336-511-1
4. **Struktur und Funktion von Transaminasen aus *Corynebacterium glutamicum***
von J. Marienhagen (2008), VI, 154 Seiten
ISBN: 978-3-89336-512-8
5. **Implementierung eines Funk-Protokolls (IEEE 802.15.4) und Entwicklung eines adaptiven Zeitsynchronisationsverfahrens für ein Netzwerk intelligenter und autarker Sensoren**
von M. Schlösser (2008), 77 Seiten
ISBN: 978-3-89336-519-7
6. **Etablierung und Optimierung der sekretorischen Gewinnung thermostabiler Lipasen in Gram-positiven Bakterien**
von H. Brundiek (2008), VIII, 154 Seiten
ISBN: 978-3-89336-520-3
7. **Visuospatial Attention: Neural Correlates and Pharmacological Modulation in Healthy Subjects and Patients with Spatial Neglect**
by S. Vossel (2008), XIV, 176 Seiten
ISBN: 978-3-89336-526-5
8. **Analyse des Substratspektrums der ClpCP-Protease aus *Corynebacterium glutamicum***
von J.-E. Schweitzer (2008), V, 130 Seiten
ISBN: 978-3-89336-528-9
9. **Adaptive Verfahren zur automatischen Bildverbesserung kernspintomographischer Bilddaten als Vorverarbeitung zur Segmentierung und Klassifikation individueller 3D-Regionen des Gehirns**
von J. Castellanos (2008), VI, 100 Seiten
ISBN: 978-3-89336-539-5



Band | Volume 9
ISBN 978-3-89336-539-5

