Segmentierung von MR Hirnbildern mit Hilfe von Markov-Random Feldern

Elena Rota Kops, Karsten Held[1], Bernd J. Krause, Hans-W. Müller-Gärtner

Institut für Medizin, Forschungszentrum Jülich GmbH, 52425 Jülich
[1]Theoretische Physik III, Universität Augsburg, 86135 Augsburg
e.rota.kops@kfa-juelich.de

Eine vollautomatische 3D-Segmentierung für kernspintomographische Bilder des Gehirns wird vorgestellt. Unter Einsatz von Markov-Zufallsfeldern (MRF) berücksichtigt dieser Algorithmus drei wichtige Charakteristika: nicht-parametrische Verteilung von Gewebsintensitäten, Signalinhomogenitäten und Nachbarschaftsbeziehungen. Ein "iterated conditional mode" (ICM) findet Anwendung zur Maximierung der a posteriori Wahrscheinlichkeit der segmentierten Daten und der Signalinhomogenitäten. In mittels Doppel-Echo und Single-Echo Sequenzen akquirierten MR-Bildern werden die Gewebsklassen von grauer und weißer Hirnsubstanz, Liquor, Kopfschwarte/Knochen und Hintergrund klassifiziert. Bei originalen MR-Bildern und in Simulationen werden die Charakteristika des Segmentierungs-Algorithmus aufgezeigt. Der Einfluß von Rauschen, Inhomogenität, Glättung und Dicke der Strukturen auf die Qualität der Segmentierung wird evaluiert.

Keywords: Kernspintomographie, Segmentierung, Markov-Zufallsfelder

1 Einleitung

Die Kernspintomographie (MRT) zeichnet sich als bildgebendes Verfahren durch guten Kontrast verschiedener Gewebe und eine hohe räumliche Auflösung aus. Bei MR-Bildern des Gehirns ist die Segmentierung in verschiedene Gewebsklassen wie graue Hirnsubstanz, weiße Hirnsubstanz, Liquor, Kopfschwarte/Knochen und Hintergrund eine wichtige Voraussetzung für die 3D-Visualisierung und "Peeling" des Gehirnes, quantitative Analyse der Gehirnmorphometrie, Matching von MR-Bildern mit anderen bildgebenden Verfahren und die Partialvolumenkorrretur im Kontext quantitativer Positronen Emissions Tomographie (PET) und Einzelphotonen Emissions Tomographie (SPECT). Eine vollautomatische 3D-Segmentierung für kernspintomographische Bilder des Gehirns wird vorgestellt, die auf einer adaptiven Segmentierung (AS) basiert [1]. Unsere Erweiterung nutzt MRF zur Einbeziehung von Nachbarschaftsbeziehungen in die 3D-Segmentierung. Der vorgestellte Segmentierungsalgorithmus vereint folgende Spezifikationen: Nicht-parametrische Verteilung von Gewebsinhomogenitäten, Nachbarschafts-Gewebe Korrelationen (MRF) und Signalinhomogenitäten (*a priori* MRF).

2 Methode

2.1 MRF Segmentierung

Eine Methode zur Einbeziehung räumlicher Korrelationen in einem zu segmentierendem Bild ist der Einsatz von MRF als *a priori* Modell. Die Markov-Zufallsfelder liefern eine bedingte Wahrscheinlichkeitsverteilung, wobei die Wahrscheinlichkeit eines Zufallsfeldes (Voxel) von seiner Nachbarschft abhängt. Gibbs-Verteilungen stellen eine äquivalente Beschreibung von Zufallsfeldern als Verbundverteilungen dar, so daß die betrachteten *a priori* Wahrscheinlichkeiten mittels Gibbs-Verteilung beschrieben werden können.

Eine *a priori* Wahrscheinlichkeit $p(\mathbf{x})$ für die segmentierten Daten wird benutzt, um die örtlichen Beziehungen innerhalb des Bildes zu modellieren. Ein geglättetes Inhomogenitätsfeld **y** wird durch eine eingeschränkte *a priori* Verteilung $p(\mathbf{y})$ beschrieben. Bei gegebenen *a priori* Wahrscheinlichkeiten für die segmentierten Daten **x** und für das Inhomogenitätsfeld **y** wird die bedingte Wahrscheinlichkeit für die beobachteten Intensitätswerte **z** mittels der *Parzen-Window* Verteilung [2] $p(\mathbf{z}|\mathbf{x},\mathbf{y})$ berechnet. Die Bayes'sche Regel wird benutzt, um die *a posteriori* Wahrscheinlichkeit für die segmentierten Daten **x** und das Inhomogenitätsfeld **y** bei gegebenen Intensitäten **z** zu berechnen:

$$p(\mathbf{x},\mathbf{y}|\mathbf{z}) \propto p(\mathbf{z}|\mathbf{x},\mathbf{y})\, p(\mathbf{x})\, p(\mathbf{y}) \qquad (1)$$

Diese Wahrscheinlichkeit wird mittels eines *"iterated conditional mode"* (ICM) maximiert. Auf die drei Terme von Gleichung (1) wird im folgenden eingegangen.

Mit einem Nachbarschaftssystem von 6 benachbarten Voxel (3D) wird die Wahrscheinlichkeitsverteilung $p(\mathbf{x}) \propto \exp(-E(\mathbf{x}))$ mit der Gibbs-Energiefunktion $E(\mathbf{x}) = \Sigma e_x$ benutzt, wobei die Summe über alle Voxel und deren 6 Nachbarn gebildet wird. Das Potential e_x muß minimal sein für benachbarte Voxel des gleichen Gewebstypes, um die gleiche Segmentierung sicherzustellen, andererseits muß es maximal sein für bekannterweise nicht benachbarte Gewebe (z.B. Kopfschwarte/Knochen und graue Hirnsubstanz).

Da das Magnetfeld langsam variiert, muß die *a priori* Wahrscheinlichkeit $p(\mathbf{y})$ ein geglättetes Inhomogenitätsfeld **y** liefern. Wiederum mit einem Nachbarschaftssystem von 6 benachbarten Voxel erhält man $p(\mathbf{y}) \propto \exp(-U(\mathbf{y}))$ mit der Gibbs-Energiefunktion $U(\mathbf{y}) = \alpha\Sigma(y_i - y_j)^2 + \beta\Sigma y_i^2$, wobei *i* die betrachteten Zufallsfelder (Voxel) und *j* die 6 benachbarten Voxel sind. Auf den ersten Blick scheint es, daß es unzureichend ist, eine lokale Nachbarschaft von 6 Voxeln zu betrachten, um ein geglättetes Inhomogenitätsfeld zu erhalten. Es ist jedoch aus der statistischen Mechanik bekannt, daß solche lokalen Potentiale eine hoch signifikante Korrelation besitzen. Der Gauss'sche Term wurde ausgesucht, da das Potential quadratisch zunimmt und deshalb ein geglättetes Inhomogenitätsfeld liefert. Im 2. Term ist die *a priori* Information durch β modelliert, d.h. kleine Inhomogenitätskorrekturen werden wahrscheinlicher als größere.

Nicht-parametrische Statistik wird benutzt, um die unzureichend getrennten Gewebsintensitäts-Verteilungen von MR-Bildern zu beschreiben. Zu diesem Zweck wird hier die bedingte Wahrscheinlichkeit $p(\mathbf{z}|\mathbf{x},\mathbf{y})$ durch eine *Parzen-Window* Verteilung modelliert. Für jede Gewebsklas-

klasse werden *Trainings*-Punkte durch eine ausgebildete Person [3] selektiert; die *Parzen-Window* Verteilung erhält man, indem eine schmale Gauss'sche Verteilung um jeden *Trainings*-Punkt zentriert wird. Für Single-Echo (SE) MR-Daten ist diese Verteilung eindimensional und bei Doppel-Echo (DE) Datensätzen zwei-dimensional.

Das ICM [4] maximiert die *a posteriori* Wahrscheinlichkeit der segmentierten Daten **x** und des Inhomogenitätsfeldes **y** iterativ. Es konvergiert dann zu lokalen - nicht unbedingt globalen - Maxima für die *a posteriori* Wahrscheinlichkeit.

Bei der Parameterwahl wurden aus statistischen und empirischen Überlegungen für die ersten Validierungstests zwei unterschiedliche Energien e_x benutzt: $e_x = 0$ für benachbarten Voxel gleichen Gewebes und $e_x = \varepsilon = 0.05$ für unterschiedliche Gewebe. Ähnliche Überlegungen galten für die Parameter α und β, die die Werte 100 bzw. 20 erhielten.

2.2 Akquisitions-Parameter der MR-Bilder

MR-Bilder des Gehirns von sechs gesunden Probanden wurden mit einem 1,5 T MR-Scanner "Vision" der Firma Siemens aufgenommen. Die dabei eingesetzte Sequenz war eine Doppel-Echo Sequenz mit Protonendichte- und T_2-gewichteten Bildern (T_R=5410 ms, T_{E1}=20ms und T_{E2}=120ms) mit einer isotropen Auflösung von 1x1x1mm. Zum direkten qualitativen Vergleich wurden Protonendichte-gewichtete MR-Bildern als Single-Echo-Daten benutzt.

2.3 Simulationen

Zur Validierung des Segmentierungsalgorithmus und für einen quantitative Analyse wurden MR Bilder simuliert. Eine Template-Segmentierung eines 256x256x256 MR Datensatzes mit isotroper Auflösung von 1x1x1mm wurde verwendet. Die Template-Segmentierung wurde als Basis-Segmentierung definiert. Ausgehend vom korrespondierendem Doppel-Echo MR-Bild wurden die Mittelwerte aller Gewebsklassen errechnet. Die Intensität jedes Voxels wurde gleich dem Mittel der Gewebsklasse gesetzt. Simulierte MR-Bilder wurden mit den AS-DE, ICM-DE und ICM-SE Algorithmen segmentiert, und die Ergebnisse mit dem Basis-Segmentierungs-Bild verglichen. Glättung (A), Rauschen (B), Inhomogenität (C) und Dicke der Strukturen (D) wurden folgendermaßen modelliert:

A Das Template-Segmentierungs-Bild wurde mit den sechs Nachbaschafts-Pixeln dreidimensional geglättet. Das Gewicht jedes Nachbarschafts-Voxels in Relation zum Pixel im Zentrum wurde *S* notiert. Bei *S*=1/6 setzt sich die Intensität eines Voxels zu 50% aus seiner Gewebsklassen-Zugehörigkeit und zu 50% aus den umgebenden Gewebsklassen zusammen.

B 2D-Gauss´sches Rauschen der Standardabweichung *N* wurde addiert. Ein relatives Maß für dieses Rauschen ist der Kontrast/Rausch Quotient zweier Gewebe. Bei den Protonendichte-gewichteten Bildern entspricht ein typisches Kontrast/Rausch Niveau bei *N*=50 einem Kontrast/Rausch Quotienten von 4,7 (graue Substanz zu weißer Substanz) und einem Signal/Rausch Quotienten von 21 (graue Substanz).

C Das Template-Segmentierungs-Bild wurde mit einem Inhomogenitäts-Faktor multipliziert. Dieser Faktor änderte sich linear mit der euklidischen Distanz vom Punkt ((x,y,z) = (0,0,15/2)). Der maximale Inhomogenitäts-Faktor eines nicht-Hintergrund Gewebes

wurde 1 + *I* gesetzt, der minimale Inhomogenitäts-Faktor eines nicht-Hintergrund Gewebes 1 - *I*.

D Für die Simulationen des Einflusses der Dicke der grauen Substanz auf die Qualität der Segmentierung wurde ein künstliches Bild mit sinusoidaler Struktur der grauen Substanz zwischen weißer Substanz und Hintergrund benutzt. Die graue Substanz war *d* Voxel dick (*d*=1-11).

3 Ergebnisse

MR-Bilder unter Einbezug von Rauschen, Inhomogenität, Glättung und Dicke der grauen Hirnsubstanz wurden simuliert, mit den AS-DE, ICM-DE und ICM-SE Algorithmen segmentiert und mit der Basis-Segmentierung verglichen. Der Fehler wurde als Quotient von falsch klassifizierten Voxel/nicht-Hintergrund Voxel berechnet. Der Einfluß von Rauschen auf die Qualität der Segmentierung ist in Abbildung 1 dargestellt.

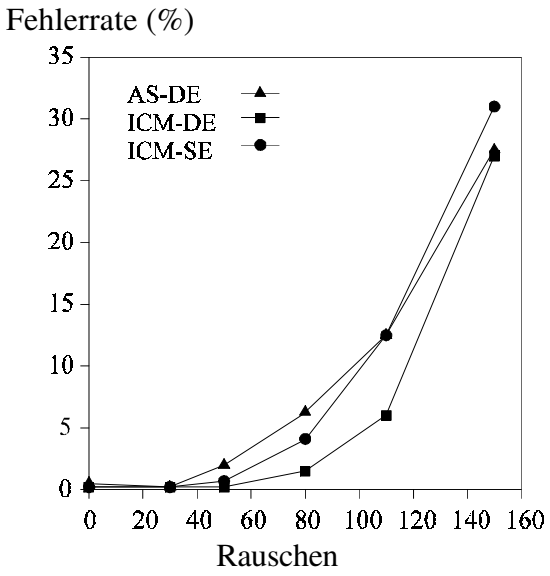

Abbildung 1: Einfluß des Rauschens auf die Fehlklassifikationsrate (DE: Doppel-Echo; SE: Single-Echo)

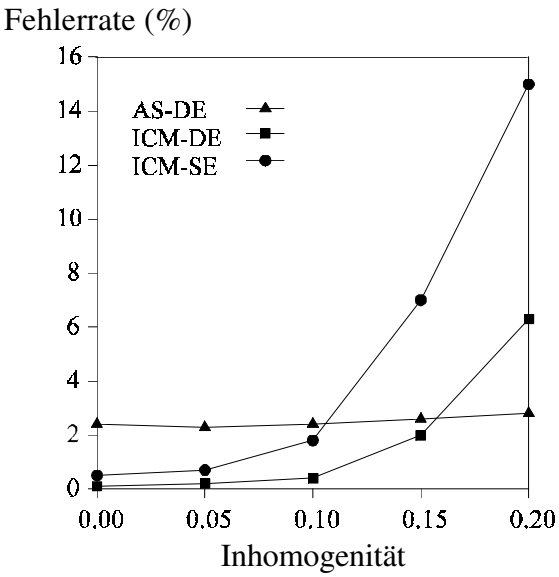

Abbildung 2: Einfluß der Inhomogenität auf die Fehlklassifikationsrate (DE: Doppel-Echo; SE: Single-Echo)

Bis zu $N = 50$ zeigt der ICM-Algorithmus eine niedrigere Fehlklassifikationsrate (0,5%) als der AS-Algorithmus (2,3%). Für erhöhte Rauschniveau ($N = 30 - 100^3$) erbrachte der Single-Echo ICM-Algorithmus bessere Ergebnisse als der AS-Algorithmus (der nur für Doppel-Echo Sequenzen ausgelegt ist). Für beide Algorithmen zeigte sich ein exponentieller Anstieg der Fehlerrate in Abhängigkeit der Standardabweichung *N* des Gauss´schen Rauschens. Der Einfluß der Inhomogenität auf die Resultate der Segmentierungsalgorithmen wurde mit verschiedenen Werten für *I* simuliert (Abbildung 2). Für die ganze Bandbreite der eingeführten Inhomogenitäten war bei dem AS-Algorithmus die Fehlklassifikationsrate konstant (2,3%). Bei Inhomogenitäten kleiner als I = 0,125 zeigte der ICM-Algorithmus kleinere Fehlklassifikationsraten als der AS Algorithmus, für Inhomogenitäten größer als I = 0,125 waren die Ergebnisse des ICM-

Algorithmus schlechter. Glättung verursachte einen Verlust an Bildinformation. Beide Algorithmen zeigten Probleme bei der Rekonstruktion des originalen Bildes, der ICM-Algorithmus jedoch die besseren Ergebnisse (Abbildung 3). In Abhängigkeit von der Dicke der grauen Hirnsubstanz zeigte sich eine bei d > 3 nicht zunehmende Fehlklassifikationsrate; für $d = 1$ war die Fehlklassifikationsrate höher (Abbildung 4).

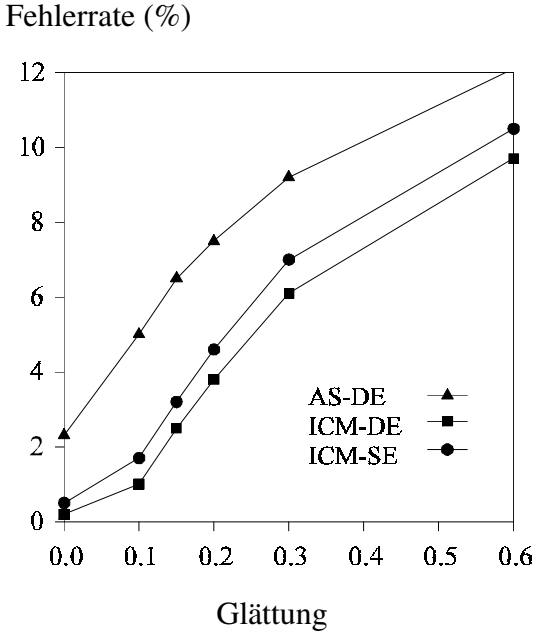

Abbildung 3: Einfluß der Glättung auf die Fehlklassifikationsrate (DE: Doppel-Echo; SE: Single-Echo)

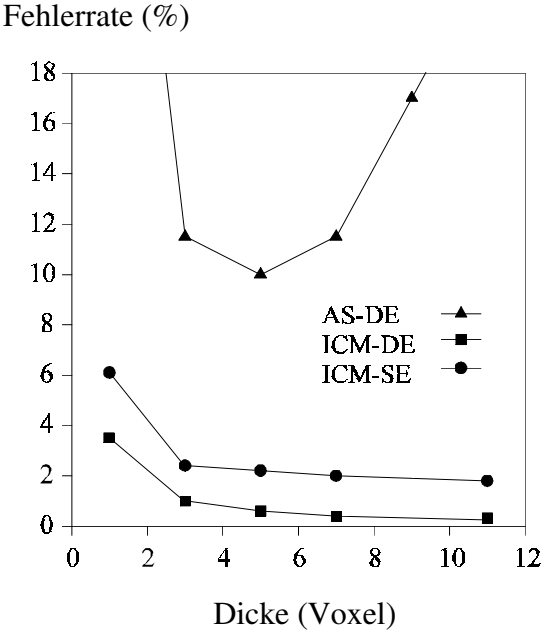

Abbildung 4: Einfluß der Dicke der grauen Substanz auf die Fehlklassifikationsrate (DE: Doppel-Echo; SE: Single-Echo)

In Abbildung 5 wird eine mittels des ICM-DE Algorithmus segmentierte Schicht durch den mesialen Temporallappen mit Darstellung der Hippocampusformation, des entorhinalen Cortex und des perirhinalen Cortex gezeigt.

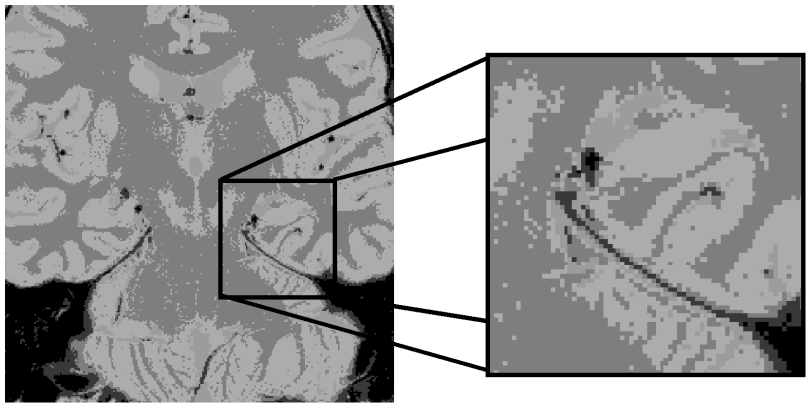

Abbildung 5: Mittels des ICM-DE Algorithmus segmentierte Schicht durch den mesialen Temporallappen (Hellgrau: graue Substanz, Mittelgrau: Liquor, Dunkelgrau: weiße Substanz)

4 Diskussion

Zwei Segmentierungs-Algorithmen (ICM- und AS-Algorithmus) wurden vorgestellt, die nicht-parametrische Verteilungen von Gewebsintensitäten, Nachbarschaftsbeziehungen und Signalinhomogenitäten im MR-Bild beschreiben. Gewebsintensitäten und Signalinhomogenitäten wurden in gleicher Weise vom ICM- und AS-Algorithmus einbezogen, während nur im ICM-Algorithmus Nachbarschaftsbeziehungen berücksichtigt wurden. Einbeziehung der Nachbarschaftsbeziehungen und a priori Gibbs Verteilung für das Inhomogenitätsfeld verbesserten das Segmentierungs-Ergebnis (siehe Abbildung 1): Bis zu einem Kontrast/Rauschen Quotienten von 2,4 klassifizierte der ICM-Algorithmus praktisch keine Voxel falsch im Gegensatz zum AS-Algorithmus (2,3%). Gewebsintensitäten und Signalinhomogenitäten wurden besser vom ICM-Algorithmus segmentiert (Abbildung 3,4). Da der AS-Algorithmus nicht berücksichtigt, daß kleine Inhomogenitätskorrekturen wahrscheinlicher sind als große, neigt er zur Überschätzung der Inhomogenität. Die erheblich hohe Fehlklassifikationsrate des AS-Algorithmus in Bereich der Sinusoiden erklärt sich aus der Tatsache, daß bei kleinen Dicken der grauen Substanz durch die Filterung die Intensität erniedrigt wird und dadurch viele Voxel grauer Substanz fälschlicherweise als weiße Substanz klassifiziert werden.

5 Zusammenfassung

Der vorgestellte 3D-Segmentierungs-Algorithmus kombiniert unter Einbeziehung von Markov-Zufallsfeldern erstmals nicht-parametrische Gewebsintensitätsverteilungen, Nachbarschaftsbeziehungen und Signalinhomogenitäten in einem einzigen Algorithmus. Die Kombination dieser drei für MR-Bilder essentiellen Charakteristika führt zu einer akkuraten und stabilen Segmentierung unter Berücksichtigung von Rauschen, Glättung, Inhomogenität und Dicke der grauen Substanz.

[1] Wells WM, Grimson WEL, Kikinis R, Jolesz FA: IEEE Trans. on Medical Imaging, 15 (4): 429-442, 1996

[2] Duda RO, Hart PE: Pattern Classification and Scene Analysis, John Wiley and Sons, 1973

[3] Kikinis R, Shenton M, Jolesz FA, Gerig G, Martin J, Anderson M, Metcalf D, Guttmann C, Mc-Carley RW, Lorensen W, Cline H: Quantitative Analysis of Brain and Cerebrospinal Fluid Spaces with MR Imaging, J Magn Res Imag: 619-629, 1992

[4] Besag J: On the Statistical Analysis of Dirty Pictures: J Roy Stat Soc, B (48): 259-302, 1986