

Level-Set-Segmentierung von Rattenhirn MRTs

Björn Eiben^{1,2}, Dietmar Kunz², Uwe Pietrzyk^{1,3} und Christoph Palm^{1,3}

¹Institut für Neurowissenschaften und Biophysik, Jülich Forschungszentrum

²Institut für Medien- und Phototechnik, Fachhochschule Köln

³Fachgruppe Physik, Bergische Universität Wuppertal

`ch.palm@fz-juelich.de`

Kurzfassung. In dieser Arbeit wird die Segmentierung von Gehirngewebe aus Kopfaufnahmen von Ratten mittels Level-Set-Methoden vorgeschlagen. Dazu wird ein zweidimensionaler, kontrastbasierter Ansatz zu einem dreidimensionalen, lokal an die Bildintensität adaptierten Segmentierer erweitert. Es wird gezeigt, dass mit diesem echten 3D-Ansatz die lokalen Bildstrukturen besser berücksichtigt werden können. Insbesondere Magnet-Resonanz-Tomographien (MRTs) mit globalen Helligkeitsgradienten, beispielsweise bedingt durch Oberflächenspulen, können auf diese Weise zuverlässiger und ohne weitere Vorverarbeitungsschritte segmentiert werden. Die Leistungsfähigkeit des Algorithmus wird experimentell an Hand dreier Rattenhirn-MRTs demonstriert.

1 Einleitung

Die Segmentierung von Gehirngewebe aus Kopfaufnahmen unterschiedlicher Modalitäten wird unter dem Begriff *Skull-Stripping* zusammengefasst. Dieses stellt einen wichtigen Vorverarbeitungsschritt für quantitative morphometrische Untersuchungen dar oder kann in vivo Konturinformationen für die Registrierung von Schnittmodalitäten bereitstellen. Im Rahmen dieser Arbeit werden MRTs von Rattenhirnen für die Evaluation des vorgeschlagenen Algorithmus verwendet.

Für die Segmentierung dreidimensionaler Daten sind leistungsstarke, flexible Modelle von hoher Bedeutung. Eine besondere Stellung nehmen hier aktive Konturmodelle ein, welche durch die Level-Set-Formulierung eine implizite Oberflächendarstellung und -entwicklung erlauben. Sie weisen insbesondere bei numerischen Berechnungen gutmütige Eigenschaften auf [1, 2].

Ein weit verbreitetes Werkzeug zum Skull-Stripping von Kopf-MRTs des Menschen ist das Brain-Extraction-Tool (BET), welches am FMRIB-Center der University of Oxford entwickelt wurde. Es basiert auf einem deformierbaren Netz, an dessen Knoten Formkräfte angreifen [3]. Zhuang et al. [4] haben diese Formkräfte in die Geschwindigkeitsfunktion der Level-Set-Methoden überführt und dabei einen zweidimensionalen Ansatz gewählt, welcher durch Konturpropagation auf benachbarte Schichten für dreidimensionale Daten einsetzbar ist. In dieser Arbeit wird ein echt-dreidimensionales Level-Set-basiertes Skull-Stripping auf Rattenhirn-MRTs vorgestellt und damit ein in allen Raumrichtungen konsistentes Segmentierungsergebnis ermöglicht.

2 Material und Methoden

Für die Segmentierungsaufgabe wird auf die Level-Set-Methoden nach [2] zurückgegriffen. Level-Sets sind Höhenlinien einer Funktion $\phi(\mathbf{x}) : \mathbf{x} \in \mathbb{R}^n \mapsto \mathbb{R}$ mit der Bilddimension n . Die zu beschreibende Kontur $\partial\Omega$ wird implizit durch den Nulldurchgang der Funktion ϕ beschrieben, das so genannte Zero-Levelset: $\partial\Omega = \{\mathbf{x} \mid \phi(\mathbf{x}) = 0\}$. Eine auf diese Weise definierte Startkontur, welche komplett innerhalb des zu segmentierenden Objektes liegt, wird durch eine partielle Differentialgleichung zeitlich deformiert und führt zu den Level-Set-Methoden:

$$\frac{\partial\phi}{\partial t} + \beta S(\mathbf{x}, \phi(\mathbf{x}, t)) |\nabla\phi| = \gamma\kappa |\nabla\phi| \quad (1)$$

Hierbei bezeichnet t die Zeit, $S(\mathbf{x}, \phi(\mathbf{x}, t))$ die Geschwindigkeitsfunktion in Normalenrichtung $\nabla\phi$ der Kontur und κ die Krümmung der Kontur. Damit ist die Geschwindigkeitsfunktion bestimmend für den Segmentierungsprozess, wobei sich die Minimierung der Krümmung glättend auf die Kontur auswirkt. β und γ sind skalare Gewichtungsfaktoren.

Die Geschwindigkeitsfunktion wird, wie schon in [4], örtlich und zeitlich adaptiv berechnet. Hierzu wird entlang der nach innen zeigenden Konturnormalen das Intensitätsminimum und -maximum bestimmt. Der hieraus ermittelte Kontrast definiert, wie schnell die Kontur orthogonal zu sich selbst deformiert wird. Vor der Segmentierung wird eine Histogrammauswertung innerhalb der Startkontur vorgenommen. Das ermittelte Minimum darf nicht größer und das Maximum nicht kleiner werden als der Median des Histogramms. Dieses Prinzip findet auch beim BET Anwendung [3]. Globale Helligkeitsgradienten im Bild führen daher zu frühzeitigen Segmentierungsabbrüchen (Abb. 1, helle Kurve).

Zur Steigerung der Robustheit bei Helligkeitsgradienten im Bild wird im ersten Versuch auf den globalen Median verzichtet und stattdessen auf den lokalen Kontrast an der Objektgrenze abgehoben:

$$S(\mathbf{x}, \phi(\mathbf{x}, t)) = \frac{I_m(\mathbf{x}, \phi(\mathbf{x}, t), d_m)}{I_M(\mathbf{x}, \phi(\mathbf{x}, t), d_M)} - T, \quad (2)$$




Abb. 1. Vergleich des Segmentierungsergebnisses an der sagittalen Schicht 140 zwischen dem 2D- (hell) und dem 3D-Segmentierer (dunkel). Der 2D-Ansatz führt zu einem frühzeitigen Abbruch der Segmentierung.

wobei I_m das Minimum auf der Normalen $\mathbf{N} = \frac{\nabla\phi}{|\phi|}$ in einem einstellbaren, maximalen Abstand d_m zur Kontur und I_M das entsprechende Maximum mit dem maximalen Abstand d_M darstellt. T bezeichnet den erwarteten Konturkontrast.

In einem zweiten Ansatz wird I zusätzlich lokal kontrastverstärkt:

$$I' = \text{Median}(I, \mathbf{x}, \mathbf{N}) + w \frac{\text{Var}_i(I, \mathbf{x}, \mathbf{N}) - \text{Var}_o(I, \mathbf{x}, \mathbf{N})}{\text{Median}(I, \mathbf{x}, \mathbf{N})} \quad (3)$$

Die Differenz zwischen den auf \mathbf{N} gleitenden, nach außen und nach innen gerichteten Varianzen Var_i und Var_o ruft eine Kontrastverstärkung hervor, welche insbesondere in schwachkontrastigen Bereichen bedingt durch die Normierung auf den gleitenden Median stärker wirkt. w gewichtet diese Signalaufteilung. Die korrespondierende Geschwindigkeitsfunktion ergibt sich analog zu (2). Abbildung 2 zeigt die Wirkung der Signaladaption exemplarisch an einer Scanline in einem schwachkontrastigen Bereich. Nulldurchgänge bedingen einen Richtungswechsel der Konturpropagation (positive Werte bedeuten Expansion).

Beim Übergang von einer 2D-Konturpropagation mit globalem Median [4] zu einer 3D-Segmentierung mit lokaler Auswertung der Kontrastverhältnisse und späterer Erweiterung mit Signaladaption besteht die Hypothese, dass im Hinblick auf Leakage bzw. vorzeitigen Abbruch robustere und an problematischen Stellen genauere Ergebnisse resultieren.

Die Implementation wurde mit dem Insight Segmentation and Registration Toolkit (ITK) vorgenommen, welches für die Level-Set-Methoden jedoch isotrope Daten voraussetzt. Zur Generierung isotroper Daten wurde eine registrierungs-basierte Interpolation nach Penney verwendet [5].

3 Ergebnisse

Drei Datensätze eines 9,4 T Kleintier MRI-Scanners (21 cm Innendurchmesser, Oberflächenspule, Gradientenfeld: 270 mT/m, UnityInova Konsole (Varian, Palo Alto, USA)) standen zur Verfügung. Das T2 gewichtete Echo (TE = 24 ms)




Abb. 2. Signal (hell gestrichelt) und adaptiertes Signal (durchgezogen) der Scanline (von innen nach außen) mit den zugehörigen Geschwindigkeitsfunktionen und der Scanline im Bild. Nulldurchgänge bewirken einen Richtungswechsel der Konturpropagation.

Tabelle 1. Die Dice-Koeffizienten gemäß (4) für drei Datensätze, wobei der erste Datensatz einen deutlichen Helligkeitsgradienten aufweist.

Datensatz	D_{2D}	D_{3D}	$D_{3D,SA}$
1	0.939	0.964	0.966
2	0.938	0.945	0.938
3	0.939	0.942	0.931

ergab 40 Schichtbilder mit einer Auflösung von 256×256 Bildpunkten und einer Ortsauflösung von $0,117 \times 0,117 \times 0,5$ mm.

Die rekonstruierten 3D-Daten wurden einmal mit dem in [4] vorgestellten Algorithmus 2D schichtweise segmentiert und einmal 3D ohne und mit Signaladaption. Als Referenz zur Qualitätsbestimmung der Segmentierungsergebnisse wurden die Daten manuell segmentiert. Als Qualitätsmaß dient der Dice-Koeffizient:

$$D = \frac{2|X \cap Y|}{|X| + |Y|} \quad (4)$$

Dabei sind X und Y die Mengen der Bildpunkte, welche zum Referenz- bzw. segmentierten Volumen gehören. Die Dice-Koeffizienten für drei Datensätze sind

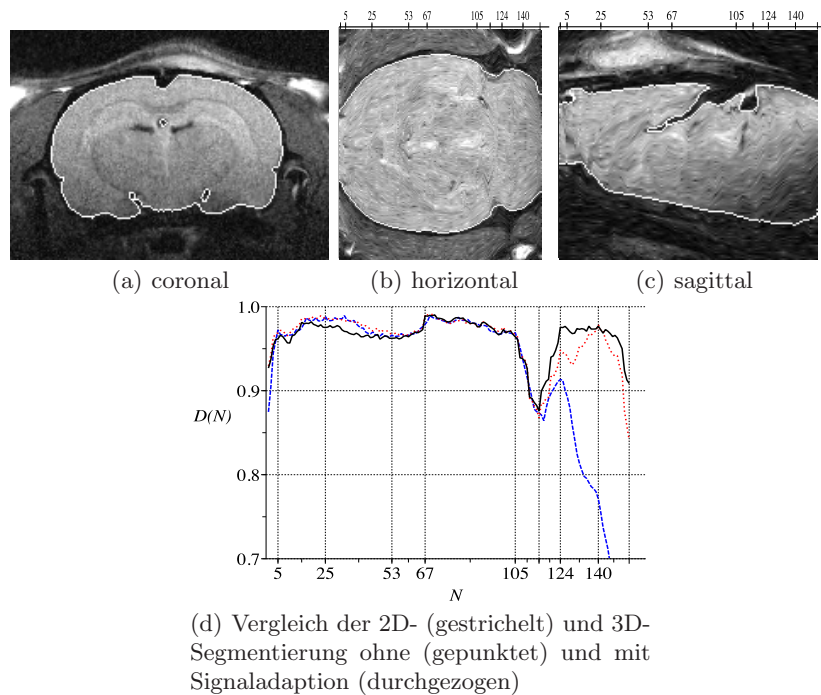


Abb. 3. Darstellung des Segmentierungsergebnisses zu Datensatz 1 in zueinander orthogonalen Schnitten.

in Tabelle 1 dargestellt. Für alle Tests schneidet ein 3D-Ansatz besser ab. Besonders deutlich ist mit 0.966 zu 0.939 der Unterschied für den ersten Datensatz. Dieser weist, bedingt durch eine Oberflächenspule, einen deutlichen Helligkeitsgradienten auf. Bei den übrigen Daten ist diese Eigenschaft weniger ausgeprägt.

Abbildung 3(d) zeigt D aufgetragen über die Schichten N des ersten Datensatzes, aus welchem zueinander orthogonale Schnitte in Abbildung 3(a)-3(c) dargestellt sind. Die gestrichelte Kurve zeigt das Ergebnis der zweidimensionalen, die gepunktete das der dreidimensionalen, lokal modifizierten Segmentierung und die durchgezogene Kurve das Segmentierungsergebnis mit Signaladaption.

4 Diskussion

Die gewählte Kombination aus 3D-Datenverwertung und einer lokalen Signaladaption bei der Level-Set-Segmentierung liefert insbesondere bei Datensätzen mit einem ausgeprägten, globalen Helligkeitsgradienten eine deutliche Verbesserung des Segmentierungsergebnisses. Eine Vorverarbeitung zur globalen Helligkeitsangleichung ist damit für den Segmentierungsprozess nicht erforderlich. Bei Daten ohne ausgeprägten Helligkeitsgradienten konnte das Qualitätsniveau mindestens gehalten oder sogar leicht verbessert werden (siehe Tab. 1, Zeile 2 und 3). Die Erwartung, dass eine 3D-Verarbeitung an stark gekrümmten Strukturen zu stark glätten könnte, wurde nicht bestätigt. Der 3D-Ansatz ist demnach der 2D-Segmentierung vorzuziehen.

Die Signaladaption verbessert die Segmentierung in Bereichen mit schwachem Signal-zu-Rausch-Verhältnis beispielsweise im Bereich des Cerebellums. In den Schichten 25-40 zeigen sich jedoch leichte Schwächen durch Leakage.

In weiteren Studien werden die Einbindung von Formmodellen in Anlehnung an Leventon [6] beabsichtigt, um die Robustheit weiter zu erhöhen. Darüber hinaus wird die Übertragbarkeit der Ergebnisse auf Menschen-MRs untersucht.

Literaturverzeichnis

1. Sethian JA. Level Set Methods and Fast Marching Methods. Cambridge: Cambridge University Press; 1999.
2. Osher S, Fedkiw R. Level Set Methods and Dynamic Implicit Surfaces. Berlin: Springer; 2002.
3. Smith SM. BET: Brain Extraction Tool. Oxford: FMRIB; 2002.
4. Zhuang AH, Valentino DJ, Toga AW. Skull-stripping magnetic resonance brain images using a model-based level set. NeuroImage. 2006;32:79–92.
5. Penney GP, Schnabel JA, Rueckert D, et al. Registration-based interpolation. IEEE Trans Med Imaging. 2004;23:922–926.
6. Leventon ME, Grimson WEL, Faugeras O. Statistical shape influence in geodesic active contours. Proc CVPR. 2000;01:316–323.