

Automatische, modellbasierte Segmentierung subkortikaler Areale aus MRT-Daten des menschlichen Gehirns: Erste Ergebnisse

Hendrik Belitz¹, Karl Rohr², Heinrich Müller³ und Gudrun Wagenknecht¹

¹Zentralinstitut für Elektronik, Forschungszentrum Jülich GmbH, 52425 Jülich

²Abt. Intelligente Bioinformatik Systeme, Universität Heidelberg und
DKFZ Heidelberg, D-69120 Heidelberg

³Lehrstuhl Informatik VII, Universität Dortmund, 44221 Dortmund
Email: h.belitz@fz-juelich.de

Zusammenfassung. In diesem Beitrag wird ein System zur zweidimensionalen Segmentierung subkortikaler Regionen vorgestellt. Erste Ergebnisse werden anhand von realen Schichtbilddaten und Phantomen präsentiert und eine Erweiterung des Modells auf ein 3D-Verfahren diskutiert. Das sequentiell arbeitende Verfahren verwendet eine Gewebeklassifikation und gradientenvektorflussbasierte aktive Konturmodelle, um den Bildraum bezüglich der gesuchten Strukturen zu partitionieren und diese dann zu segmentieren.


1 Einleitung

In MRT-Bilddaten des menschlichen Gehirns sind die subkortikalen Bereiche, in diesem Fall vor allem die Basalganglien, aufgrund ihrer Grauwertcharakteristik kaum von ihrer Umgebung abgrenzbar (vgl. Abb. 1). Eindeutige Regionengrenzen können deshalb allein auf Basis der Bildinformation oft nicht generiert werden. Durch Einbringen von topologischem und geometrischem Vorwissen ist jedoch eine automatische, modellbasierte Segmentierung und Klassifikation der gesuchten Areale denkbar.

2 Stand der Forschung

Die Segmentierung der Basalganglien aus MRT-Datensätzen erfolgt in Forschung und klinischer Anwendung heutzutage oft immer noch schichtweise und von Hand. Semiautomatische Verfahren können dabei den Segmentierungsprozess signifikant beschleunigen. Sie sind jedoch für den nahezu vollautomatischen Einsatz nur sehr begrenzt geeignet. Automatische, rein bildbasierte Methoden dagegen sind oft nicht in der Lage, die sich nur unzureichend von der umgebenden, weißen Substanz abgrenzenden subkortikalen Areale des Gehirns zu segmentieren.

Abb. 1. Schicht des MNI-Datensatzes [1] mit hervorgehobenen Basalganglien



3 Wesentlicher Fortschritt durch den Beitrag


Das vorliegende prototypische System soll eine weitestgehend automatische Segmentierung der Basalganglien aus einem MRT-Datensatz ermöglichen. Dies wird unter anderem durch Einbringen von topologischem und geometrischem Vorwissen erreicht. Das Vorwissen erlaubt eine Interpolation der Regionengrenzen in Bereichen, in denen die Bildinformation allein nicht für eine sinnvolle Segmentierung ausreicht. Der eigentliche Segmentierungsprozess verläuft vollautomatisch, der Benutzer muss lediglich das Vorwissen und einige Modellparameter im Vorfeld festlegen.

4 Methoden

Das entwickelte prototypische System realisiert eine serielle Verarbeitungspipeline für zweidimensionale, transversale Schichtdaten (wie in Abb. 2a beispielhaft dargestellt), die sich in die Module *Vorverarbeitung*, *Partitionierung* und *Segmentierung* unterteilen lässt.

Im Vorverarbeitungsschritt kommt eine Artefaktreduktion zum Einsatz, sofern das Bildmaterial diese erfordern sollte.

Die Partitionierung trennt die *Regionen des Interesses (ROI)* voneinander und schließt für die Segmentierung uninteressante Regionen des Bildes von weiteren Arbeitsschritten aus. Dieser Schritt kann die Laufzeit der Segmentierung positiv beeinflussen, da durch ihn die Größe des zu durchsuchenden Bildraumes drastisch verringert wird. Zudem erhöht die Trennung der *ROIs* die Stabilität des Segmentierungsmodells. Die Partitionierung verwendet zum einen eine Gewebeklassifikation aller Bildpixel durch ein überwacht lernendes neuronales Netz und einen wissensbasierten *Peeling-Algorithmus* [2] (wie in Abb. 2b für die weiße Substanz dargestellt). Zum anderen dient als Eingangsdatum der Gradient eines zuvor bestimmten Kantenbildes. Dieses Vektorfeld wird mittels eines *generalisierten Gradienten-Vektorfluss-Verfahrens (GGVF)* [3] diffundiert. Die entste-

Abb. 2. Eingangsdatum, Zwischenschritte und resultierende Partitionierung des Bildes


henden Diffusionsfronten benachbarter Objekte treffen dabei aufeinander und bilden *lokale Inhomogenitäten*, das heißt, stark voneinander abweichende Vektorenrichtungen, im resultierenden Feld. Mittels eines Operators können diese Inhomogenitäten extrahiert werden, wie in Abb. 2c dargestellt. Aus dem so gewonnenen Inhomogenitätsprofil und der zuvor bestimmten Klassifikationsmaske kann nun eine sinnvolle Bildunterteilung gewonnen werden (vgl. Abb. 2d). Weitere Details zum Verfahren der Partitionierung können [4] entnommen werden.

Die eigentliche Segmentierung verwendet ein deformierbares aktives Konturmodell in Form eines mit [5] vergleichbaren diskreten Partikelsystems. Dieses wird als Polygon interpretiert, wobei die Stützpunkte des Polygons durch die Partikel gegeben sind. Das Modell ist adaptiv diskretisierbar, das heißt, mit einer Veränderung der Polygongröße werden neue Partikel eingefügt oder Partikel gelöscht, so dass immer eine durchschnittliche Partikeldistanz und somit eine annähernd konstante Diskretisierungsrate gewährleistet wird. Die einzelnen Partikel werden durch gewichtete Kräftesterme verschoben, die das Vorwissen sowie den Bildeinfluß repräsentieren. Im Idealfall konvergiert das Modell gegen die gesuchte Bildstruktur und liefert so die gesuchte Segmentierung.

5 Ergebnisse

Die Segmentierungsergebnisse für zwei beispielhaft ausgewählte Schichten des MNI-Datensatzes [1] sind in den Abbildungen 3a und b dargestellt. Die Ermittlung eines sinnvollen Goldstandards für die gegebene Problemstellung dagegen ist sehr schwierig; das Verfahren wird deshalb anhand von künstlich erzeugten Phantomen evaluiert. Diese Phantome werden aus geometrischen Primitiven erzeugt und bilden den subkortikalen Bereich exemplarischer Hirnschichten grob nach. Die eindeutige Definition der Phantome erlaubt eine einfache Extraktion von Referenzkonturen und somit eine Evaluation auf Basis von verschiedenen Diskrepanzmaßen, die nach den in [6] und [7] vorgestellten Kriterien ausgewählt wurden. Um Bildartefakte und realitätsnahe anatomische Grauwertvariabilitäten zu simulieren, werden die Regionen der Phantome mit einem linearen Grauwertverlauf stetig in die umgebende weiße Substanz überführt und

Abb. 3. Segmentierung zweier Schichten des MNI-Datensatzes und künstlich erzeugte Phantome.




zusätzlich die Phantome als Ganzes mit einem additiven Gaußschen Rauschen verschiedener Standardabweichung überlagert (vgl. Abb 3c, lineare Grauwertverläufe sind in der linken Hälfte des Phantoms zu sehen). Das vorgestellte Verfahren wird für verschiedene Diskretisierungsraten des Modells angewendet und die resultierenden Segmentierungsergebnisse über mehrere Diskrepanzmaße (*Hausdorff-Distanz*, *Dice-Koeffizient*, *Mittlere Oberflächendistanz* und *die Zahl falsch segmentierter Pixel*) mit den Referenzkonturen verglichen. Die Evaluation erlaubt es, Aussagen über die Segmentierungsqualität in Abhängigkeit von vorhandenen Grauwertverläufen und Rauschniveaus der Eingangsdaten sowie der Diskretisierungsrate des Modells zu machen. Exemplarisch ist die Auswertung der Mittleren Oberflächendistanz für die Segmentierung der Putamen-Region in Abb. 4 dargestellt. Die nachfolgenden Ergebnisse bestätigen sich auch unter Verwendung der übrigen Diskrepanzmaße [4].

Gegenüber schwachem Rauschen zeigt sich das Verfahren relativ unempfindlich. Grauwertverläufe in den gesuchten Regionen haben in diesem Fall nur sehr begrenzten Einfluss auf die Qualität der Ergebnisse. Ebenso zeigt sich hier eine gewisse Unempfindlichkeit gegenüber der Wahl der Diskretisierungsrate des Verfahrens. Hohe Rauschniveaus dagegen verschlechtern das Ergebnis deutlich. Zudem sind bei starkem Rauschen deutliche Unterschiede in der Segmentierungsqualität zwischen den Regionen mit und ohne Grauwertverlauf auszumachen. Bei hohen Rauschniveaus zeigt sich auch eine starke Abhängigkeit von der Diskretisierungsrate. Zu klein gewählte Raten führen zu rauschbedingten Oszillationen der Kontur, die durch die internen Glattheitskräfte nicht mehr kompensiert werden können. Schlechtere Diskretisierungsraten erfassen zwar weniger Details, liefern aber stabilere Ergebnisse.

6 Diskussion

Die Evaluationsergebnisse sowie die qualitative Beurteilung exemplarisch durchgeführter Segmentierungen auf realem Datenmaterial haben gezeigt, dass das

Abb. 4. Evaluationsergebnisse für das Putamen-Phantom am Beispiel der mittleren Oberflächendistanz



beschriebene Verfahren gut zur Lösung der gegebenen Aufgabenstellung geeignet ist. Probleme können entstehen, falls die Bilddaten von schlechter Qualität sind. Eine gute Artefaktreduktion im Vorfeld ist somit erforderlich.

Das nun angestrebte Hauptziel ist die vollständige Entwicklung und Realisierung eines Systems, welches direkt auf den dreidimensionalen Volumendaten arbeiten kann. Dieser Ansatz ist gegenüber einer schichtweisen Abarbeitung, wie sie derzeit möglich ist und in der Praxis oft eingesetzt wird, zu bevorzugen. Dabei ist unter anderem die komplexe Geometrie und Konnektivität der gesuchten subkortikalen Strukturen im Dreidimensionalen zu beachten.

Literaturverzeichnis

1. Collins DL, Neelin P, Evans AC, et al. Automatic 3D registration of MR volumetric data in standardized talairach space. *J Comput Assist Tomogr* 1994;18(2):192–205.
2. 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. Dissertation. RWTH Aachen; 2002.
3. Xu C, Prince J. Generalized gradient vector flow external forces for active contours. *Signal Processing* 1998;71(2):131–139.
4. Belitz H, Wagenknecht G, Müller H. Modellbasierte Segmentierung von MRT-Daten des menschlichen Gehirns. In: *Procs Remagener Physiktage*. VDE; 2004. p. Im Druck.
5. Lobregt S, Viergever MA. A Discrete Dynamic Contour Model. *IEEE Trans Med Imaging* 1991;14(1):12–24.
6. Zhang YJ. A survey on evaluation methods for image segmentation. *Pattern recognition* 1996;29(8):1335–1346.
7. Heimann T, Thorn M, Kunert T, et al. Empirische Vergleichsmaße für die Evaluation von Segmentierungsergebnissen. In: *Procs BVM. Informatik Aktuell*. Springer, Berlin; 2004. p. 165–169.