

Segmentierung des Femurs aus MRT-Daten mit Shape-Based Level-Sets

Claudia Dekomien¹, Martin Busch², Wolfram Teske³, Susanne Winter¹

¹Institut für Neuroinformatik, Ruhr-Universität Bochum, 44780 Bochum,

²Grönemeyer Institut für Mikrotherapie, 44799 Bochum,

³Orthopädische Universitätsklinik, Ruhr-Universität Bochum, 44791 Bochum

`Claudia.Dekomien@neuroinformatik.rub.de`

Kurzfassung. Inhalt dieser Arbeit ist die Segmentierung des Femurs aus MRT-Datensätzen mit einem Shape-based Level-Set-Ansatz. Der Algorithmus besteht aus zwei Phasen, der Modellerstellung und der Segmentierungsphase. In der Segmentierungsphase wurde ein kantenbasiertes und ein auf Intensitäten basierendes Optimierungskriterium miteinander kombiniert. Für eine lokale Verbesserung des Ergebnisses wurde zusätzlich ein Laplacian Level-Set-Verfahren angewendet. Der Femur konnte mit diesem Ansatz in drei verschiedenen MRT-Sequenzen und einem Fusionsdatensatz gut segmentiert werden.

1 Einleitung

Die automatische Segmentierung anatomischer Strukturen in medizinischen Bilddaten ist in vielen Bereichen von großem Interesse. Sie kann z.B. als Basis für weitere diagnostische Verfahren wie eine automatische Gewebeklassifikation dienen, oder aber Strukturen liefern, die zur Registrierung der Daten mit anderen Daten herangezogen werden können. Wir stellen in dieser Arbeit die modellbasierte Segmentierung des Femurs in MRT-Daten vor. Die Ergebnisse der Segmentierung sollen nachfolgend als Basis für die intraoperative Registrierung der MRT-Daten mit Ultraschalldaten dienen. Dafür ist es notwendig die Knochenoberfläche aus den Daten zu extrahieren. Während dies in CT-Daten mit schwellwertbasierten Verfahren möglich ist, erweist sich diese Aufgabe in MRT-Daten als wesentlich schwieriger. Die Registrierbarkeit von CT-Daten, sowie von MRT-Daten bei halbautomatischer Segmentierung der Knochenoberfläche konnte bereits nachgewiesen werden [1, 2].

Es existiert eine Vielzahl von Arbeiten, die sich mit MRT-Segmentierung beschäftigen [3]. Aufgrund von lückenhaften und fehlenden Bildinformation sowie überlappenden Intensitäten verschiedenerer Gewebe sind einfache, schwellwertbasierte Verfahren für die Segmentierung wenig geeignet. Die erfolgreichsten Verfahren verwenden Vorwissen in Form von Modellen für die Segmentierung [4]. Aufgrund der Flexibilität ist die Level-Set-Darstellung von Modellen besonders gut geeignet [5]. Daher haben wir uns für einen Shape-based Level-Set Ansatz [6] für die Segmentierung dreidimensionaler Knochenstrukturen entschieden. Der gewählte Algorithmus wurde bereits erfolgreich zur Segmentierung einzelner Wirbel aus CT-Daten verwendet [7].

2 Material und Methode

2.1 Daten

Von Probanden wurden dreidimensionale MRT-Daten des Knies mit verschiedenen Aufnahme Sequenzen akquiriert. Es wurden ein T1-gewichteter isotroper Datensatz (T1), ein T2-gewichteter isotroper Datensatz (T2) und ein T1-gewichteter isotroper Datensatz mit Wasseranregung (T1W) aufgenommen. Aus den beiden T1 gewichteten Daten (T1 + T1W) wurde ein fusionierter Datensatz erstellt. Hierfür wurden die Grauwerte des T1-Datensatzes zu den Grauwerten des T1W-Datensatzes addiert.

Zur Erstellung des Kniemodells standen insgesamt 16 Spiral-CT-Datensätze von Patienten und Phantomen zur Verfügung.

2.2 Datenvorverarbeitung

Alle Datensätze wurden in eine isotrope Auflösung von $0.5 \text{ mm} \times 0.5 \text{ mm} \times 0.5 \text{ mm}$ umgerechnet. Zum Ausgleich von Helligkeitsunterschieden, unter anderem aufgrund von Sensitivitätsunterschieden der Empfangsspule, wurde ein Bias Correction-Algorithmus [8] auf die MRT-Daten angewendet.

2.3 Segmentierung

Die Segmentierung des Femurs aus MRT-Daten wurde mit einem Shape-based Level-Set-Ansatz durchgeführt. Der verwendete Algorithmus basiert auf einer Modifikation der Methode von Tsai [6, 7] und besteht aus zwei Phasen, der Modellerstellung und der Segmentierungsphase.

Um ein Femur-Shape-Modell zu erstellen, wurden verschiedene Femora, mit einem halbautomatischen Schwellwertverfahren aus CT-Datensätzen segmentiert. Alle Femurobjekte wurden binarisiert und zu einander ausgerichtet. Für jedes binäre Objekt wurde eine Signed Distance Map berechnet. Aus diesen Signed Distance Maps werden entsprechend der in [6] beschriebenen Methode ein Meanshape M und k Eigenshapes E_k gebildet. Die Level-Set-Funktion L setzt sich aus M und E wie folgt zusammen:

$$L_{w,p}(\mathbf{x}) = M(T_p(\mathbf{x})) + \sum_{i=0}^k w_i E_i(T_p(\mathbf{x})). \quad (1)$$

Hierbei stellen $w = (w_0, \dots, w_k)$ die Gewichte für die $k (\leq n)$ Eigenshapes und p die Parameter für die Koordinatentransformation $T_p(\mathbf{x})$ eines Koordinatenpunktes dar. $T_p(\mathbf{x})$ beschreibt eine Rotation, eine Translation und eine Skalierung.

Die Initialisierung der Startposition für die Segmentierung wurde mit einer rigiden Landmarken-Registrierung durchgeführt. Die Level-Set-Funktion $L_{w,p}$ besteht aus zwei Regionen, einer außerhalb und einer innerhalb des Objektes. Die Objektkontur wird als Zero-Level-Set bezeichnet. Die Segmentierung erfolgt

durch Optimierung der Parameter p und w . Erfolgreiche Fehlerfunktion waren das kantenbasierte Optimierungskriterium:

$$E_{\text{edge}} = \sum_{i=0}^m f_i, \text{ mit } f_i = \begin{cases} g_i, & L_{w,p}(\mathbf{x}_i) = 0 \\ 0, & L_{w,p}(\mathbf{x}_i) \neq 0 \end{cases} \text{ und } g_i = \frac{1}{1 + \nabla I(\mathbf{x}_i)}, \quad (2)$$

wobei $\nabla I(\mathbf{x}_i)$ den Gradienten des zu segmentierenden MRT-Volumens I an der Stelle $\mathbf{x}_i = (x_1, y_i, z_i)$ darstellt, sowie das Binary-Mean-Optimierungskriterium

$$E_{\text{mean}} = -\frac{1}{2}(\mu - v). \quad (3)$$

Hierbei stellen μ und v die mittleren Grauwertintensitäten des MRT-Volumens innerhalb und außerhalb des Zero-Level-Sets dar. Die Fehlerfunktionen E_{edge} und E_{mean} wurden gleichzeitig optimiert, indem die Fehlerfunktion $E_{\text{multi}} = E_{\text{mean}}/E_{\text{edge}}$ minimiert wurde. Zur Optimierung wurde die CMA-Evolutionsstrategie [9] verwendet. Zur lokalen Verbesserung der Segmentierung wurde zusätzlich ein Laplacian Level-Set-Verfahren aus der ITK-Library angewendet.

3 Ergebnisse

In drei unterschiedlichen MRT-Sequenzen und einem Fusionsdatensatz eines Probanden wurde der Femur segmentiert. Abbildung 1 zeigt die Segmentierungsergebnisse in allen vier Datensätzen nach der Shape-based Level-Set-Segmentierung. In Abbildung 2 sind die Segmentierungsergebnisse mit zusätzlicher lokaler

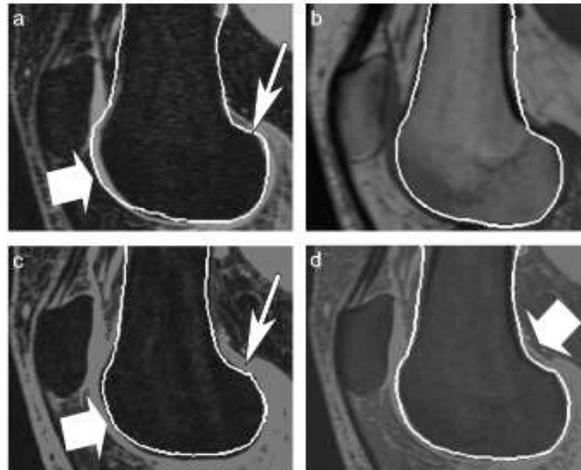


Abb. 1. Shape-based Level-Set-Segmentierung; die weiße Linie repräsentiert das Segmentierungsergebnis a) T2-gewichtete MRT-Sequenz b) T1-gewichtete MRT-Sequenz c) T1-gewichtete MRT-Sequenz mit Wasseranregung d) Fusionsdatensatz aus den in b) und c) dargestellten Datensätzen. Die Pfeile markieren Regionen, an denen das Segmentierungsergebnis noch nicht perfekt auf der Knochenoberfläche liegt.

Optimierung durch das Laplacian Level-Set-Verfahren dargestellt. In den Abbildungen 1 a) und c) ist deutlich zu erkennen, dass nach der Shape-based Level-Set Segmentierung der Knochenrand mit dem Modell noch nicht exakt erfasst wurde. Nach der lokalen Anpassung liegt das Segmentierungsergebniss besser auf dem Knochenrand (markiert durch die dicken Pfeile) und kleine spezielle Strukturen des Knochens (markiert durch die dünnen Pfeile), die nicht im Modell enthalten sind, werden erkannt. Die Rechenzeit, auf einem Intel Core 2 Duo 2,19 GHz CPU, für die Shape-based Level-Set Segmentierung lag bei ca. 2 Minuten. Die Laplacian Level-Set Segmentierung benötigt ca. 1,5 Minuten.

4 Diskussion

Der Shape-based Level-Set-Segmentierungsalgorithmus zeigt gute Resultate bei der Segmentierung des Femurs aus allen vier MRT-Datensätzen. Mit der lokalen Anpassung der Ergebnisse durch die Laplacian Level-Set-Segmentierung konnten die Resultate noch weiter verbessert werden. Dieses lokale Verfahren führt jedoch nur zu optimalen Ergebnissen, wenn das initiale Level-Set der Form des Objektes bereits stark ähnelt. Es ist daher nicht alleine einsetzbar, sondern nur als zweiter Schritt nach der modellbasierten Segmentierung.

Zusammenfassend lässt sich sagen, dass der vorgestellte Algorithmus zuverlässig den Femur aus verschiedenen Datensätzen segmentieren kann. Die Be-

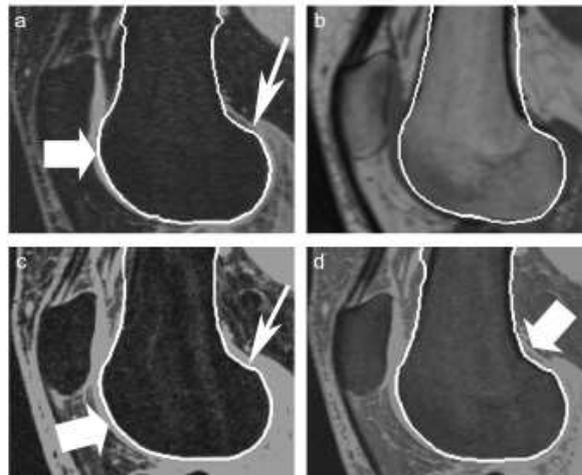


Abb. 2. Shape-based Level-Set-Segmentierung mit zusätzlicher lokaler Optimierung durch das Laplacian Level-Set-Verfahren; die weiße Linie repräsentiert das Segmentierungsergebnis a) T2-gewichtete MRT-Sequenz b) T1-gewichtete MRT-Sequenz c) T1-gewichtete MRT-Sequenz mit Wasseranregung d) Fusionsdatensatz aus den in b) und c) dargestellten Datensätzen. Die Pfeile markieren Stellen der Segmentierung, die sich durch die lokale Optimierung verbessert haben.

nutzerinteraktion war sehr gering und die Rechenzeit lag für präoperative Prozesse in einem vertretbaren Rahmen. Die Segmentierungsergebnisse können für MRT-Registrierungen mit verschiedenen anderen Modalitäten wie Ultraschall, CT oder auch 2D-Röntgenbildern verwendet werden. Außerdem lassen sich dreidimensionale Modelle des Femurs erstellen, die auch für eine OP-Planungen zur Verfügung stehen können.

Weitere geplante Arbeiten umfassen unter anderem eine Erweiterung des Modells um eine größere Zahl von Einzelmodellen. Dadurch können mehr Formvariationen erfasst werden. Außerdem soll im nächsten Schritt die Initialisierung der Startposition der Segmentierung mittels einer automatischen Landmarkendetektion durchgeführt werden. Das reduziert die Benutzerinteraktion weiter und trägt wesentlich zur Einsetzbarkeit des Verfahrens in der Praxis bei.

Literaturverzeichnis

1. Winter S, Brendel B, et al. Registration of CT and intraoperative 3D ultrasound images of the spine using evolutionary and gradient-based methods. *IEEE Trans Evol Comput.* 2008;12(3):284–296.
2. Winter S, Dekomien C, et al. Registrierung von intraoperativem 3D-Ultraschall mit präoperativen MRT-Daten für die computergestützte orthopädische Chirurgie. *Z Orthopäd Unfallchir.* 2007;145:586–590.
3. Fripp J, Crozier S, et al. Automatic segmentation of the bone and extraction of the bone cartilage interface from magnetic resonance images of the knee. *J Comput Phys.* 2007;52:1617–1631.
4. McInerney T, Terzopoulos D. Deformable models in medical image analysis: A survey. *Med Image Anal.* 1996;1(2):91–108.
5. Osher S, Fedkiw RP. Level set methods: An overview and some recent results. *J Comput Phys.* 2001;169(2):463–502.
6. Tsai A, Yezzi A, et al. A shape-based approach to the segmentation of medical imagery using level sets. *IEEE Trans Med Imaging.* 2003;22(2):137–154.
7. Dekomien C, Winter S. Segmentierung einzelner Wirbel in dreidimensionalen CT-Daten mit einem modelbasierten Level Set Ansatz. *Biomed Tech.* 2007;52.
8. Vovk U, Pernus F, et al. MRI intensity inhomogeneity correction by combining intensity and spatial information. *Phys Med Biol.* 2004;49(17):4119–4133.
9. Hansen N, Kern S. Evaluating the CMA evolution strategy on multimodal test functions. *Parall Prob Sol Nature.* 2004;3242:282–291.