

Vollautomatische Segmentierung der Prostata aus 3D-Ultraschallbildern

Tobias Heimann, Tobias Simpfendörfer, Matthias Baumhauer,
Hans-Peter Meinzer

Abteilung für Medizinische und Biologische Informatik, DKFZ Heidelberg
t.heimann@dkfz.de

Kurzfassung. Diese Arbeit beschreibt ein modellbasiertes Verfahren zur Segmentierung der Prostata aus 3D-Ultraschalldaten. Kern der Methode ist ein statistisches Formmodell, das auf Beispieldaten der Prostata trainiert wird. Erster Schritt der Segmentierung ist ein evolutionärer Algorithmus, mit dem das Modell grob im zu segmentierenden Bild positioniert wird. Für die darauf folgende lokale Suche wurden mehrere Varianten des Algorithmus evaluiert, unter anderem Ausreißer-Unterdrückung, freie Deformation und Gewichtung der verwendeten Erscheinungsmodelle nach ihrer Zuverlässigkeit. Alle Varianten wurden auf 35 Ultraschallbildern getestet und mit manuellen Referenzsegmentierungen verglichen. Die beste Variante erreichte eine durchschnittliche Oberflächenabweichung von 1.1 mm.

1 Einleitung

Bei Tumorerkrankungen der Prostata ist die vollständige Entfernung des Organs (Prostatektomie) die erfolgversprechendste Therapie. Eine minimalinvasive Operationsstrategie verringert hierbei das Risiko für Folgeerscheinungen wie Inkontinenz und Impotenz, ist ohne Unterstützung durch OP-Planungs- und Navigationssysteme aber schwieriger durchzuführen. Um den Chirurgen bei diesem Eingriff zu unterstützen, entwickeln wir in unserer Gruppe ein Navigationssystem, das Risikostrukturen wie Tumor und Harnleiter in das Kamerabild aus dem Endoskop einblenden kann. Dafür müssen die präoperativen Planungsdaten aus dem CT mit intraoperativen transrektalen Ultraschalldaten (TRUS) registriert werden. Anstatt CT und TRUS Bilder direkt zu registrieren, schlagen wir vor, die Prostataoberfläche aus den TRUS-Daten zu extrahieren und auf die entsprechende Oberfläche aus den CT-Daten abzubilden. Während die Segmentierung der Prostata aus den CT-Daten präoperativ erfolgt und zeitlich unkritisch ist, muss die Segmentierung aus den TRUS-Daten im OP erfolgen und sollte so schnell und automatisch wie möglich vonstatten gehen. Zu diesem Zweck stellen wir in dieser Arbeit ein System zur vollautomatischen Segmentierung der Prostata mit Hilfe statistischer Formmodelle vor, welche sich durch ihre Robustheit besonders gut zur Analyse der verrauschten TRUS-Bilder eignen.

Während für die Segmentierung der Prostata aus CT-Bildern teilweise einfache Techniken wie Regionenwachstumsverfahren angewendet werden können [1],

müssen für Ultraschallbilder mit ihrem niedrigen Signal-Rausch-Verhältnis robustere Verfahren verwendet werden. So nutzen sowohl Hodge et al. [2] als auch Zhan und Shen [3] statistische Formmodelle für diese Aufgabe. Eine große Rolle spielen dabei die verwendeten Erscheinungsmodelle, die das Formmodell an die Bilddaten anpassen. In [2] wird die Prostata mit einem ad-hoc Ansatz (dunkle Grauwerte innerhalb, helle außerhalb) vom Hintergrund unterschieden, ein Training findet nicht statt. In [3] dagegen wird eine Gabor Filterbank zur Merkmalsberechnung genutzt und die Ergebnisse an eine Support Vector Machine zur Klassifizierung weiter geleitet.

Während die erste Variante ohne Training das Problem sehr vereinfacht, erscheint die zweite Methode relativ komplex. In dieser Arbeit gehen wir einen Mittelweg zwischen beiden Methoden, indem wir bewährte Grauwertprofile in Verbindung mit einem kNN-Klassifikator nutzen. Bei der Modellsuche in neuen Bilddaten evaluieren wir sowohl Algorithmen mit harten Formbeschränkungen (wie in [2] verwendet) als auch Methoden mit freier Deformation (wie in [3] genutzt).

2 Material und Methoden

Für diese Arbeit wurden 35 TRUS Volumen verwendet, die eine Auflösung von 430x280x200 bis 480x430x250 Voxeln aufweisen. Die Auflösung variiert zwischen 0.15 und 0.2 mm in einer Schicht bei 0.2 bis 0.25 mm Schichtabstand. Zur Glättung der Bilder wurde ein 7x7x7 Median Filter benutzt. Zum Training der Formmodelle und zur Validierung der Ergebnisse hat ein Medizinstudent alle Bilder mit einem interaktiven Oberflächenverfahren segmentiert.

Der erste Schritt zur Erstellung des Formmodells ist die Bestimmung von korrespondierenden Landmarken auf den so erstellten Oberflächen. Hierzu setzen wir ein automatisches Verfahren ein, das auf der Minimierung der Beschreibungslänge (MDL) des Formmodells basiert [4]. Eine Hauptkomponenten-Analyse der so bestimmten Landmarkenpositionen zeigt die größten Variationsrichtungen der Trainingsmenge, die für das statistische Formmodell verwendet werden (Abb. 1).

Zur Beschreibung der Erscheinung wurden an jeder Landmarke in allen Trainingsbildern Grauwert-Profile senkrecht zur Oberfläche eingelesen. Diese Profile wurden abgeleitet und die entstandenen Gradienten auf eine absolute Summe von 1 normalisiert. Die 9 Werte langen Profile wurden in zwei unterschiedlichen Modellen verwendet. Für das erste Modell wurden alle Trainingsprofile mit einer Kovarianzmatrix modelliert. Während der Modellsuche können Kandidatenprofile somit über die entsprechende Mahalanobisdistanz auf ihre Ähnlichkeit zu den trainierten Profilen überprüft werden. Für das zweite Modell wurden zusätzlich zu den Profilen an den korrekten Landmarkenpositionen auch Profile an nach innen und außen verschobenen Positionen eingelesen. Beide Gruppen wurden für das Training eines kNN-Klassifikators genutzt, der während der Modellsuche die Kandidatenprofile so als „Prostatakantur“ oder „Verschoben“ klassifizieren kann. Um das Formmodell auf ein neues Ultraschallbild anzupassen, wurde zuerst eine grobe Initialisierung durchgeführt. Hierzu wurde ein evolutionärer Algorithmus

verwendet, der Position, Skalierung und die 5 größten Variationsrichtungen des Modells optimiert. Die Güte einer Einzellösung wurde durch Kombination der Antworten von allen Erscheinungsmodellen bestimmt. Nach einer konstanten Anzahl von 20 Iterationen (über 500 Einzellösungen) wurde das bis dahin beste Ergebnis als Ausgangspunkt für eine lokale Suche verwendet.

Die lokale Suche wurde in den folgenden Variationen ausgeführt:

- *Def*: Eine deformierbare Oberfläche ist an das statistische Formmodell gekoppelt. Die Oberfläche versucht zu jedem Zeitpunkt eine ähnliche Form wie vom Modell vorgegeben anzunehmen, gleichzeitig ziehen die Erscheinungsmodelle ihre Landmarken zu den bestpassenden Positionen in den Bilddaten [5]. Durch dieses System wird eine freie Deformation (zusätzlich zu den vorgegebenen Variationen des Formmodells) ermöglicht. Um die Oberfläche zu stabilisieren, werden Ausreißer in den Kräften der Erscheinungsmodelle durch eine optimale Oberflächensuche mit festen Randbedingungen unterbunden. Diese Randbedingungen setzen fest, dass die Bewegung benachbarter Landmarken nur einen festgelegten Betrag voneinander abweichen darf.

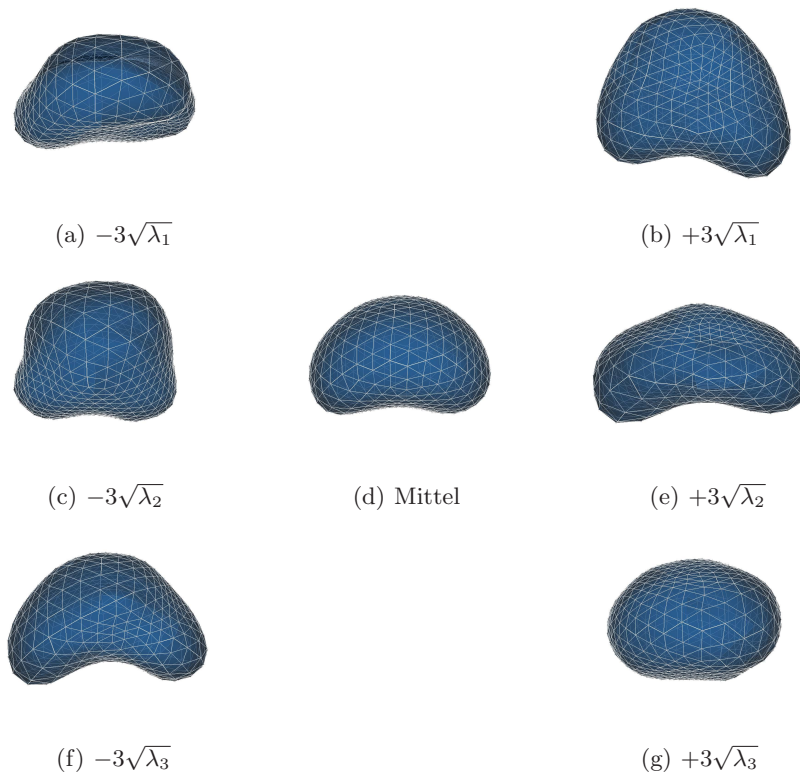


Abb. 1. Haupt-Variationsrichtungen des Formmodells der Prostata. Bild (d) zeigt die mittlere Form, die anderen Bilder jeweils eine Variation um drei Standardabweichungen

- *App-PW*: Wie *Def*, aber die Kräfte der Erscheinungsmodelle werden mit ihrer Zuverlässigkeit gewichtet, so dass unzuverlässige Erscheinungsmodelle die Oberfläche nicht viel verformen können. Die Zuverlässigkeit eines Erscheinungsmodells wird dabei durch einen Testlauf auf den Trainingsdaten festgestellt.
- *No-OS*: Wie *Def*, aber die Ausreißer-Unterdrückung durch optimale Oberflächensuche wird nicht angewendet.
- *No-FD*: Wie *Def*, aber die deformierbare Oberfläche muss sich immer genau an das Formmodell halten. Es gibt somit keine freie Deformation.
- *App-Std*: Wie *Def*, aber das Standard-Erscheinungsmodell mit Kovarianzmatrix wurde verwendet. Alle anderen Varianten verwenden das nicht-lineare kNN-Modell.

3 Ergebnisse

Die beschriebenen Suchvarianten wurden mit einem „Leave-5-out“ Verfahren auf den zur Verfügung stehenden Datensätzen getestet. Dabei wurden sowohl Formals auch Erscheinungsmodell immer auf 30 Datensätzen trainiert und auf den ausgelassenen 5 getestet. Die erzielten Segmentierungen wurden mit den manuellen Referenzsegmentierungen verglichen und die durchschnittliche Oberflächenabweichung bestimmt. Für die unterschiedlichen Suchvarianten beträgt diese:

Def: 1.2 mm, *App-PW*: 1.1 mm, *No-OS*: 1.7 mm, *No-FD*: 1.2 mm, *App-Std*: 1.6 mm. Abbildung 3 zeigt die entsprechenden Boxplots, Abbildung 3 ein repräsentatives Ergebnis. Um die Ergebnisse besser interpretieren zu können, hat der Medizinstudent, der die Referenzsegmentierungen erstellt hat, dieselben Daten zu einem späteren Zeitpunkt noch einmal segmentiert. Ein Vergleich mit den ersten Ergebnissen ergab eine durchschnittliche Oberflächenabweichung von 0.9 mm.

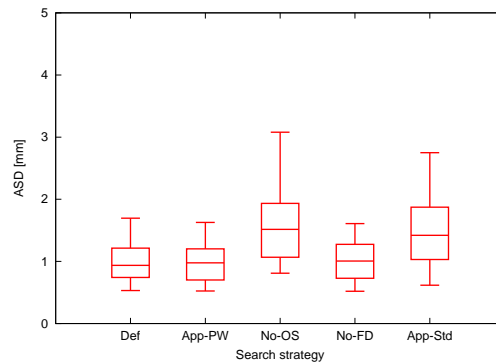



Abb. 2. Durchschnittliche Oberflächenabweichung zwischen den erzielten Ergebnissen und Referenzsegmentierungen für alle getesteten Suchvarianten

Abb. 3. Repräsentatives Segmentierungsergebnis (Median aller Ergebnisse) für Suchvariante *Def* (helle Kontur). Die manuelle Referenzsegmentierung ist zum Vergleich als dunkle Kontur angegeben



4 Diskussion

Die Ergebnisse zeigen, dass eine robuste Ausreißer-Unterdrückung und ein zuverlässiges Erscheinungsmodell die Qualität der Segmentierung auf Ultraschallbildern deutlich steigern können, was auf das schlechte Signal-Rausch-Verhältnis der Daten zurückzuführen ist. Zusätzliche freie Deformation brachte in diesen Experimenten keinen Vorteil, da die Prostata nur eine relativ geringe Formvariation aufweist und durch das Formmodell ausreichend gut modelliert werden kann. Die Gewichtung der Erscheinungsmodelle konnte die Ergebnisse noch leicht verbessern.

Die Segmentierung eines 3D-Volumens dauerte mit dem vorgestellten Verfahren weniger als zwei Minuten, was für die geplante Anwendung zur initialen Registrierung ausreichend schnell ist. Ein Vorteil des modellbasierten Ansatzes ist, dass die Segmentierung in einem Live-Ultraschallbild sehr schnell aktualisiert werden kann (da wenige Iterationen der lokalen Suche ausreichen) und somit die Prostata praktisch in Echtzeit verfolgt werden kann.

Literaturverzeichnis

1. Mazonakis M, Damilakis J, Varveris H, et al. Image segmentation in treatment planning for prostate cancer using the region growing technique. *Br J Radiol.* 2001;74(879):243–8.
2. Hodge AC, Fenster A, Downey DB, et al. Prostate boundary segmentation from ultrasound images using 2D active shape models: Optimisation and extension to 3D. *Comput Methods Programs Biomed.* 2006;84(2-3):99–113.
3. Zhan Y, Shen D. Deformable segmentation of 3-D ultrasound prostate images using statistical texture matching method. *IEEE Trans Med Imaging.* 2006;25:256–72.
4. Heimann T, Wolf I, Williams TG, et al. 3D Active shape models using gradient descent optimization of description length. *Inf Process Med Imaging.* 2005;19:566–77.
5. Heimann T, Münzing S, Meinzer HP, et al. A shape-guided deformable model with evolutionary algorithm initialization for 3D soft tissue segmentation. *Inf Process Med Imaging.* 2007;20:1–12.