

# Segmentierung der Prostata aus MRT-Bilddaten mittels eines statistischen Modells

Stefan Dänzer<sup>1,5</sup>, Stefan Freitag<sup>2</sup>, Dirk Beyersdorff<sup>3</sup>, Markus Scholz<sup>4</sup>,  
Oliver Burgert<sup>1</sup>, Jens-Uwe Stolzenburg<sup>5</sup>

<sup>1</sup>ICCAS, Universität Leipzig

<sup>2</sup>HTWK, Leipzig

<sup>3</sup>Klinik für Radiologie, Charite Berlin

<sup>4</sup>IMISE, Leipzig

<sup>5</sup>Klinik für Urologie, Universitätsklinikum Leipzig

stefan.daenzer@gmail.com

**Kurzfassung.** In dieser Arbeit wird ein semi-automatisches Verfahren zur Segmentierung der Prostata in MRT Bildern vorgestellt. Dieses basiert auf der Kombination eines statistischen Formmodells mit einem lokalen statistischen Erscheinungsmodell, welche beide aus handsegmentierten Trainingsdaten generiert werden. Eine neue, robuste Kostenfunktion auf Basis eines Shrinkage-Schätzers wird an 10 Datensätzen evaluiert. Dabei zeigt sich für das Segmentierungsergebnis mit Shrinkage-Schätzer eine mittlere Oberflächenabweichung von 1.77 mm, während die verbreitet eingesetzte Mahalanobis Distanz eine Abweichung von 2.67 mm erreicht.

## 1 Einleitung

Die Visualisierung und Modellierung von anatomischen Strukturen findet zunehmend Anwendung in der Therapieplanung und der computerassistierten Chirurgie. Um Strukturen patientenindividuell visualisieren zu können, müssen diese in radiologischen Aufnahmen zunächst segmentiert werden. Eine detailgetreue manuelle Segmentierung ist jedoch sehr zeitaufwändig. Ein akkurates Segmentierungsverfahren, welches möglichst wenig Interaktion benötigt stellt hier einen entscheidenden Vorteil dar. In dieser Arbeit wird ein modellbasiertes Verfahren zur Segmentierung vorgestellt, mit welchem anatomische Strukturen mit minimaler Benutzerinteraktion erkannt werden können.

## 2 Material und Methoden

### 2.1 Stand der Forschung

In der Literatur finden sich mehrere Publikationen zum Thema der Segmentierung der Prostata aus MRT Aufnahmen. Martin verwendet ein Verfahren, welches auf einem statistischen Formmodell (SSM) mit einer Beschränkung der

Deformierung basiert [1]. Klein greift auf ein Verfahren basierend auf Atlas Matching mit einer Mutual Information Kostenfunktion zurück [2]. Toth entwickelte ein Verfahren basierend auf SSM kombiniert mit einer combined Mutual Information Kostenfunktion [3].

## 2.2 Beschreibung der verwendeten Methoden

Das vorgestellte Verfahren basiert auf einem statistischen Form- und Erscheinungsmodell, welches aus 87 MRT Aufnahmen von verschiedenen Patienten erstellt wurde. Ein deformierbares Oberflächenmodell und ein graphbasiertes Suchverfahren in Kombination mit einer Kostenfunktion werden verwendet um das Modell iterativ an die gesuchte Struktur anzupassen. Für die Generierung des Formmodells wurde auf einen bereits implementierten Algorithmus von Heimann [4] zurückgegriffen. Die iterative Anpassung erfolgt gemäß der Methode in [5], durch ein deformierbares Modell, welches den Lagrange'schen Bewegungsgleichungen zugrunde liegt. Dabei wird eine Oberflächentriangulation  $M = (V, E)$  mit Punkten  $p, q \in V$  und Kanten  $[p, q] \in E$  an das Bildvolumen angepasst. Jeder der  $n$  Punkte  $p_i \in V$ , ( $i = 1, \dots, n$ ) korrespondiert hierbei zu einem Punkt  $\tilde{p}_i$ , ( $i = 1, \dots, n$ ) im statistischen Formmodell. Innere Kräfte  $F_{\text{int}}$  und äußere Kräfte  $F_{\text{ext}}$  verformen die Triangulation iterativ und wirken dabei explizit auf jeden Punkt  $p_i \in V$

$$p_i^{t+1} = p_i^t + F_{\text{int}}(p_i^t) + F_{\text{ext}}(p_i^t) \quad (1)$$

Die inneren Kräfte setzen sich aus zwei voneinander unabhängigen Teilkräften zusammen. Die Spannkkräfte  $F_T$  gleichen Unterschiede in den Kantenlängen aus. Die Steifekräfte  $F_R$  beheben Differenzen bei Winkeln benachbarter Flächen. Beide Kräfte werden für jeden Punkt  $p_i \in V$  im geometrischen Modell unabhängig voneinander berechnet und addiert. Äußere Kräfte verformen das geometrische Modell so, dass es möglichst gut an das zugrunde liegende Bildvolumen angepasst wird. Dazu wird eine Kostenfunktion eingeführt, welche für jeden Punkt  $p_i \in V$  die Abweichung von der Oberfläche bzw. die Anpassungskosten von  $p_i$  berechnet. Zu diesem Zweck, werden sowohl für jeden Punkt  $p_i \in V$ , als auch an  $K$  nach innen und außen verschobenen Positionen die Kosten berechnet. Dadurch erhält man für jeden Punkt  $2K + 1$  Stellen  $p_{ik}$ , welche äquidistant mit dem Abstand  $d$  entlang des Normalenvektor  $N(p_i)$  verteilt sind

$$p_{ik} = p_i + k * d * N(p_i) \quad k \in [-K; K] \quad (2)$$

Unter den  $2K + 1$  Punkten kann nun der optimale Punkt  $s(p_i)$  mit minimalen Kosten bestimmt werden. Die äußeren Kräfte sind als Zugkräfte einer Linearen Feder definiert, welche die  $p_i \in V$  in Richtung ihrer optimalen Position  $s(p_i)$  verschieben

$$F_{\text{ext}}(p_i) = \gamma(s(p_i) - p_i) \quad (3)$$

$\gamma$  stellt einen Parameter zur Regulierung der Stärke der äußeren Kräfte dar. Zur Bestimmung der optimalen Verschiebungen  $s(p_i)$  aller Punkte  $p_i$  des geometrischen Modells wurde die Methode von Li et al. [6] verwendet. Dabei wird das

beschriebene Problem in das Problem des Findens eines Minimum s-t-Schnitt in einem gerichteten Graphen umgewandelt. Das Ergebnis des Verfahrens liefert eine Konstellation optimaler Verschiebungen  $s(p_1), \dots, s(p_n)$ , welche zusätzlich noch die Bedingungen erfüllt, dass sich benachbarte Punkte  $p_i, p_j \in V$  in ihrer optimalen Verschiebung  $s(p_i), s(p_j)$  um nicht mehr als ein vorher festgelegtes  $\Delta k$  unterscheiden dürfen.

Als Grundlage zur Modellierung einer Kostenfunktion im Zusammenhang mit statistischen Formmodellen zählen die Grauwertprofile, welche bereits 1993 von Cootes [7] eingeführt wurden. Dazu wird entlang der Normalen des betrachteten Punktes ein Grauwertprofil  $g$  abgetastet. Der Grundgedanke bestand darin, dass die Grauwertprofile näherungsweise einer multivariaten Gauß-Verteilung unterliegen sollten. Um diese zu modellieren wurde zu jeder Landmarke  $p_i$  in jedem der  $J$  Trainingsdatensätze das Profil  $g_{ij}$  abgetastet, sodass durch den Mittelwert  $\bar{g}_i$  und die empirische Kovarianzmatrix  $\Sigma_i$  die Verteilung der Profile für die  $i$ -te Landmarke geschätzt werden konnte. Auf dieser Grundlage lässt sich schließlich für jedes weitere Profil  $g$  die Wahrscheinlichkeit  $P_i(g)$ , dass  $g$  zur Verteilung der Profile der  $i$ -ten Landmarke gehört, bestimmen

$$P_i(g) = e^{-\frac{1}{2}D_{M,i}(g)} \quad D_{M,i}(g) = (g - \bar{g}_i)\Sigma_i^{-1}(g - \bar{g}_i)^T \quad (4)$$

Wobei  $D_{M,i}(g)$  die Mahalanobisdistanz des Profils  $g$  zur Stichprobe der  $i$ -ten Landmarke bestimmt.

Um das Verfahren der lokalen Suche stabiler zu machen, erfolgt die Berechnung anhand eines Multi Resolution Approach. Bei jedem Downsampling des Originalbildes, werden zusätzlich bei jeder Halbierung der Auflösung die Abstände  $d$  der Proben entlang jedes Profils verdoppelt. Ein bekanntes Problem der Mahalanobisdistanz besteht darin, dass die Kovarianzmatrix und der Erwartungswertvektor für kleine Stichproben stark fehleranfällig für Ausreißer sind. Um diesen Effekt zu mindern und somit auch für nicht so mächtige Trainingsmengen noch eine verlässliche Kostenfunktion zu erhalten wurden Shrinkage-Schätzer aus [8] für die neue Kostenfunktion verwendet. Durch den Einsatz dieser Schätzer für die Kovarianzmatrix und den Erwartungswertvektor wird die Berechnung wesentlich weniger anfällig für Ausreißer. Dabei werden die Schätzer für Erwartungswertvektor  $\hat{\mu}_{\text{shr}}$  und Kovarianzmatrix  $\hat{\Sigma}_{\text{shr}}$  mit Hilfe der traditionellen Schätzer  $\hat{\mu}$  sowie  $\hat{\Sigma}$  bestimmt. Der Schätzwert für den Erwartungswertvektor setzt sich als gewichtetes Mittel aus  $\hat{\mu}$  und  $b$  zusammen

$$\hat{\mu}_{\text{shr}} = (1 - \alpha) * \hat{\mu} + \alpha * b \quad b = \frac{1}{N} \sum_{i=1}^N \hat{\mu}_i * \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \quad (5)$$

In [8] wurde gezeigt, dass sich die optimale Gewichtung  $\alpha$  durch

$$\alpha = \frac{1}{T} * \frac{N\bar{\lambda} - 2\lambda_{\text{max}}}{(\hat{\mu} - b)^T(\hat{\mu} - b)} \quad (6)$$

berechnen lässt, wobei  $\lambda_{\text{max}}$  den größten Eigenwert des Kovarianzschätzwertes  $\hat{\Sigma}$  und  $\bar{\lambda}$  den Durchschnitt über alle Eigenwerte darstellt. Die Berechnung des

**Tabelle 1.** Mittlerer Fehler  $ASD_{\text{mean}}$  und Root Mean Square Fehler RMS über alle Segmentierungen mit Mahalanobisdistanz (Mahal) und Shrinkage Schätzer (Shr).

	Mahal $ASD_{\text{mean}}$	Mahal RMS	Shr $ASD_{\text{mean}}$	Shr RMS
Minimum	1.664	1.9864	1.1675	1.4766
Unteres Quartil	2.2702	2.6115	1.549	1.9282
Median	2.6657	3.2821	1.7708	2.1847
Oberes Quartil	2.9124	3.495	2.223	2.7645
Maximum	3.35	3.8769	2.4822	2.9494

Shrinkage-Schätzers für die Kovarianzmatrix erfolgt ebenfalls durch ein gewichtetes Mittel aus traditionellem Schätzer  $\hat{\Sigma}$  und der Diagonalmatrix  $C$

$$\hat{\Sigma}_{\text{shr}} = (1 - \beta) * \hat{\Sigma} + \beta * C \quad C = \frac{1}{N} \sum_{n=1}^N \hat{\lambda}_n * E_N \quad (7)$$

Mit  $E_N$  als Einheitsmatrix mit Rang  $N$ , lässt sich die optimale Wichtung  $\beta$ , wie in [8] gezeigt, folgendermaßen berechnen

$$\beta = \frac{1}{J} * \frac{\frac{1}{J} \sum_{j=1}^J \text{Spur} \left\{ (g_j g_j' - \hat{\Sigma})^2 \right\}}{\text{Spur} \left\{ (\hat{\Sigma} - C)^2 \right\}} \quad (8)$$

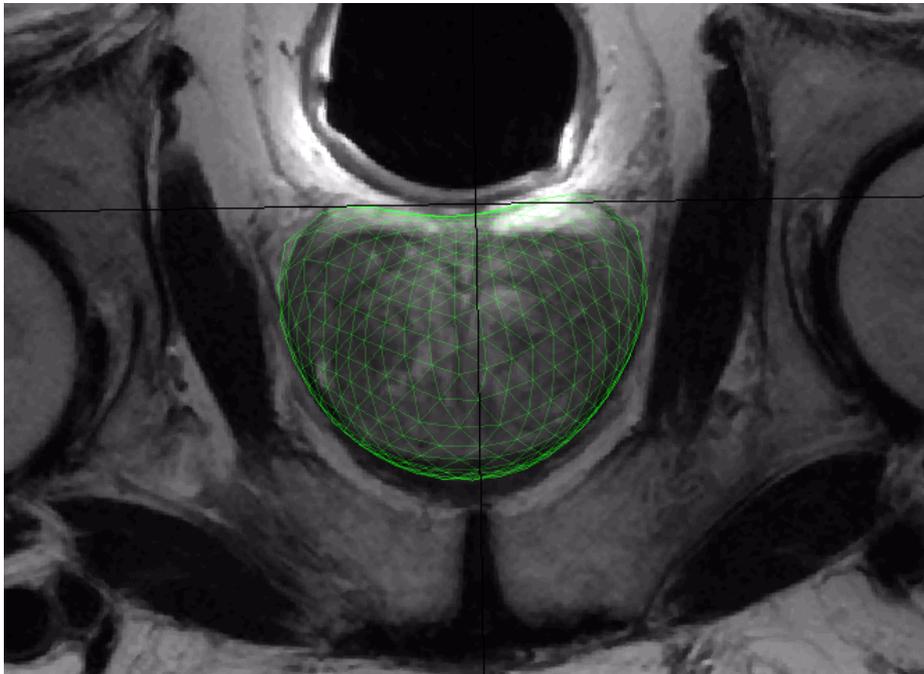
Sowohl  $\alpha$  als auch  $\beta$  beschränkt man auf das Intervall  $[0, 1]$ . Die Shrinkage-Schätzwerte  $\mu_{\text{shr}}$  und  $\Sigma_{\text{shr}}$  werden in Gleichung 4 für  $\bar{g}_i$  bzw.  $\Sigma_i$  eingesetzt, zur Berechnung der Anpassungskosten angewandt.

### 3 Ergebnisse

Im Zuge der Validierung wurde die Genauigkeit der Segmentierungsmethode mit den jeweiligen Kostenfunktionen an 10 MRT Bilddatensätzen gemessen. Ein Segmentierungsergebnis ist in Abb. 1 dargestellt. Die Abweichungen der Segmentierungen zu den handsegmentierten Referenzen sind in Tabelle 1 dargestellt.

### 4 Diskussion

In dieser Arbeit wurde ein Verfahren zur semi-automatischen Segmentierung von Organkonturen vorgestellt und anhand MRT Bildern der Prostata validiert. Das Verfahren beruht auf einer Kombination von statistischem Formmodell, statistischen Erscheinungsmodell und eines deformierbaren Modells. Der entscheidende Forschungsbeitrag stellt hierbei neben dem Segmentierungsergebnis, die Evaluierung einer neuen, robusten Kostenfunktion dar, welche der herkömmlichen Mahalanobisdistanz überlegen ist.

**Abb. 1.** Exmpl. Segmentierung unter Verwendung des Shrinkage Schätzers.

## Literaturverzeichnis

1. Martin S, Troccaz J, Daanenc V. Automated segmentation of the prostate in 3D MR images using a probabilistic atlas and a spatially constrained deformable model. *Med Phys.* 2010;37(4):1579–90.
2. Klein S, van der Heide UA, Lips IM, et al. Automatic segmentation of the prostate in 3D MR images by atlas matching using localized mutual information. *Med Phys.* 2008;35(4):1407–17.
3. Toth R, Chappelow J, Rosen M, et al. Multi-attribute non-initializing texture reconstruction based active shape model. In: *Proc MICCAI*. vol. 11; 2008. p. 653–661.
4. Heimann T, Wolf I, Williams T, et al.; Springer. 3D active shape models using gradient descent optimization of description length. *Proc Inf Process Med Imaging*. 2005; p. 566–77.
5. Heimann T, Münzing S, Meinzer HP, et al.; Springer. A shape-guided deformable model with evolutionary algorithm initialization for 3D soft tissue segmentation. *Proc Inf Process Med Imaging*. 2007; p. 1–12.
6. Li K, Millington S, Wu X, et al.; Springer. Simultaneous segmentation of multiple closed surfaces using optimal graph searching. *Proc Inf Process Med Imaging*. 2005; p. 406–417.
7. Cootes T, Taylor C. Active shape model search using local grey-level models: A quantitative evaluation. In: *Proc BMVC*; 1993. p. 639–48.
8. Meucci A. *Risk and Asset Allocation*. Springer Verlag; 2005.