

Ein wissensbasiertes dreidimensionales Formmodell für die Segmentierung von organischen Strukturen

Michael Kohnen, Andreas H. Mahnken, Jörg Kesten, Rolf W. Günther und Berthold B. Wein

Klinik für Radiologische Diagnostik
Rheinisch-Westfälische Technische Hochschule (RWTH), 52057 Aachen
Email: kohnen@rad.rwth-aachen.de

Zusammenfassung. Ein dreidimensionales wissensbasiertes Modell für die vollautomatische Segmentierung von organischen Strukturen in CT- und MR- Datensätzen ist entwickelt worden. Die notwendigen Trainingsdaten des Modells werden anhand von semiautomatisch erstellten Voxeldatensätzen der zu segmentierenden Strukturen erzeugt. Oberflächen-triangulationen der Voxeldatensätze dienen als Eingabedaten für eine Hauptkomponentenanalyse, so dass die charakteristischen Formvariationen durch eine stark reduzierte Anzahl von Parametern darstellbar sind. Neben dem so berechneten Formmodell wird die Bildinformation im Kantenbereich der Trainingsobjekte durch Grauwertprofile modelliert. Hier wird ebenfalls durch eine Hauptkomponentenanalyse der Grauwertprofile ein durch wenige Parameter darstellbares flexibles Profilmodell erstellt. Die Optimierung des Modells erfolgt durch iteratives Anpassen der Profilmodelle an die Bildregion unter Erhaltung einer plausiblen Objektform durch das Formmodell. Durch diese intensive Verwendung von Vorwissen über Form und Bildstruktur wird eine zuverlässige Segmentierung organischer Strukturen ermöglicht.

1 Einleitung

In der medizinischen Bildverarbeitung sind wissensbasierte Ansätze für eine zuverlässige Segmentierung notwendig. Ein valides vollautomatisches 3D-Segmentierungsverfahren kann ein wichtiges Werkzeug für die medizinische Diagnostik von CT- und MRT-Datensätzen sein. Solche Verfahren können wichtige Daten zur Diagnoseunterstützung, wie z.B. Volumenangaben, liefern. Die nicht-Interaktivität der Segmentierung spielt hier für die medizinische Praxis eine entscheidende Rolle.

Das vorgestellte 3D-Segmentierungsverfahren basiert auf dem zweidimensionalen Active Shape Model Verfahren von COOTES ET. AL. [1][2]. Es handelt sich hierbei um ein statistisches Modell, das versucht, mittels Hauptkomponentenanalyse von Trainingsdaten, komplexe Form- und Bildinformation durch eine geringe Anzahl von relevanten Parametern zu beschreiben.

2 Erstellung der Trainingsdaten

Grundlage für die Erstellung der Trainingsdaten bilden CT-Datensätze von Milz und Niere. Die relevanten Regionen wurden dazu aus einem größeren Abdomen-CT-Datensatz extrahiert. Die Markierung der zur Milz bzw. Niere gehörenden Voxel erfolgt semiautomatisch. Dazu wurde eine dreidimensionale Variante der hierarchischen Wasserscheidentransformation [3] verwendet, die es ermöglicht, das betreffende Organ durch eine geringe Anzahl von Wasserscheidenregionen darzustellen, welche leicht durch manuelles Markieren zum vollständigen Organ zusammengefügt werden können.

Zur Berechnung des Modells wird aus den generierten Voxeldatensätzen jeweils eine Oberflächentriangulation berechnet. Die Triangulationen, müssen jedoch zwei Bedingungen erfüllen:

- Jede Triangulation muss die gleiche Anzahl von Punkten besitzen.
- Die Punkte der verschiedenen Triangulationen müssen eindeutig einander zugeordnet werden können.

Dazu wird eine triangulierte Einheitskugel auf jeden Voxeldatensatz der Trainingsdatenmenge abgebildet. Die Ausrichtung der Kugel wird anhand der Hauptträgheitsachsen und des Schwerpunktes des Voxeldatensatzes vorgenommen.

3 Berechnung des Modells

Die so berechneten Oberflächentriangulationen aller Voxeldatensätze der Trainingsdatenmenge dienen als Berechnungsgrundlage für das Formmodell als auch für die Grauwertmodelle.

3.1 Berechnung des Formmodells

Jedes Element der Trainingsdatenmenge kann somit durch die Koordinaten der n Knotenpunkte als $3n$ -Tupel $\mathbf{x} = (x_1, y_1, z_1, \dots, x_n, y_n, z_n)^T$ dargestellt werden. Die so berechneten Merkmalsvektoren bilden eine Verteilung in einem $3n$ dimensionalen Merkmalsraum. Durch eine Hauptkomponentenanalyse dieser Verteilung kann die Anzahl der Dimensionen und damit der relevanten Parameter stark reduziert werden. Dies wird durch Berechnung der Kovarianzmatrix

$$\mathbf{S} = \frac{1}{s-1} \sum_{i=1}^s (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (1)$$

sowie deren Eigenvektoren ϕ_i und korrespondierenden Eigenwerten λ_i (in sortierter Folge, so dass $\lambda_i \geq \lambda_{i+1}$) erreicht.

Die Eigenvektoren bilden die Hauptträgheitsachsen der Verteilung. Dadurch lässt sich jedes Element \mathbf{x} der Trainingsdatenmenge durch eine Linearkombination der ersten t Eigenvektoren approximieren:

$$\mathbf{x} \approx \Phi \mathbf{b}, \quad \text{mit } \Phi = (\phi_1 | \phi_2 | \dots | \phi_t), \quad \mathbf{b} = \Phi^T (\mathbf{x} - \bar{\mathbf{x}}) \quad (2)$$

Jeder Eigenwert stellt die Varianz der Trainingsdatenmenge entlang des korrespondierenden Eigenvektors dar, somit kann der Informationsverlust

$$\sum_{i=1}^t \lambda_i \geq \delta \sum \lambda_i \quad (3)$$

durch geeignete Wahl von δ (z.B. 0,97 entspricht 97%) bestimmt werden.

3.2 Berechnung der Grauwertmodelle

Analog zur Berechnung des Formmodells wird zu jedem Oberflächenpunkt ein Grauwertmodell auf Basis eines Grauwertprofils berechnet. Damit die Kanteninformation modelliert werden kann, verlaufen die Profile senkrecht zur Oberfläche. Als Trainingsdaten dienen Profile, die aus den Trainingsdaten an den Punktkoordinaten extrahiert werden.

4 Optimierung

Die Optimierung ist ein iterativer Prozess, der sich in zwei Schritte einteilen läßt:

1. Zuerst werden die Grauwertprofile innerhalb eines Suchraumes um den jeweiligen Triangulationspunkt zur optimalen Position verschoben. Als Maß wird hier die Mahalanobisdistanz M des nach 2 berechneten Vektors \mathbf{b} zu Grunde gelegt:

$$M = \sum_{i=1}^t \frac{b_i^2}{\lambda_i} \quad (4)$$

2. Da Schritt 1 normalerweise keine plausible Form des Objektes liefert, ist es notwendig die Mahalanobisdistanz M von \mathbf{b} so zu beschränken, dass $M \leq M_t$. Dadurch wird gewährleistet, dass \mathbf{b} in einem Hyperellipsoiden beschränkt durch die obere Schranke M_t liegt.

Durch entsprechende Wahl des Suchraums sowie Wiederholung der beiden Schritte liefert das Verfahren eine Segmentierung des Objektes.

5 Ergebnisse

Bisher sind zwei verschiedene dreidimensionale Formmodelle entwickelt worden: ein Milz-Modell bestehend aus 10 und ein Modell der linken Niere bestehend aus 7 CT-Datensätzen. Das Formmodell der Milz besteht aus 7 affinen sowie 6 Formparametern. Das Formmodell der Niere hat ebenfalls 7 affine aber nur 4 Formparameter. Die Profilmolelle beider Modelle werden jeweils durch 4 Parameter beschrieben. Das Milzmodell ist auf 6 unbekanntem Milz-CT-Datensätzen und das Nierenmodell auf 7 CT-Datensätzen von linken Nieren getestet worden. Als Bewertungsmaß ist die totale Überdeckung des Segmentierungsergebnisses mit der manuellen Markierung berechnet worden. Die Ergebniswerte liegen zwischen 71% und 80%. In Anbetracht der bisher noch kleinen Trainingsdatenmenge, sind diese Ergebnisse als zufriedenstellend einzustufen.




Abb. 1. Segmentierungsergebnis eines Nierenmodells. 4 von 140 Schichten des Datensatzes sind abgebildet. In einigen Bereichen ist die Segmentierung nicht hinreichend genau, daher wird eine Erweiterung der Trainingsdatenmenge und damit eine Erhöhung der Modellflexibilität notwendig.

6 Diskussion und Fazit

Das Verfahren hat gezeigt, dass eine wissensbasierte Segmentierung von dreidimensionalen Objekten möglich ist. Als wesentlicher Vorteil des Verfahrens ist die vollständig automatische Segmentierung zu nennen. Durch die Modellinformation reagiert die Optimierung weniger sensitiv auf Bildpotenziale, die durch benachbarte Objekte hervorgerufen werden. Desweiteren ist das Verfahren nicht auf bestimmte Topologien beschränkt. Objekte höherer Ordnung, können ebenfalls modelliert werden. Die echte Dreidimensionalität hebt das Verfahren gegen andere Verfahren ab, die hingegen 2D-Segmentierungsinformationen lediglich zu einem 3D-Objekt zusammensetzen.

Andererseits erfordert dieses Verfahren die Erstellung einer Trainingsdatenmenge. Dieser Aufwand konnte jedoch durch die Verwendung der Wasserscheidentransformation erheblich reduziert werden. Hinzu kommt, dass die Modellberechnung zwar aufwendig ist, dieser Prozess jedoch nur einmalig stattfinden muss. Aufgrund seiner Struktur ist das Modell in der Lage Formen zu referenzieren, die in bestimmten durch die Trainingsdatenmenge definierten Grenzen variieren. Daher eignet sich das Modell sehr gut für die Modellierung parenchymatöser Organe. Bei Hohlorganen, wie zum Beispiel dem Darm oder auch Gefäßen, ist die Variabilität der Objekte zu groß, so dass für derartige Strukturen das Modell eher ungeeignet ist.

Literatur

1. Cootes TF, Hill A, Taylor CJ: Active Shape Models - 'Smart Snakes'. Proc. British Machine Vision Conference. Springer Verlag, 1992, 266-275.
2. Cootes TF, Hill A, Taylor CJ, Haslam J: The Use of Active Shape Models For Locating Structures in Medical Images. Image and Vision Computing, Vol.12, No.6, 355-366, July 1994.
3. Schindewolf T, Peitgen HO: Interaktive Bildsegmentierung von CT- und MR-Daten auf Basis einer modifizierten hierarchischen Wasserscheidentransformation. Proc BVM 2000:96-100, 2000.