

Finite-Elemente-Segmentierung mit Formwissen: Hybridisierung aus Aktiver Kontur und Point-Distribution-Modell

Jörg Bredno, Reinhold Schwippert, Thomas M. Lehmann
und Walter Oberschelp*

Institut für Medizinische Informatik
Universitätsklinikum der RWTH Aachen
Pauwelsstr. 30, 52057 Aachen
Email: jbredno@mi.rwth-aachen.de
*Lehrstuhl Informatik VII der RWTH Aachen
Ahornstr. 55, 52056 Aachen

Zusammenfassung. Bei der Segmentierung medizinischer Bilder können Algorithmen robuster gestaltet werden, wenn Wissen über die Form dargestellter Strukturen in eine Erkennung einfließt. In unserer Methode wird ein Ballon-Modell hybrid mit einem Point-Distribution-Modell (PDM) verknüpft. Dabei wird in jeder Iteration des Ballon-Modells der zur Kontur ähnlichste zulässige Formprototyp des PDM geschätzt, eine elastische Anbindung führt zu einer Formkraft, die als neuer Anteil der Einflüsse das Ballon-Modell deformiert. Die gegenseitige Annäherung beider Modelle unter gleichzeitigem Einfluß von Bildinformationen führt zu einer robusten Objekterkennung auf artefaktbehaftetem Bildmaterial. Tests auf synthetischen Bildern quantifizieren die Verbesserung einer Segmentierung durch Einsatz von Formwissen. Auf 52 realen Bildern eines sprechenden Mundes konnte die subjektiv bewertete Erkennungsrate von 3,8% auf 80,8% gesteigert werden.

1 Einleitung

Die Segmentierung ist ein essentieller Schritt zur quantitativen Auswertung medizinischer Bilddaten. Eine aktive Kontur auf Basis finiter Elemente kann als Ballon-Modell beliebig geformte Objekte detektieren [1], verfügt aber nur über lokales Wissen bezüglich der aufzufindenden Strukturen. Bei medizinischen Bildern ist üblicherweise bekannt, welche Objekte enthalten sind und welche Formen diese annehmen können. Durch den Einsatz dieses Formwissen kann die Segmentierung robust gegenüber undeutlichen Objektkanten oder Artefakten gestaltet werden [2]. Da die Objekte in medizinischen Bildern einer starken globalen und lokalen Variabilität unterliegen, führt der Einsatz starrer Modelle oder solcher mit algorithmisch festgelegter Variabilität zu unakzeptablen Segmentierungsergebnissen [3]. Die im folgenden vorgestellte Methode soll insbesondere nicht auf einen zweidimensionalen Bildraum festgelegt zu sein, keine Einschränkungen der repräsentierbaren Formen geben und die zu erkennende Form und die auftretenden Formvariabilitäten automatisch aus Trainingsbeispielen ermitteln.

2 Methode

Auf Basis dieser Anforderungen wurde das hybride Modell konzipiert und implementiert. Konturen werden im folgenden als Simplex-Netze, also Listen von Knoten und linearen Verbindungselementen repräsentiert. Diese Datenstruktur ist für Bildmaterial beliebiger Dimension d geeignet.

2.1 Training

In einer mehrstufigen Trainingsphase werden Informationen über auftretende Formen und Formvariabilitäten aus einem Satz von Beispielkonturen entnommen und dann zur Unterstützung eines Ballon-Modells genutzt.

- Zuerst wird der Median I der Knotenzahl aller Trainingskonturen bestimmt, alle Konturen werden auf diese Knotenzahl gesampelt.
- Die Konturen werden auf einen mittleren Schwerpunkt und eine mittlere Größe (Anzahl der eingeschlossenen Pixel, Voxel oder Stixel) normiert.
- Dann wird der Konturensatz global RST-ausgerichtet. Der hierbei verwendete iterative-closest-points-Algorithmus (ICP) [4] wurde um eine Skalierungskomponente erweitert, um statt ausschließlich rigider auch affine Transformationen durchführen zu können. Zusätzlich werden die RST-Parameter der durchgeführten Transformationen mit einer unimodalen, univariaten Gaussverteilung modelliert. Die Ausrichtung erfolgt dabei auf eine fest gewählte Kontur der Trainingsmenge. Der ICP minimiert die mean-squares-distance (MSD) der Knoten zweier Konturen, die Ergebniskonturen müssen nicht mehr schwerpunkts- und größengleich sein.
- Anschließend werden durch eine Oberflächenregistrierung lokale Punktkorrespondenzen aufgefunden. Die Knoten der ausgewählten Vorlagenkontur werden auf alle anderen Konturen übertragen. Um dies zu erreichen, werden zu allen Konturen binäre Segmentbilder erzeugt, die Inneres und Äusseres trennen. Das Ballon-Modell verwendet dann die Vorlagenkontur als Initialisierung und segmentiert diese Binärbilder mit regionenorientierten Kräften, die Knoten im Innern nach außen drücken und umgekehrt. Dabei wird durch eine schwach parametrisierte Deformationskraft gleichzeitig eine Regulierung der Knotenabstände erreicht.

Als Ergebnis dieser Schritte erhält man einen affin ausgerichteten Konturensatz mit korrespondierenden Punkten, die auch lokale Variationen widerspiegeln. Solche Kontursätze sind Voraussetzung zur Generierung eines PDMs [5], für das bisher meist eine manuelle Wahl korrespondierender Punkte auf Basis einer Handsegmentierung nötig war. Mit dem PDM werden die mittlere Form und durch eine Principal-Component-Analysis die relevanten Variabilitäten ermittelt. Dazu werden die Komponenten der I Knotenpositionen $(x_{i1}, x_{i2}, \dots, x_{id})^T$ im d -dimensionalen Bildraum zu einem Formvektor

$$\mathcal{A} = (x_{11}, x_{12}, \dots, x_{1d}, x_{21}, \dots, x_{Id})^T \quad (1)$$

der Dimension $I \cdot d$ zusammengefaßt, für den eine unimodale, multivariate Verteilung angenommen wird. Zulässige Formprototypen ergeben sich dann als Summe des mittleren Formvektors \mathcal{M} mit einer Linearkombination der ermittelten Eigenvektoren \vec{e}_j zu den J größten Eigenwerten λ_j .

$$\mathcal{A} = \mathcal{M} + \sum_{j=1}^J b_j \cdot \vec{e}_j \quad (2)$$

Die Komponenten von \mathcal{A} werden anschliessend mit einer Skalierung α , Rotationsmatrix M und Translation \vec{t} transformiert, um einen Formprototypen \mathcal{P} zu erhalten.

2.2 Segmentierung

Während einer Segmentierung beeinflussen sich das Ballon-Modell und das PDM gegenseitig, um gemeinsam eine Segmentierung durchzuführen (Abb. 1). Zunächst wirken auf die Kontur die für Ballon-Modelle typischen Einflüsse aus Druck, externen und internen Kräften, die für Bildmaterial in 2, 3 und 4 Dimensionen bestimmt werden können [6]. Zusätzlich wird beim hybriden Modell nach jeder Iteration des Grundmodells mit einem genetischen Algorithmus die ähnlichste Repräsentation des Formwissens gefunden, die auf Basis des Trainings zulässig ist. Zur Bestimmung dieses Formprototypen \mathcal{P} müssen die affinen Transformationsparameter α , M und \vec{t} sowie die Vorfaktoren b_j der Eigenvektoren \vec{e}_j geschätzt werden. Der genetische Algorithmus variiert diese Parameter zur Optimierung einer gewichteten Summe aus der MSD der Knoten von \mathcal{P} zur aktuellen Kontur und dem Kehrwert der aus dem Training bekannten Wahrscheinlichkeiten von Transformationsparametern und Vorfaktoren der Eigenvektoren. Wie im Training wird dann zur aktiven Kontur die lokale Punktkorrespondenz zum Formprototypen ermittelt. Die Knoten werden dann zusätzlich zu allen anderen Kräften elastisch zu den korrespondierenden Knoten auf dem Formprototypen hingezogen. Während der Segmentierung nähern sich so der jeweilige Formprototyp und die aktive Kontur einander und gleichzeitig den im Bild enthaltenen Objekten an und konvergieren schließlich.

3 Ergebnisse

Die Leistungsfähigkeit unseres Hybrid-Ansatzes wurde auf synthetischen Bildern untersucht. Dazu wurden 100 artefaktgestörte, verrauschte Bilder eines syn-




Abb. 1. Gegenseitiger Einfluß der aktiven Kontur des Ballonmodells und des Formprototypen \mathcal{P} des PDM durch Formkraft und MSD.

thetischen Objekts erzeugt. Dieses Objekt enthält die Kontur zu $r(\varphi) < r_0 + d_r \sin(\varphi_0 + k \cdot \varphi)$ zentriert in Bildern mit 128×128 Pixeln, $k = 5$ und r_0 , d_r und φ_0 jeweils gleichverteilt aus $[40, 50]$, $[5, 10]$ bzw. $[-10, 10]$ (Abb. 2a). Das Formwissen wurde auf acht Konturen trainiert, die je als Segmentierung der nicht verrauschten Bilder zu den möglichen Extremwerten von r_0 , d_r und φ_0 ermittelt wurden. Zur Modellierung von 95% der auftretenden Variabilität wurden $J = 3$ Eigenvektoren exportiert.

Inneres und Äußeres der Konturen erhielten dann unterschiedliche Mittelwerte mit $\Delta_\mu = 10$ und additives normalverteiltes Rauschen zu $\sigma = 25$. Dies ergibt ein Amplituden-Signal-zu-Rausch-Verhältnis von -3.98dB (Abb. 2b). Am Rand des Objekts wurden die Mittelwerte über einen Bereich von 5 Pixeln Breite angepaßt, um allzu deutliche Gradienten entlang der Objektkontur zu vermeiden. Weiterhin wurden Bilder mit einem schwächeren Rauschen zu $\sigma = 2$ erzeugt, dann wurden in jedem Bild je 5 helle und dunkle additiv überlagerte Artefakte in Form einer 2D-Gaussverteilung mit $\sigma_x = \sigma_y = 5$ und einer maximalen Intensität von +10 bzw. -10 Grauwerten überlagert, die Lage der Artefakte war gleichverteilt über den Bildraum (Abb. 2c). Als Bewertung der Segmentierungen wurde jeweils die mittlere asymmetrische Hausdorff-Distanz \bar{H} (Maximaler Abstand von Knoten oder der Mitte von Kanten zur tatsächlichen Kontur) bestimmt. Hier ergab sich durch Einsatz des Formwissens nach Mittelung über alle 100 Testbilder mit starkem Rauschen ein Rückgang von $\bar{H} = 20,11$ auf 12,7. Für die artefaktgestörten Bilder mit geringerem Rauschanteil wurde die mittlere Hausdorff-Distanz \bar{H} von 14,88 auf 5,19 reduziert.

In einer ersten Anwendung auf Videosequenzen des artikulierenden Mundes wurde ein Trainingsdatensatz aus Lippenaußenkonturen bei Artikulation der Vokale a,e,i,o,u sowie bei geschlossenem Mund (2 Aufnahmen) erzeugt. Zur Darstellung von 95% der Formvariabilität werden hier $J = 4$ Eigenvektoren exportiert. Anschließend wurde für je vier Einzelbilder aus 13 unterschiedlichen Sequenzen der Grünkanal extrahiert und die Segmentierung auf diesen 52 Bildern getestet. Bei ausschließlicher Verwendung des Grundmodells der aktiven Kontur entsprachen nur zwei Segmentierungsergebnisse dem subjektiven visuellen Eindruck eines Betrachters (Erkennungsrate 3,8%). Die Segmentierung scheitert, weil durch Schattenwurf Kanten im Bild enthalten sind, die nicht die Lippenkontur widerspiegeln. Unter dem Einfluß von Formwissen werden dagegen 42 Bilder akzeptiert (80,8%, Abb. 3). Bei den verworfenen 10 Bildern fand zwar eine korrekte Lokalisation des Mundes statt, die Konturen wurden allerdings




Abb. 2. Eine synthetische Form (a), stark mit Rauschen (b) oder mit lokalen Artefakten (c) überlagert. Ergebnisse des Ballon-Modells ohne Formwissen sind weiß dargestellt, Ergebnisse des hybriden Modells in schwarz.

nicht präzise genug detektiert.

4 Diskussion

Die Hybridisierung aus Ballon-Modell und PDM verbindet die Vorteile beider Modelle. Es ist möglich, beliebig geformte Strukturen ohne eine manuelle Initialisierung zu detektieren und dabei Wissen über deren Form und auftretende Variabilitäten einzubringen, um die Erkennung robust gegen Rauschen und Artefakte zu machen. Durch die elastische Ankopplung der Modelle werden ihre jeweiligen Nachteile gemindert: Das Formwissen verhindert katastrophale Ausbrüche oder die vorzeitige Konvergenz des Ballon-Modells, das gemeinsame Wirken von konkurrierenden Formkräften und Bildeinflüssen ermöglicht aber auch die Detektion von lokalen Strukturen, die nicht durch den Trainingsdatensatz abgedeckt sind. So können auch diagnostisch relevante subtile Formänderungen vom hybriden Modell erkannt werden. Im Vergleich zu anderen Ansätzen, wie beispielsweise dem Active Shape- oder Active Appearance Model [7], ist das automatisierbare Training ein weiterer Vorteil, der den routinemäßigen Einsatz von Formwissen in der medizinischen Bildverarbeitung überhaupt erst ermöglicht.

Literatur

1. Cohen LD, Cohen I: Finite-element methods for active contour models and balloons for 2-D and 3-D images. *IEEE Trans. PAMI* 15(11): 1131-1147, 1993.
2. McInerney T, Terzopoulos D: Deformable models in medical image analysis: A survey. *Medical Image Analysis* 1(2): 91-108, 1996.
3. Jain AK, Zhong Y, Dubuisson-Jolly MP: Deformable template models: A review. *Signal Processing* 71(2): 109-129, 1988.
4. Brett AD, Taylor CJ: A method of automated landmark generation for automated 3D PDM construction. *Image and Vision Computing* 18: 739-748, 2000.
5. Cootes TF, Taylor CJ, Cooper DH, Graham J: Active shape models - Their training and application. *Computer Vision and Image Understanding* 61(1): 38-59, 1995.
6. Bredno J, Lehmann T, Spitzer K: A general finite element model for segmentation in 2, 3, and 4 dimensions. *Proc. SPIE* 3979: 1174-1184, 2000.
7. Cootes TF, Edwards GJ, Taylor CJ: Active appearance models. In Burkhardt H, Neumann B (Hrsg.): *5th European Conference on Computer Vision*, Springer-Verlag, Berlin: 484-498, 1998.




Abb. 3. Aktive Kontur (weiß) und der geschätzte Formprototyp \mathcal{P} (schwarz) nach 12(a), 24(b), 38(c) und 63(d) Iterationen.