

Freiheit für Formmodelle!

Eine robuste Erweiterung der Deformationsgleichungen

Tobias Heimann, Sascha Münzing, Ivo Wolf und Hans-Peter Meinzer

Abteilung für Medizinische und Biologische Informatik,
Deutsches Krebsforschungszentrum, 69120 Heidelberg
Email: t.heimann@dkfz.de

Zusammenfassung. Wir stellen eine neuartige Methode zur Segmentierung volumetrischer Bilddaten vor, die Techniken von statistischen Formmodellen mit deformierbaren Oberflächen kombiniert. Die internen Kräfte der deformierbaren Oberfläche berechnen sich dabei aus einem mitlaufenden Formmodell, während die externen Kräfte aus einem graph-basierten Verfahren zur optimalen Oberflächenerkennung gewonnen werden. Testsegmentierungen der Leber auf über 50 CT-Datensätzen zeigen eine mittlere Oberflächenabweichung von 1.6 ± 0.7 mm zu manuellen Referenzsegmentierungen und machen deutlich, dass mehr Freiheit für Formmodelle die Ergebnisse oft signifikant verbessern kann.

1 Einleitung

Die automatische Segmentierung dreidimensionaler Datensätze ist in der medizinischen Bildverarbeitung nach wie vor ein drängendes – und weitgehend ungelöstes – Problem. Aufgrund ihrer Robustheit auch bei verrauschten und artefaktbehafteten Bilddaten erfreuen sich statistische Formmodelle [1] in letzten Jahren steigender Beliebtheit. Aus einer Menge von Trainingsdaten wird bei diesem Verfahren eine Durchschnittsform und mögliche Variationsrichtungen berechnet, welche den Segmentierungsvorgang leiten. Da die Anzahl verfügbarer Trainingsdaten stets limitiert ist, sind die resultierenden Modelle allerdings oft nicht umfassend genug: Die erlaubten Deformationen sind zu stark eingeschränkt und die Bilddaten können nicht optimal segmentiert werden.

2 Stand der Forschung und Fortschritt durch den Beitrag

Neben der Einführung einer beschränkten Anzahl von künstlichen Freiheitsgraden in das Modell [2] (was die grundsätzliche Problematik nicht ändert), gibt es zwei Möglichkeiten, die Segmentierungsergebnisse besser an die Daten anzupassen: Entweder die Adaptierung findet als Nachbearbeitungsschritt statt (wie in [3]) oder die Segmentierung erfolgt über ein frei deformierbares Modell, das seine internen Kräfte an einem gleichzeitig mitlaufenden Formmodell ausrichtet [4]. In diesem Artikel stellen wir eine robuste Methode vor, die dem zweiten Ansatz folgt. Hauptunterschied zu den bisherigen Arbeiten ist die Definition der

externen Kräfte, die auf einem graph-basierten Algorithmus zur optimalen Oberflächenerkennung basiert. Zusammen mit den stabilisierenden internen Kräften, die längen- und winkelgetrieben sind, ergibt sich ein neues Segmentierungsmodell für 3D-Daten, das bisherigen Ansätzen deutlich überlegen ist.

3 Methoden

Das deformierbare Modell ist ein trianguliertes Gitternetzmodell (Mesh) des Objekts und stimmt topologisch mit dem korrespondierenden Formmodell (SSM) überein. Für jeden Knoten p_i im Mesh gibt es somit einen entsprechenden Punkt \tilde{p}_i im SSM. Nach einer benutzerbasierten Initialisierung wird die Evolution des deformierbaren Modells über regularisierende (interne) und datengetriebene (externe) Kräfte gesteuert. In diskreter Form ergibt sich für jeden Knoten p_i des triangulierten Meshes:

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

Analog zu den klassischen Snakes [5] wird die interne Energie als Kombination von Spannung und Rigidität realisiert. Die Spannungskraft wirkt auf alle Kanten des Meshes und treibt sie auf die Länge der entsprechenden Kante im aktuellen Formmodell:

$$F_T(p, q) = \alpha \left(1 - \frac{|\tilde{p} - \tilde{q}|}{|p - q|} \right) (p - q) \quad (2)$$

mit α als Stärke der Spannungskraft. Die Rigiditätskraft wirkt auf die Winkel zwischen benachbarten Dreiecken und treibt sie auf die entsprechenden Winkel im Formmodell zu (Abb. 1):

$$F_R(q, [p_1, p_2]) = T(q, [p_1, p_2], \beta\delta) - q \quad (3)$$

Hierbei ist $T(q, [p_1, p_2], \delta)$ eine Rotation von Punkt q um die Kante $[p_1, p_2]$ um δ Grad und β die Stärke der Rigiditätskraft. Da die durchschnittlichen Positionen der betroffenen Punkte durch die internen Kräfte nicht verändert werden dürfen, muss eine entsprechende Gegenkraft auf alle Punkte der Gruppe wirken:

$$F_N([p_1, p_2]) = -\frac{1}{4}(F_R(q_1, [p_1, p_2]) + F_R(q_2, [p_1, p_2])) \quad (4)$$

Die interne Kraft F_{int} ergibt sich dann aus einer Summe aus F_T , F_R und F_N .

Die externen Kräfte werden aus Effizienzgründen nur alle 10 Iterationen aktualisiert: Für jede Landmarke wird dann entlang der Oberflächennormale an mehreren Stellen (nach innen und außen) eine Kostenfunktion ausgewertet, die den Übereinstimmungsgrad der Position mit einem zuvor berechneten Erscheinungsmodell berechnet. In dieser Arbeit verwenden wir dafür ein nichtlineares Grauwertmodell, das auf einem kNN-Klassifikator basiert und auf Kantenprofilen und zusätzlichen Umgebungsprofilen (von der echten Position verschoben) trainiert wurde [6]. Anstatt nun für jede Landmarke individuell die Position mit den jeweils minimalen Kosten als besten Kandidaten zu wählen, berechnen wir die

Abb. 1. Zwei angrenzende Dreiecke formen den Winkel θ . Die interne Rigiditätskraft (die im gezeigten Fall den Winkel vergrößert) wirkt nicht nur auf die äußeren Punkte q_1 and q_2 , sondern auch auf die Kantenpunkte p_1 and p_2 , um das Gleichgewicht der Gruppe zu halten





Abb. 2. Optimale Oberflächensuche für triangulierte Meshes: Links ist ein Ausschnitt aus dem Mesh abgebildet; die unterschiedlichen Testpositionen für jeden Punkt sind als graue Linien eingezeichnet. Auf der rechten Seite wird gezeigt, wie zwei benachbarte Testlinien im Graphen repräsentiert sind



Oberfläche, die unter festgeschriebenen Stetigkeitskriterien global (d.h. über alle Landmarken summiert) die minimalen Kosten erreicht. Dazu wird das Problem der optimalen Oberflächensuche in das in polynomialer Laufzeit lösbare Problem des maximalen Flusses in einem Graphen überführt, wie in [7] beschrieben wird. Der verwendete Graph wird aus dem Mesh erstellt und verbindet sämtliche Testpositionen mit ihren direkten Nachbarn und der Mesh-Topologie (Abb. 2). Die berechneten Kosten werden als Kantengewichte zu speziellen Quell- und Senkknoten eingefügt. Durch den minimalen Schnitt zwischen Quelle und Senke (der sich aus dem maximalen Fluss ergibt) können die Punkte der optimalen Oberfläche gewonnen werden. Der Unterschied zwischen diesen Punkten und den entsprechenden Positionen im aktuellen Mesh ergibt nach einer Multiplikation mit dem Faktor γ die externe Kraft F_{ext} .

Die Parameter des SSM werden nun wie in [1] beschrieben auf die Punkte der optimalen Oberfläche angepasst. Für die folgenden 10 Iterationen werden die internen Kräfte versuchen, den Mesh zu dieser Form hin zu deformieren,

während die externen Kräfte die als optimal erkannten Punkte ansteuern. Durch eine Verschiebung der Gewichte α, β, γ von externen zu internen Kräften wird im Verlauf der Segmentierung der Schwerpunkt von Formerhaltung auf Datenanpassung verlagert.

4 Ergebnisse

Das beschriebene deformierbare Modell wurde auf über 50 abdominalen (zum Großteil pathologischen, d.h. mit Tumoren durchsetzten) CT-Datensätzen für die Segmentierung der Leber ausgewertet. Das für die internen Kräfte genutzte Formmodell wurde zuvor aus 32 anderen Lebersegmentierungen erstellt, ebenso wie die Erscheinungsmodelle für die externen Kräfte. Die zur Datenakquisition verwendeten Protokolle variieren sowohl in der Trainings- als auch in der Testgruppe bezüglich Auflösung, Voxelgrößen, genutztem Kontrastmittel und weiteren internen Parametern, was die Auswertung für das klinische Umfeld als realistisch erscheinen lässt. Nach einer kurzen benutzergesteuerten Initialisierung (d.h. grobe Anpassung von Position, Rotation und Größe des Modells auf den aktuellen Datensatz) lief die Segmentierung vollautomatisch. Die durchschnittliche Oberflächenabweichung von manuellen Referenzsegmentierungen betrug insgesamt 1.6 ± 0.7 mm. Abb. 3 zeigt das Ergebnis für den Datensatz, der den Median der Oberflächenabweichungen markiert.

5 Diskussion


Die erzielte Genauigkeit bei der Lebersegmentierung ist deutlich besser als bisher veröffentlichte Werte anderer Methoden: So erreichten Soler et al. eine mittlere Oberflächenabweichung von 2mm mit frei deformierbaren Modellen [8] und Lamecker et al. 2.3 ± 0.3 mm mit klassischen Formmodellen [9]. Hauptvorteil des vorgestellten Verfahrens im Gegensatz zu den klassischen Formmodellen ist, dass sich die Segmentierung besser an die Daten anpassen kann, was auch in Abb. 3 zu sehen ist. Die zusätzliche Freiheit in der Deformation zahlt sich hier direkt aus. Im Vergleich zu anderen deformierbaren Modellen sind die externen Kräfte des vorgestellten Verfahrens stabiler, da sie sich auf eine global optimale Oberfläche für den jeweiligen Iterationsschritt stützen, anstatt auf individuelle beste Positionen für jeden Punkt. Ausreißer können so völlig vermieden werden.

Probleme gibt es noch bei der Anpassung an spitz zulaufende Formen, da die Auflösung des verwendeten Meshes (ca. 2500 Punkte) an diesen Stellen nicht hoch genug ist. Neben der Lösung dieser Aufgabe werden wir den Algorithmus auch auf andere Objekte und Modalitäten anwenden. Wir hoffen, mit dem vorgestellten Verfahren den Großteil der anfallenden Segmentierungen in Zukunft weitgehend automatisch lösen zu können.

Literaturverzeichnis

1. Cootes TF, Taylor CJ, Cooper DH, Graham J. Active shape models: Their training and application. *Comp Vis Image Underst* 1995;61(1):38–59.

Abb. 3. Transversale, sagittale and frontale Schicht für eine durchschnittliche Lebersegmentierung. Oben: Die manuelle Referenzsegmentierung. Unten: Das Ergebnis für das Standard SSM in dunkelgrau, für das vorgestellte deformierbare Modell in weiss



2. Tölli T, Koikkalainen J, Lauerma K, Lötjönen J. Artificially enlarged training set in image segmentation. LNCS 2006;4190:75–82.
3. Li B, Reinhardt JM. Automatic generation of object shape models and their application to tomographic image segmentation. In: Procs SPIE; 2001. 311–322.
4. Weese J, Kaus M, Lorenz C, Lobregt S, et al. Shape constrained deformable models for 3D medical image segmentation. In: Proc IPMI. Springer; 2001. 380–387.
5. Kass M, Witkin A, Terzopoulos D. Snakes: Active countour models. Int Journal Comp Vis 1988;1(4):321–331.
6. Münzing S, Heimann T, Wolf I, Meinzer HP. Evaluierung von Erscheinungsmodellen für die Segmentierung mit Statistischen Formmodellen. In: Proc BVM; 2007.
7. Li K, Millington S, Wu XD, Chen DZ, Sonka M. Simultaneous segmentation of multiple closed surfaces using optimal graph searching. In: Proc IPMI. Springer; 2005. 406–417.
8. Soler L, Delingette H, Malandain G, Montagnat J, Ayache N, et al. Fully automatic anatomical, pathological, and functional segmentation from CT scans for hepatic surgery. Procs SPIE 2000; 246–255.
9. Lamecker H, Lange T, Seebass M. Segmentation of the Liver using a 3D Statistical Shape Model. Zuse Institute. Berlin; 2004.