

Aktive Sensoren: Kontextbasierte Filterung von Merkmalen zur modellbasierten Segmentierung

Lars Dornheim, Jana Dornheim, Heiko Seim, Klaus D. Tönnies

Institut für Simulation und Graphik, Fakultät für Informatik,
Otto-von-Guericke-Universität Magdeburg

Zusammenfassung. Strukturen in medizinischen Bildern sind oft unvollständig abgebildet und erfordern zusätzliches Modellwissen zu ihrer Segmentierung. Es gibt eine Fülle einfacher Merkmale (Grauwerte, Kanten, etc.) mit deren Hilfe eine modellbasierte Segmentierung erfolgt. Sensorbasierte Modelle reagieren nun mit allen Sensoren potentiell auf all diese Merkmale, auch wenn pro Sensor nur ein Bruchteil interessiert. Es werden richtungsgewichtete Kontursensoren vorgestellt, die abhängig von ihrer Richtung Konturen im Datensatz bewerten. Sie reagieren bevorzugt auf Konturen, die aus Modellsicht eine erwartete Richtung aufweisen. Während der Modellanpassung werden diese erwarteten, sensorabhängigen Konturrichtungen konsistent zum Modell gehalten. Dadurch werden *aktive Sensoren* geschaffen, die eine deutliche Vorfilterung auf einer einfachen Merkmalsebene im Kontext des Modells durchführen. So wird die Segmentierung von detailreichen, verrauschten und unvollständigen Daten mittels Modellen deutlich zielstrebigter und robuster, wie wir in drei Anwendungsfällen nachweisen können.

1 Einführung

Im Fall medizinischer Bilder ist oft auf Grund der reinen Bildinformation keine komplette, exakte Segmentierung möglich. In diesen Fällen ist *Modellwissen* über die zu segmentierenden Strukturen erforderlich. Dieses Wissen, z.B. über die erwartete Form, Größe oder Lage, wird durch Modelle verschiedenster Ausprägung (*ACMs*, *ASMs*, *SMSMs* [1], etc.) beschrieben.

Eine Reihe von Modellen bezieht die Bildinformation dabei über *Sensoren*. Diese sind über das Modell verteilt und können auf spezifische Bildmerkmale (Grauwerte, Konturen, Ecken, etc.) reagieren. Sie fungieren als eine erste Abstraktionsebene, auf der das Bild durch das Modell punktuell und lokal wahrgenommen werden kann. Diese einfachen Merkmale werden durch das Modell zu einem komplexen Objekt zusammengeführt.

Problematisch ist, daß es in verrauschten oder detailreichen Bildern sehr viele solcher einfachen Merkmale gibt und es a priori nicht immer klar ist, zu welcher Struktur sie gehören. Daher ist es von zentraler Bedeutung, schon frühzeitig im Segmentierungsprozeß möglichst viele irrelevante Merkmale herauszufiltern. Wir wenden uns in diesem Paper der besonders häufig benutzten Klasse der Konturmerkmale zu und werden auf Grund von Sensorausrichtungen ihre Relevanz dynamisch und lokal bestimmen.

2 Stand der Forschung

Aus der Literatur sind viele verschiedene Arten von Sensoren bekannt, die in Modellen zur Segmentierung eingesetzt werden. Ihre Ausgaben können u.a. von bestimmten Intensitäts- oder Farbwerten, Kanten oder Ecken [2] abhängen.

Nach unserem Kenntnisstand agieren zur Zeit alle diese Sensoren passiv. D.h., die Ausgabe eines Sensors hängt im allgemeinen nur von den Bilddaten ab. Selten werden Sensoren beschrieben, die vom initialen Modell abhängig sind. Sie schränken damit sinnvoll die Merkmalsmenge ein (z.B. die fest gerichteten Sensoren in [3]). Der Nachteil bei all diesen während der Modellanpassung passiven Sensoren ist die fehlende Möglichkeit, den Zustand des Modells in die Berechnung der Sensorausgaben mit einzubeziehen. Deshalb werden auch keine für das Modell irrelevanten Merkmale dynamisch durch diese Sensoren herausgefiltert.

3 Stabile Feder-Masse-Modelle

Wir nutzen zur modellbasierten Segmentierung dreidimensionale *Stabile Feder-Masse-Modelle* (SMSMs [1]). Sie sind auch in höheren Dimensionen effizient simulierbar und weisen eine gut kontrollierbare Formstabilität auf. Sie sind dynamische Formmodelle, die über ein Gleichgewicht aus drei Kräften gesteuert werden:

1. *Federkräfte* zum Größenerhalt des Modells
2. *Torsionskräfte* zum Formerhalt des Modells
3. *Sensorkräfte* zur Anpassung des Modells an die Daten

Punkt 2 unterscheidet sie von einfachen Feder-Masse-Modellen. Die zusätzlichen, stabilisierenden Torsionskräfte werden durch den Abgleich aktueller Federrichtungen zu ihren *Federruherichtungen* erzeugt.

4 Richtungsgewichtete Kontursensoren

Wir haben für die mit den einzelnen Massen des Modells assoziierten Sensoren Normalen eingeführt, die jeweils die Richtung eines Sensors beschreiben. Bei der Modellkonstruktion werden diese Sensornormalen durch arithmetische Mittlung der Normalen der angrenzenden Konturflächen, jeweils gewichtet durch den Winkel der Fläche an der Sensormasse, berechnet, so daß sie Vertexnormalen entsprechen.

Bei der Veränderung des Modells während seiner Anpassung an die Daten ändern sich die Längen und Richtungen der Federn. Somit müssen auch die Normalen der Sensoren diesem neuen lokalen Kontext (gegeben durch die Ausrichtung der angrenzenden Federn) angepaßt werden. Das geschieht durch eine Neuausrichtung jedes einzelnen Sensors.

Für jeden Sensor wird dabei jede dreidimensionale Verdrehung einer an ihn angrenzenden Feder i durch ein Rotationsquaternionen Q_i beschrieben, der im

Fälle von SMSMs schon berechnet zur Verfügung steht. Daraus wird eine über alle m angrenzenden Federn gemittelte dreidimensionale Ausgleichsrotation Q (Gleichung 1 für großes n für eine genaue Approximation; z.B. $n = 100$) approximiert, die auf den Sensor angewendet wird. Dadurch wird dieser entsprechend den an ihn angrenzenden Federn mitrotiert, so daß sein lokaler Kontext korrekt aufrechterhalten wird.

$$Q = \left(\prod_i Q\left(\frac{\varphi_i}{m \cdot n}, \vec{a}_i\right) \right)^n \quad \text{mit} \quad Q_i = Q(\varphi_i, \vec{a}_i) = \begin{pmatrix} \cos \frac{\varphi_i}{2} \\ \sin \frac{\varphi_i}{2} \cdot \vec{a}_i \end{pmatrix} \quad (1)$$

Mit Hilfe dieser Sensorrichtungen lassen sich nun richtungsgewichtete Kontursensoren konstruieren, die Konturinformationen abhängig von ihrer eigenen Richtung bewerten. Auf diese Weise werden durch einen Sensor bevorzugt Konturen gefunden, die zum lokalen Kontext des Sensors und damit zum Modell eine bestimmte, erwartete Ausrichtung (in unseren Fällen stets die Sensorrichtung) aufweisen (Abb. 1 zeigt den Effekt am Beispiel eines Sensors auf Thorax-3D-SPECT-Daten).

Im Detail wird diese Konturbewertung erreicht, indem zur Konturberechnung zunächst ein $5 \times 5 \times 5$ Gradientenfilter angewendet wird. Wir verwenden hier optimierte Filter aus [4], die besonders richtungstreue Gradientenapproximationen auf den Voxeldaten erzeugen, da die Gradientenrichtungen in unserem Fall eine besonders wichtige Rolle spielen. Die Abweichung der Richtung des Gradienten ∇I von der Sensorrichtung \vec{n} wird bestimmt und zur linearen Wichtung der Gradientengröße benutzt (Gleichung 2), wobei kleinere Abweichungen zur höheren Wichtungen führen.

$$K = \left(1 - \frac{\angle(\nabla I, \vec{n})}{\pi} \right) \cdot \|\nabla I\| \quad (2)$$




Abb. 1. Über den Gradientenbetrag erzeugte Konturbilder eines Schichtbildes eines 3D-SPECT-Datensatzes des Thorax. Bild **(b)** wurde zusätzlich einer Richtungsgewichtung in X-Richtung (Pfeil) unterzogen. Die hellen Bereiche sind jeweils die unscharfen Konturen des linken Ventrikels.

5 Ergebnisse

Wir untersuchten das Modellverhalten bei der Verwendung der aktiven, richtungsgewichteten Kontursensoren im Vergleich zu klassischen, passiven Kontursensoren (normale Gradientenfilter) in drei medizinischen Anwendungsfällen.

5.1 Segmentierung des Schildknorpels

Im ersten Fall sollte der Schildknorpel (Kehlkopf) in CT-Daten des Halses segmentiert werden [5]. Dafür wurde Konturmodellwissen in Form eines SMSM genutzt, das jeweils einmal mit aktiven und passiven Kontursensoren auf 12 CT-Datensätzen des Halses angewendet wurde. Die Segmentierungsergebnisse mit aktiven Sensoren waren in 10 von 12 Fällen deutlich besser als die mit passiven Sensoren, im Rest der Fälle identisch. In den meisten Fällen zeigte sich bei passiven Sensoren eine Untersegmentierung gegenüber der Segmentierung mittels aktiver Sensoren mit Volumenunterschieden von bis zu 30 Prozent (z.B. fehlerhaftes Finden der gegenüberliegenden Kante des flachen Schildknorpels in Abb. 2(b)). Auch Abwanderungen passiver Kontursensoren zu Nachbarstrukturen mit starken Gradienten kamen vor. Diese negativen Effekte waren bei den aktiven Sensoren signifikant vermindert, was eine erfolgreiche Segmentierung des Schildknorpels erst ermöglichte.

5.2 Segmentierung vergrößerter Lymphknoten

Im zweiten Fall sollten vergrößerte Lymphknoten in CT-Daten des Halses durch ein zweischaliges, initial kugelförmiges SMSM nach Vorgabe eines im Lymphknoten liegenden Startpunktes segmentiert werden [6]. In den von uns untersuchten drei CT-Datensätzen grenzten sich die Lymphknoten im Gradientenbild oft nicht klar und durchgängig ab, zudem waren deutlich stärkere Gradienten in ihrer unmittelbaren Nähe zu finden. Beides verhinderte eine gute Segmentierung mit dem SMSM, das passive Kontursensoren benutzte. Bei der Verwendung aktiver Kontursensoren konvergierte das Modell zielstrebig zu einer jeweils zufriedenstellenden Segmentierung. Das bei dem ersten Modell beobachtete, zum Teil großräumige Abwandern einzelner Sensoren (Abb. 2(d)) zu starker, aber falscher Gradienteninformation war nicht mehr festzustellen.

5.3 Segmentierung des linken Ventrikels

Der letzte Anwendungsfall war die Segmentierung des mit infarktbedingten Lücken behafteten linken Ventrikels in SPECT-Daten, die ein sehr niedriges Signal-Rausch-Verhältnis aufwiesen. Durch ein mehrstufiges Verfahren konnte hier der linke Ventrikel erfolgreich in 41 Datensätzen segmentiert werden [7]. Die letzte Stufe bildete dabei ein ventrikelförmiges SMSM, das die beschriebenen aktiven Kontursensoren benutzte. Auf 7 quantitativ untersuchten Datensätzen stellte sich dabei gegenüber der Verwendung passiver Kontursensoren eine durchschnittliche Verbesserung des Segmentierungsfehlers gegenüber einem von einem Experten erstellten Goldstandard um 11,9 Prozent heraus.




Abb. 2. Der Schilddrüsengang in (a) und der Lymphknoten in (c) wurden unter Verwendung von richtungsgewichteten Kontursensoren segmentiert. In (b) und (d) ist jeweils das zugehörige Ergebnis mit klassischen Kontursensoren dargestellt.

6 Diskussion

Die beschriebenen Ergebnisse zeigen, daß in den drei beschriebenen Anwendungsfällen die Segmentierungsqualität durch den Einsatz der aktiven Sensoren deutlich verbessert werden konnte. Das Abwandern von Sensoren zu benachbarten Objektkanten wurde fast vollständig vermieden. Das im Modell verankerte Modellwissen konnte damit umfassender genutzt werden.

Die Implementierung der aktiven Sensoren erfolgte sehr effizient. Die Sensorrotationen konnten direkt aus den im SMSM bereits vorliegenden Federrotationenquaternionen abgeleitet werden. Insgesamt war kein Performanzverlust durch den Übergang zu den aktiven Sensoren spürbar. Im Fall anderer Modellarten müssen die aktuellen Sensornormalen unter Umständen aufwendiger berechnet werden, wie es bei SMSMs nur während der Konstruktion erfolgt.

Literaturverzeichnis

1. Dornheim, L., Tönnies, K.D., Dornheim, J.: Stable dynamic 3D shape models. In: ICIP. (2005)
2. Bergner, S.: Structural deformable models for robust object recognition. Diplomarbeit, Fakultät für Informatik, Otto-von-Guericke-Universität Magdeburg (2003)
3. Schild, M., Pohle, R., Brune, K., Hess, A.: Semi-automatic segmentation of the left ventricle in CINE MR datasets by linked radial active model (LRAM). In: Bildverarbeitung für die Medizin. (2005)
4. Jähne, B., Schar, H., Körkel, S.: Principles of Filter Design. In: Signal Processing and Pattern Recognition. Volume 2 of Handbook of Computer Vision and Applications. Academic Press (1999) 125–151
5. Dornheim, J., Dornheim, L., Preim, B., Tönnies, K.D., Hertel, I., Strauss, G.: Stable 3d mass-spring models for the segmentation of the thyroid cartilage. Technical report, Otto-von-Guericke-Universität Magdeburg, Germany (2005)
6. Seim, H., Dornheim, J.: Ein 2-Fronten-Feder-Masse-Modell zur Segmentierung von Lymphknoten in CT-Daten des Halses. In: Bildverarbeitung für die Medizin. (2006)
7. Dornheim, L., Tönnies, K.D., Dixon, K.: Automatic segmentation of the left ventricle in 3D SPECT data by registration with a dynamic anatomic model. In: MICCAI. (2005)