Modellbasierte Segmentation klinischer MR-Aufnahmen

Christian D. Werner, Frank B. Sachse, Karsten Mühlmann und Olaf Dössel

Institut für Biomedizinische Technik,
Universität Karlsruhe, 76128 Karlsruhe
Email: cw@ibt.etec.uni-karlsruhe.de

Zusammenfassung Die in dieser Arbeit vorgestellte Strategie zur Segmentation und Klassifikation drei- und vierdimensionaler MR-Datensätze ermöglicht die Erstellung anatomischer Modelle des menschlichen Körpers. Zur Segmentation dieser Datensätze kommen unterschiedliche Verfahren zum Einsatz. Schwerpunkte bilden dabei das Region Growing und die Aktiven Konturen. Bei beiden Segmentationsverfahren werden zur Filterung der Datensätze unterschiedliche Filter (u. a. Gauß-, Sobelfilter, nichtlineare adaptive Diffusionsfilter, morphologische Filter) angewendet. Das Aktive Konturen-Verfahren wird weiterhin durch die Wahl geeigneter Potentialfunktionen unterstützt.

Schlüsselwörter: Segmentation, Aktive Konturmodelle, Region Growing, Diffusionsfilter, Klassifikation

1 Einleitung

Rechnerbasierte drei- und vierdimensionale anatomische Modelle des menschlichen Körpers gewinnen in vielen Bereichen der Medizin zunehmend an Bedeutung. Anwendungsgebiete dieser Modelle finden sich bei der Optimierung diagnostischer und therapeutischer Verfahren.

Um aus medizinischen tomographischen Aufnahmen dreidimensionale anatomische Modelle zu erstellen, bedarf es der Segmentation und Klassifikation dieser Aufnahmen. Im Allgemeinen geht der Segmentation und Klassifikation eine Vorverarbeitung der Aufnahmen voraus, die zum Ziel hat, die Bildqualität zu erhöhen und die Fehler in den Aufnahmen zu reduzieren. Bei der Segmentation der Bilddaten wird eine Unterteilung des Bildes in homogene Regionen durchgeführt [1]. Durch die Klassifikation wird jeder dieser homogenen Regionen eine Gewebeart zugeordnet.

Die in dieser Arbeit vorgestellte Strategie zur Segmentation klinischer MR-Aufnahmen basiert auf zwei unterschiedlichen Segmentationsverfahren, Region Growing und Aktive Konturen. Beiden Segmentationsverfahren gehen Filterungen der Ausgangsdatensätze voraus. Neben Mittelwert-, Gauss- und Sobelfiltern werden auch nichtlineare adaptive Diffusionsfilter eingesetzt. Die Segmentation mittels Aktiver Konturen wird durch die Wahl einer geeigneten, durch einen statistischen Klassifikator gewonnene Potentialfunktion unterstützt.

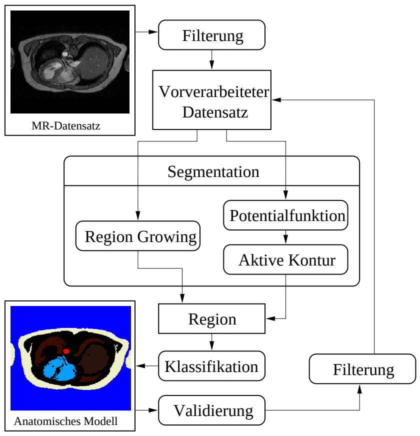

Abb. 1. Segmentationsstrategie für klinische MR-Aufnahmen

2 Methodik

2.1 Segmentationsstrategie

Die dieser Arbeit zugrundeliegende Segmentationsstrategie (Abb. 1) basiert im Wesentlichen auf dem iterativen Anwenden der Segmentationsverfahren Region Growing und Aktive Konturen. Bei jedem Iterationsschritt kommen unterschiedliche Filteroperationen zum Einsatz.

Nach einer initialen Filterung der MR-Ausgangsdaten erhält man einen vorverarbeiteten Datensatz. Dieser Datensatz wird zur Segmentation herangezogen, einerseits durch Region Growing oder andererseits mit Aktiven Konturen, wobei er hier zur Bestimmung der Potentialfunktion dient. Als Segmentationsergebnis erhält man eine Region, der bei der Klassifikation eine Gewebeart zugeordnet wird. Das Ergebnis der Klassifikation ist ein anatomisches Modell. Nach der Validierung dieses Modells kann gegebenenfalls erneut gefiltert, segmentiert und klassifiziert werden.

2.2 Datenmaterial

Als Ausgangsdaten dienen klinische 4D-MR-Aufnahmen unterschiedlicher Patienten in Voxelrepräsentation. Diese 4D-Aufnahmen liegen als Sequenzen dreidimensionaler Datensätze vor. Jeder dieser T1-gewichteten Datensätze [2] besteht aus $256 \times 256 \times 16$ Voxeln der Kantenlängen $2\,mm \times 2\,mm \times 8\,mm$.

2.3 Filterung

Neben der Mittelwert-, Median- und Gauss-Filterung [1] kommt zur Reduktion von Rauschen ein nichtlinearer adaptiver Diffussionsfilter (Adaptive Smoothing) [3] zum Einsatz.

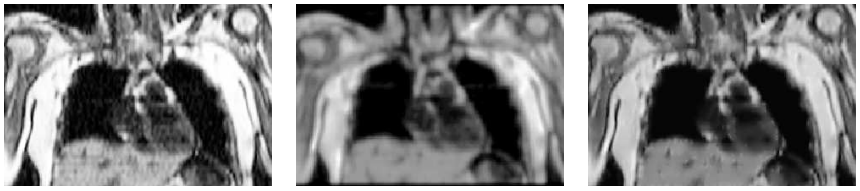

(a) (b) (c)

Abb. 2. Filterung von (a) 3D-MR-Daten mittels (b) Mittelwertfilter und (c) Adaptive Smoothing

Beim Adaptive Smoothing werden in Abhängigkeit der Bildgradienten Gewichtungsfaktoren bestimmt, mittels derer für jedes Voxel die Parameter zur Filterung neu definiert werden. Aus den Bilddaten I ergeben sich die gefilterten Daten F folgendermaßen:

$$F(x, y, z) = \frac{\sum_{i,j,k=-1}^{+1} I(x+i, y+j, z+k) w(x+i, y+j, z+k)}{\sum_{i,j,k=-1}^{+1} w(x+i, y+j, z+k)} \tag{1}$$

Hierbei ist w die Gewichtungsfunktion, die sich aus G, dem Betrag des Bildgradienten, wie folgt bestimmen läßt:

$$w(x, y, z) = e^{-\frac{G^2(x,y,z)}{2\sigma^2}} \tag{2}$$

Mit dem Parameter σ läßt sich die Filtercharakteristik beinflussen. Wird σ groß gewählt, nähert sich das Verhalten einem Mittelwertfilter an, d. h. man erhält eine starke Glättung der Ausgangsdaten. Bei kleinem σ bleiben Kanten weitgehend unverändert erhalten.

Der Betrag des Gradienten wird wie folgt bestimmt [3]:

$$G(x, y, z) = \max(|I(x, y, z) - I(x-i, y-i, z-i)|) \tag{3}$$

Ein Vergleich der Filterung von 3D-MR-Daten mit Gaussfilter bzw. Adaptive Smoothing ist in Abb. 2 dargestellt.

2.4 Region Growing

Das Region Growing Verfahren ermöglicht die Segmentierung eines zusammenhängenden Gebietes. Das Verfahren wird durch die Vorgabe von Saatpunkten, Segmentationskriterien und Nachbarschaftsbeziehungen parametrisiert [1].

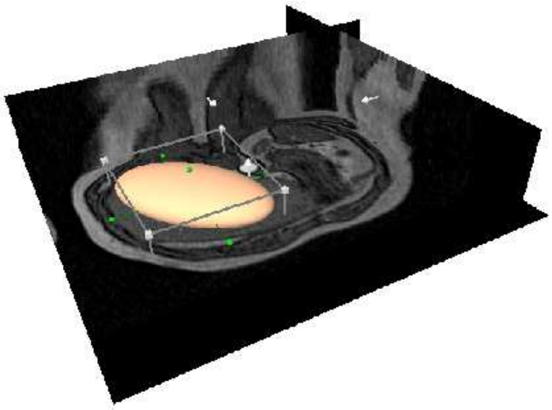

Abb. 3. Initale Kontur zur Segmentierung der Leber mittels eines Aktiven Konturmodells. Die Kontur wird interaktiv skaliert, rotiert und plaziert.

2.5 Aktive Konturen

Mit Aktiven Konturen werden die elasto-mechanische Eigenschaften einer dünnen Oberfläche nachgebildet. Dieses Oberflächenmodell steht dabei unter dem Einfluß unterschiedlicher Kräfte, die sich zum einen aus den inneren, durch Materialeigenschaften definierten Kräften und den äußeren, durch die Bildinformation eingebrachten Kräften zusammensetzen.

Die Energie einer Aktiven Kontur $\mathbf{x}(u,v)$ wird durch folgendes Energiefunktional beschrieben [4]:

$$\mathcal{E}(\mathbf{x}) = \mathcal{S}(\mathbf{x}) + \mathcal{P}(\mathbf{x}) \tag{4}$$

wobei $\mathcal{S}(\mathbf{x})$ die innere Deformationsenergie und $\mathcal{P}(\mathbf{x})$ die äußere durch die Bildinformation eingebrachte Energie ist. Es ergeben sich nach [4]:

$$\mathcal{S}(\mathbf{x}) = \iint \alpha_{10} \left|\frac{\partial \mathbf{x}}{\partial u}\right|^2 + \alpha_{01} \left|\frac{\partial \mathbf{x}}{\partial v}\right|^2 + \beta_{20} \left|\frac{\partial^2 \mathbf{x}}{\partial u^2}\right|^2 + \beta_{11} \left|\frac{\partial^2 \mathbf{x}}{\partial u\, \partial v}\right|^2 + \beta_{02} \left|\frac{\partial^2 \mathbf{x}}{\partial v^2}\right|^2 \mathrm{d}u\, \mathrm{d}v, \tag{5}$$

$$\mathcal{P}(\mathbf{x}) = -\iint P(\mathbf{x}(u,v))\, \mathrm{d}u\, \mathrm{d}v, \tag{6}$$

wobei die Parameter α_{01}, α_{10}, β_{20}, β_{02} und β_{11} die elasto-mechanischen Eigenschaften der Kontur bestimmen und $P(\mathbf{x}(u,v))$ eine aus den Bilddaten gewonnene skalare Potentialfunktion darstellt. Diese Potentialfunktion kann durch Gradientenbildung und durch Einsatz eines statistischen Klassifikators gebildet werden. Die Aktive Kontur $\mathbf{x}$ minimiert das Energiefunktional $\mathcal{E}$.

In dieser Arbeit wurde eine Diskretisierung der Kontur mittels eines Dreiecksnetzes durchgeführt. Durch geschickte Wahl der initialen Kontur (Abb. 3), der Potentialfunktion und der elasto-mechanischen Eigenschaften wird angestrebt, daß die Kontur das Energieminimum an Organ- oder Gewebegrenzen erreicht und somit eine Segmentierung der MR-Daten erfolgt.

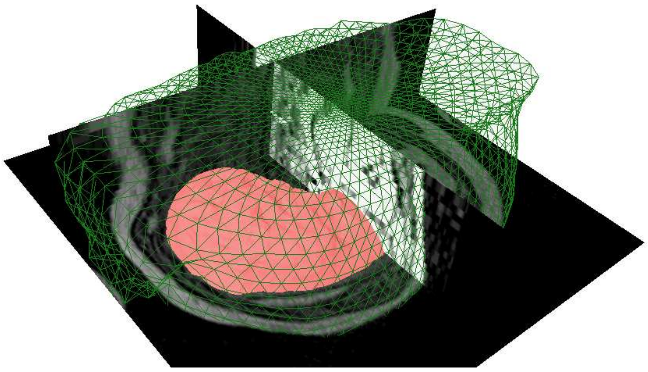

Abb. 4. Ergnisse der Segmentation: Segmentation der Leber und des Aussenbereichs.

3 Ergebnisse

Mit der vorgestellten Segmentationsstrategie wurde ein anatomisches Modell des Thorax erstellt. Dabei konnten in den Datensätzen folgende Gewebeklassen unterschieden werden: Aussenbereich, Haut, Lunge, Aorta, Subkutanes Fett, Muskel, Leber und Herz. Der Aussenbereich, die Lunge und die Aorta wurden hierbei durch Region Growing segmentieren. Durch Anwendung aktiver Konturen wurden Leber, Subkutanes Fett, und Muskulatur abgegrenzt. Die Kenntnis von Lage und Form der an das Herz grenzenden Gewebearten ermöglichte dessen Segmentierung. Hierbei wurden u. a. morphologischer Filter eingesetzt.

Danksagung

Wir danken Herrn Bornstedt vom Deutschen Herzzentrum Berlin für die freundliche Unterstützung unserer Arbeit, insbesondere für die Erstellung der 4D-MR-Aufnahmen.

Literatur

1. R. C. Gonzalez and R. E. Woods, *Digital Image Processing.* Reading, Massachusetts; Menlo Park, California; New York; Bonn: Addison-Wesley, 1992.
2. H. Morneburg, Siemens Aktiengesellschaft, ed., *Bildgebende Systeme für die medizinische Diagnostik.* Erlangen: Publicis MCD, 3 ed., 1995.
3. I. Matalas, R. Benjamin, and R. Kitney, "An edge detection technique using the facet model and parametrized relaxation labeling," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 19, pp. 328–341, April 1997.
4. T. McInerney and D. Terzopoulos, "Deformable models in medical image analysis: A survey," *Medical Image Analysis*, vol. 1, no. 2, 1996.