

# **Schnelle, interaktive Segmentierung medizinischer 3D-Datensätze durch Anwendung der „Image Foresting Transformation“ in zwei verschiedenen Auflösungsstufen**

Regina Pohle, Manfred Hinz, Klaus D. Tönnies, Georg Stamm<sup>1</sup>, Tilo Pohle<sup>2</sup>

Institut für Simulation und Graphik

Otto-von-Guericke-Universität, 39106 Magdeburg

<sup>1</sup> Klinik für Radiologie, Medizinische Hochschule Hannover, Hannover

<sup>2</sup> Klinik für Chirurgie, Pfeiffersche Stiftungen, Magdeburg

Email: regina@isg.cs.uni-magdeburg.de

**Zusammenfassung.** Zur Segmentierung von 3D-Datensätzen in der klinischen Praxis werden Verfahren benötigt, die einen möglichst geringen Interaktionsaufwand besitzen und flexibel einsetzbar sind. Dieses Ziel wird durch die vorgenommenen Erweiterungen der „Image Foresting Transformation“ erreicht. Die Leistungsfähigkeit des Verfahrens wird anhand des Vergleichs zur manuellen Segmentierung eingeschätzt.

## **1 Einleitung**

Die Auswertung medizinischer Bilddaten zum Zweck der computergestützten Diagnostik und der Operationsplanung schließt häufig eine Segmentierung des Bildmaterials als Vorstufe zur Visualisierung bzw. Quantifizierung mit ein. So ist z.B. die Segmentierung der Leber notwendig, um Aussagen über deren Volumen treffen zu können. Bisher erfolgt diese zumeist semi-automatisch durch speziell angepasste Softwarelösungen. Doch sowohl das eingesetzten Live-wire-Verfahren [1] als auch die Ziplock-Snakes [2] erfordern einen hohen Interaktionsaufwand. Unser Ziel war es, einen allgemeinen Ansatz zur 3D-Segmentierung mit geringem Interaktionsanteil zu finden, der es außerdem dem Arzt erlaubt, solange Veränderungen an dem Segmentierungsergebnis vorzunehmen, bis es seinen Bedürfnissen entspricht.

## **2 Beschreibung der Segmentierungsmethode**

Da es in medizinischen Bildern keine eindeutige Beziehung zwischen Organen und bestimmten Grauwertverteilungen gibt, kann derartiges Modellwissen nicht automatisch in einen allgemeinen Segmentierungsalgorithmus integriert werden, sondern es muss vom Nutzer über eine geeignete Interaktion abgefordert werden. Bei der von uns erweiterten „Image Foresting Transformation“ (IFT) [3] geschieht dies über das Einzeichnen von Linien als Startregionen auf wenigen Schichten, die als Objekt bzw. als Hintergrund gekennzeichnet werden müssen. Das Einzeichnen kann bisher wahlweise in allen drei möglichen achsenparallelen Schnittebenen erfolgen.

Bei der anschließenden regionenorientierten Segmentierung auf Grundlage der IFT wird der Datensatz durch einen gewichteten und nicht-orientierten Graphen beschrie-

ben. Jedes Voxel im Datensatz wird als ein Knoten und jedes Paar von verbundenen Voxeln als ein nicht-orientierter Pfad in dem Graphen aufgefasst. Die Pfadkosten werden über die absolute Differenz der Grauwerte der jeweils verbundenen Voxel berechnet. Für alle manuell markierten Voxel ergeben sich die Anfangskosten als die maximalen Kosten, um zu einem seiner 6 direkt benachbarten Voxel zu gelangen. Für alle anderen Voxel des Datensatzes sind sie unendlich hoch. Die optimale Zerlegung des Bildes erfolgt mittels dynamischem Programmieransatz. An dieser ersten Segmentierung kann der Nutzer beliebig viele Verbesserungen vornehmen, indem er weitere Startregionen als Modellwissen in den Algorithmus einbringt. Ausgehend von diesen neuen Startregionen erfolgt ein Graphenumbau und eine Re-klassifikation von Regionen solange, bis es keinen Knoten mehr gibt, der auf einem neuen Weg kostengünstiger erreicht werden kann.

Da der Originalansatz der IFT aufgrund der sich ergebenden hohen Rechenzeiten für die in der Medizin üblichen 3D-Datenmengen nicht einsetzbar war, wurden Modifikationen zur Beschleunigung vorgenommen. So erfolgt die Segmentierung unter Nutzung von zwei verschiedenen Auflösungsstufen. Der Ablauf ist wie folgt:

1. Grobsegmentierung des Objekts in dem Datensatz bei reduzierter Auflösung
2. Gegebenenfalls Verbesserung des ersten Segmentierungsergebnisses
3. Automatische Bestimmung der Randregion des Objekts
4. Segmentierung der Randregion in Originalauflösung
5. Gegebenenfalls Verbesserung des Segmentierungsergebnisses
6. morphologisches Glätten

Für einen Beispieldatensatz sind die Resultate der einzelnen Schritte in Abb. 1 dargestellt. Die erste Segmentierung in Grobauflösung liefert ein binäres Bild, durch das Lage, Form und Größe des gesuchten Objekts angenähert ist. In diesem Bild wird nun ein Randbereich  $R$  bestimmt, dessen Rand aus Pixeln besteht, die entweder sicher innerhalb oder sicher außerhalb des Objekts liegen. Dazu wird das Binärbild auf die Originalauflösung expandiert und durch einen Mittelwertfilter geglättet. Zwei Schwellwerte  $T_1 > 0.5$  und  $T_2 < 0.5$  werden bestimmt. Das gesuchte Gebiet  $R$  besteht nun aus allen Pixeln mit  $T_2 \leq p \leq T_1$ . Randpixel  $r_p$  dieses Gebiets sind Objektpixel, falls  $|r_p - T_1| < |r_p - T_2|$  und Hintergrundpixel sonst. Die IFT wird auf der Originalauflösung für alle Pixel in  $R$  wiederholt, wobei Randpixel  $r_p$  als zusätzliche Markierungen zählen, die zu denjenigen Ursprungsmarkierungen hinzugenommen werden, die in  $R$  enthalten sind. Bei Bedarf lassen sich durch Einfügen weiterer Markierungen Korrekturen vornehmen.

### 3 Ergebnisse

Das beschriebene Verfahren wurde hinsichtlich der Segmentierung der Leber in CT-Datensätzen untersucht. Ziel der Untersuchung war es, die Rechenzeiterparnis zu bestimmen und Abweichungen von der Original-IFT sowie von der manuellen Segmentierung abzuschätzen. In vier unterschiedlichen Datensätzen wurde dazu in bis zu 10 verschiedenen Schichten eine grobe Markierung des Objekts und des Hintergrunds vorgenommen. Durch die Auswahl des interessierenden Gebietes in der ersten Stufe

der Segmentierung konnte die Anzahl der bei der genauen Berechnung zu untersuchenden Pixel auf ca. 10 % der ursprünglichen Pixelanzahl des Datensatzes reduziert werden. Damit reduzierte sich die Rechenzeit auch auf etwa ein Zehntel. Für die komplette Bearbeitung eines CT-Datensatzes mit 90 Schichten wurden ca. 20 Minuten benötigt, wobei für den Praxiseinsatz eine Trennung zwischen den interaktiven Programmteilen und der reinen Berechnung vorgenommen werden kann. In diesem Fall würde die vom Arzt aufzuwendende Zeit weniger als 5 Minuten betragen.

Die Variation des Ergebnisses zwischen der vorgeschlagenen Vorgehensweise und der Segmentierung bei voller Auflösung liegt im gleichen Bereich wie die Variation der Ergebnisse in Abhängigkeit von der Nutzereingabe. Bei drei verschiedenen Nutzereingaben lag die gemessene maximale Abweichung der Kontur des Segmentierungsergebnisses ohne Nachkorrektur bei 5 Pixeln und die mittlere Abweichung unter einem Pixel.

Zur Einschätzung der Leistungsfähigkeit des Verfahrens wurde ein Vergleich mit der manuellen Segmentierung durchgeführt. Für vier Volumendatensätze ergab sich im Vergleich zur manuell auf den einzelnen Schichten eingezeichneten Kontur eine Abweichung bei der Volumenbestimmung von  $7.2 \pm 4.7$  %. Eine zum Vergleich an 25 zufällig ausgewählten Schichten eines Datensatzes durchgeführte Messung des intra-individuellen Fehlers zwischen zwei Markierungen ergab eine prozentuale Abweichung bei der Volumenbestimmung von 10 %. Ein Vergleich zwischen zwei Ärzten ergab für die gleichen Schichten auch einen inter-individuellen Fehler von 10 %.

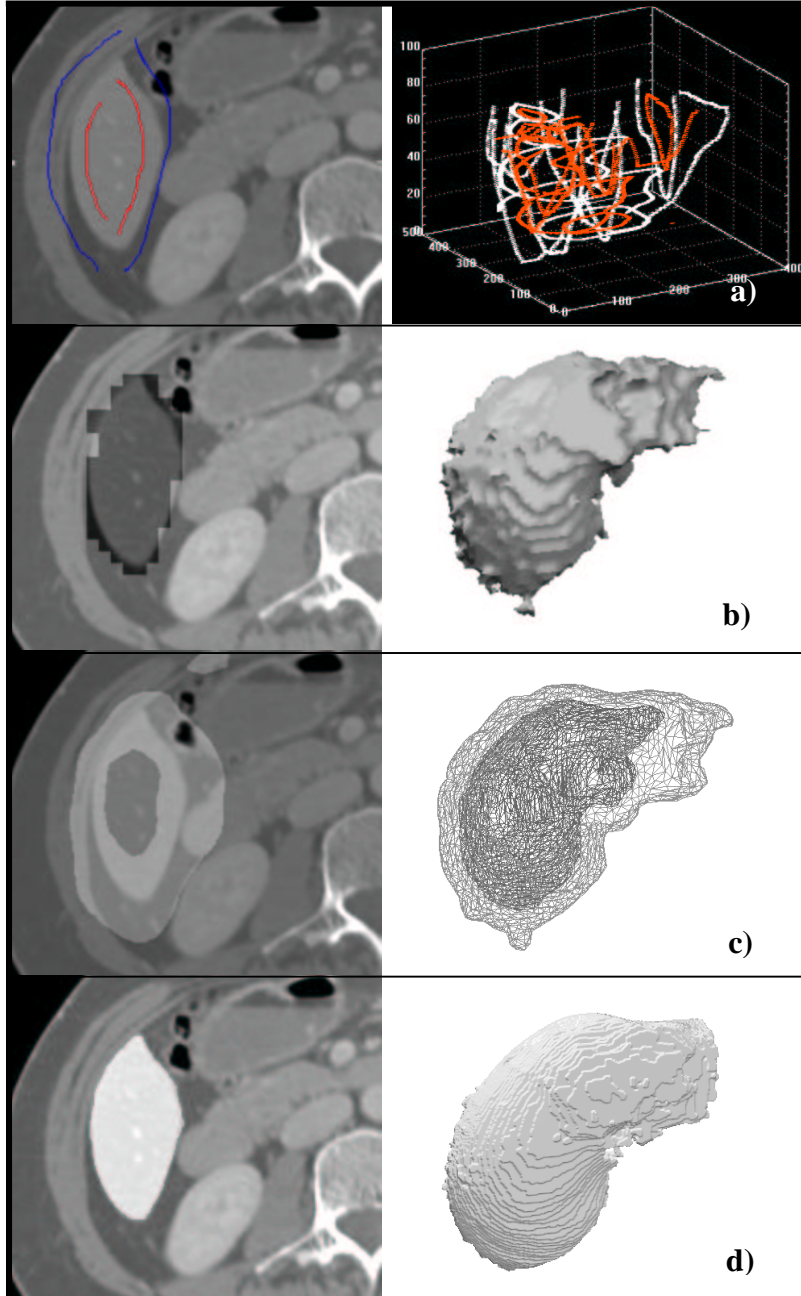
#### **4 Diskussion und Resümee**

Das vorgestellte 3D-Segmentierungsverfahren lieferte Ergebnisse, deren Genauigkeit im Bereich der intra- und interindividuellen Abweichung liegt. Ein Vorteil des Verfahrens liegt neben dem geringen Interaktionsaufwand und der vollständigen Berücksichtigung des 3D-Zusammenhangs darin, dass auch Objekte segmentierbar sind, bei denen kein vollständig geschlossener Rand zu sehen ist.

In zukünftigen Arbeiten soll untersucht werden, ob durch den Einsatz anderer Kostenfunktionen eine Verbesserung der Segmentierungsergebnisse erreicht werden kann. Außerdem ist vorgesehen, die Eingabe der Startregionen flexibler zu gestalten, so dass beliebige orientierte Linien eingezeichnet werden können.

#### **5 Literatur**

1. Schenk A, Prause G, Peitgen H-O: Optimierte semi-automatische Segmentierung von 3D-Objekten mit Live Wire und Shape-based Interpolation, Bildverarbeitung für die Medizin 2001, Proceedings, S. 202-206
2. Kunert T, Heiland M, Meinzer H-P: Interaktive Segmentierung von zweidimensionalen Datensätzen mit Hilfe von Aktiven Konturen, Bildverarbeitung für die Medizin 2001, Proceedings, S. 257-261
3. Falcao A X, Lotufo R A, Araujo G: The Image Foresting Transformation, Technischer Bericht, University of Campinas, IC-00-12, Juli 2000



**Abb. 1:** a) Ausschnitt aus einem CT des Abdomens mit Markierung der Leber- und der Hintergrundregion, b) Ergebnis der Grobsegmentierung der Leber, c) extrahierte Randregion, die einer genauen Segmentierung unterzogen wird, d) Endergebnis der Lebersegmentierung