

Evaluierung von interaktiven, texturanalytischen Segmentierungsverfahren

M.Hastenteufel, C.Cárdenas, Ch. Giess, G.Glombitza, P.Hassenpflug,
H.-P. Meinzer

Abteilung für Medizinische und Biologische Informatik
Deutsches Krebsforschungszentrum
Im Neuenheimer Feld 280, 69120 Heidelberg
Email: M.Hastenteufel@dkfz.de

Zusammenfassung Vor einer computergestützten Operationsplanung steht immer der wichtige Schritt der Segmentierung. Im klinischen Einsatz kommen hierzu momentan neben zeitaufwendigen Freihandsegmentierungen meist interaktive Verfahren zum Einsatz. In der vorliegenden Arbeit wurden in einen vektoriiellen Region-Growing Algorithmus Texturmaße aus der Cooccurencematrix sowie der Wavelettransformation integriert und anhand medizinischer Bilddaten auf Praxistauglichkeit für die klinische Routine evaluiert.

1 Einleitung

Eine computergestützte Operationsplanung setzt in einem ersten Schritt immer eine Segmentierung der betroffenen Organe voraus. Im klinischen Einsatz kommen hierzu momentan neben zeitaufwendigen Freihandsegmentierungen meist interaktive Verfahren wie das Region-Growing oder aktive Konturen zum Einsatz. In unserer Abteilung wird für die Operationsplanung in der Leberchirurgie zur Segmentierung der Leber und des Tumors ein skalares Region-Growing Verfahren eingesetzt, welches in einigen Fällen keine hinreichend genaue Segmentierung liefert. Fehlsegmentierungen müssen in einem zeitaufwendigen Schritt manuell nachgebessert werden. Genauere Segmentierungsverfahren würden den Zeitaufwand der Operationsplanung erheblich reduzieren. Es sollte nun evaluiert werden, ob eine Integration von Texturmerkmalen in die interaktive Segmentierung den Segmentierungsvorgang hinsichtlich Genauigkeit und Zeitbedarf verbessern kann. Hierfür wurden Softwarekomponenten zur texturanalytischen Segmentierung entwickelt, in ein vorhandenes Segmentierungstools integriert und anhand realer Bilddaten evaluiert. Ziel dieser Arbeit war eine Untersuchung der Eignung von interaktiven, texturbasierten Segmentierungsverfahren für den klinischen Einsatz sowie des Einflusses der Parameter der verschiedenen Methoden auf das Segmentierungsergebnis.

2 Methoden

2.1 Interaktive, texturanalytische Segmentierung

Texturbasierte oder texturanalytische Segmentierungsverfahren werden den regionenorientierten Verfahren zugeordnet. Bei diesen Verfahren werden in einem ersten Schritt, der sogenannten Merkmalsextraktion, lokale Texturmerkmale berechnet und jedem Pixel ein Merkmalsvektor zugeordnet. In einem zweiten Schritt werden die berechneten Merkmalsvektoren in Klassen ähnlicher Vektoren eingeteilt. Haben die Klassen keine Bedeutung, spricht man von einer Clusteranalyse. Wird den Klassen eine Bedeutung zugeordnet (z.B. Lebergewebe, Herzgewebe,...) spricht man von Klassifikationsverfahren. Findet vor oder während der Clusteranalyse bzw. der Klassifikation eine Benutzerinteraktion statt, spricht man von interaktiven, ansonsten von automatischen Verfahren. Den gesamten zweistufigen Prozess der Merkmalsextraktion und Clusteranalyse bzw. Klassifikation bezeichnet man als texturanalytische Segmentierung.

2.2 Merkmalsextraktion

Es existieren eine Reihe von Verfahren zur Merkmalsextraktion, von denen für die aktuelle Problemstellung das jeweils geeignetste auszuwählen ist. In der Literatur werden die Merkmalsextraktionsverfahren meist in automatische Cluster- bzw. Klassifikationsverfahren integriert, welche für praktischen Aufgaben jedoch in den seltensten Fällen zu verwenden sind. Zu jeder Methode sind eine Reihe von Parametern zu spezifizieren, welche für den Benutzer oft schwierig zu überschauen sind. Als Merkmalsextraktionsmethoden kamen in dieser Arbeit klassische Cooccurencematrizen mit den daraus abgeleiteten Merkmalen *Entropie*, *Kontrast*, *Homogenität* und *Korrelation* [1] sowie Verfahren basierend auf einer diskreten Wavelettransformation zum Einsatz [2, 3, 4]. Bei letzteren Verfahren wurden verschiedene Funktionen (z.B. Absolutwert, Quadrierung, lokale Energie,...) auf die Waveletkoeffizienten sowie die Tiefpassbilder angewandt und die daraus resultierenden Merkmalsbilder auf Ausgangsgröße hochinterpoliert, um eine eins-zu-eins Zuordnung von Pixel zu Merkmalsvektor zu gewährleisten. Zu Vergleichszwecken wurden desweiteren die trivialen Merkmale *lokaler Mittelwert* und *lokale Varianz* implementiert.

2.3 Klassifikation

Als Klassifikationsverfahren wurde ein interaktiver, vektorieller Region-Growing Algorithmus implementiert. Grundlage hierfür war ein skalarer Region-Growing Algorithmus basierend auf [5]. Die Interaktion besteht in dem Einzeichnen einer Saatregion innerhalb des zu segmentierenden Objektes. Der komplette Merkmalsraum wird anhand der Merkmalsvektoren dieser Saatregion normiert, um einen gleichmäßigen Einfluss der einzelnen Merkmalskomponenten auf die Segmentierung zu gewährleisten. Hierzu kamen die z -Normierung sowie die min-max-Normierung zum Einsatz. Bei Verwendung der z -Normierung ergibt sich für den

Mittelwertsvektor der Saatregion $\mu = (\mu_0, \dots, \mu_{k-1}) = (0, \dots, 0) \in \mathbb{R}^k$ und für den Standardabweichungsvektor $\sigma = (\sigma_0, \dots, \sigma_{k-1}) = (1, \dots, 1) \in \mathbb{R}^k$. Nach Anwendung der alternativen min-max-Normierung liegen die Komponenten der Merkmalsvektoren der Saatregion im Intervall $[-1, 1]$. Die z-Normierung setzt also normalverteilte, die min-max-Normierung gleichverteilte Merkmale voraus.

Als Homogenitätskriterien kamen das Euklidkriterium, das Intervallkriterium sowie ein abgewandeltes Intervallkriterium zum Einsatz. Beim Euklidkriterium werden alle Pixel vom Region-Growing akzeptiert, für deren Merkmalsvektoren $f_i \in \mathbb{R}^k$ $d(f_i, \mu) \leq \gamma$ gilt, wobei $\gamma \in \mathbb{R}$ ein vom Benutzer anzugebender Parameter und $d(\cdot, \cdot)$ der euklidische Abstand zweier Vektoren ist. Beim Intervallkriterium muss jede Merkmalskomponente $f[i]$ des Merkmalsvektors f innerhalb des Intervalls $[-\gamma, \gamma]$ liegen, um vom Region-Growing als positiv gewertet zu werden. Das Euklidkriterium spannt also eine Kugel im mehrdimensionalen Raum auf, das Intervallkriterium ein Rechteck. Beim abgewandelten Intervallkriterium müssen nur die Hälfte der Komponenten des Merkmalvektors f im Intervall $[-\gamma, \gamma]$ liegen.

Der entwickelte vektorielle Region-Growing Algorithmus ist nicht auf die texturanalytische Segmentierung beschränkt, sondern kann allgemein für Mehrkanalbilder, wie z.B. registrierte multimodale Aufnahmen, eingesetzt werden.

2.4 Implementierung

Die entwickelten Merkmalsextraktions- und Segmentierungskomponenten wurden innerhalb eines in unserer Abteilung entworfenen, objektorientierten Frameworks in C/C++ implementiert [6] und in ein bereits in der klinischen Routine eingesetztes Segmentierungstool integriert.

2.5 Evaluierungsmethoden

Ein Problem beim Einsatz von texturanalytischen Segmentierungsverfahren besteht in der Auswahl der Merkmalsextraktionsmethode sowie den zur Methode gehörenden Parametern. Zur Unterstützung des Benutzers bei der Auswahl der Methode und den einzustellenden Parametern wurde eine Evaluation an medizinischen Bilddaten unterschiedlicher Modalitäten durchgeführt. Anhand von CT-Aufnahmen der Leber (512×512), US-Aufnahmen des Herzens (360×256) sowie getaggten MR-Aufnahmen (MR-Aufnahme mit überlagerten Streifen zur Bewegungsverfolgung) eines Schweineherzens (256×256) wurden für die implementierten Merkmalsextraktionsverfahren verschiedene Parameterkombinationen evaluiert.

Zur Beurteilung der Segmentierungsgüte wurden die Werte Sensitivität $S_e = \frac{rp}{rp+fn}$ und Spezitivität $S_p = \frac{rn}{rn+fp}$ des Segmentierungsergebnisses berechnet, wobei rp die richtig positiv, rn die richtig negativ, fp die falsch positiv und fn die falsch negativ segmentierten Pixel bezeichnen. Grundlage hierfür war eine von einem Mediziner durchgeführte Freihandsegmentierung (Gold-Standard). Die Ergebnisse des vektoriellen Region-Growings wurden zudem mit den Ergebnissen eines herkömmlichen, skalaren Region-Growings verglichen.

Untersuchte Parameter der Merkmalsextraktion mittels Cooccurencematrizen waren *Fenstergröße*, *Grauwertquantifizierung*, *Displacement* δ sowie *Winkel* α .

Bei der Merkmalsextraktion mittels Wavelettransformation wurde der Einfluss *der Tiefpassanteile*, *der Waveletbasis* (*Daubechies18:10*, *Daubechies9:7*), *der verwendeten Waveletkoeffizienten* (*identisch*, *quadriert*, *absolut*, *lokale Energie*, *Mittelwert*, *Varianz*), sowie *der Berechnung von Cooccurencematrizen auf den Tiefpassanteilen* untersucht.

Für das vektorielle Region-Growing wurde der Einfluss *des Homogenitätskriteriums*, *des Abstandsmaßes* γ sowie *der Normierungsmethode* untersucht.

3 Ergebnisse

Bei Verwendung von Merkmalen aus der Cooccurencematrix stellte sich eine Fenstergröße von 3×3 sowie eine Grauwertquantifizierung von 16-32 Grauwerten am geeignetsten heraus. Durch größere Fenster wird zwar potentiell die Genauigkeit der Texturmaße erhöht, Übergänge zwischen verschiedenen texturierter Regionen werden allerdings zu stark verwischt. Durch die Wahl eines Fensters von 3×3 resultiert gleichzeitig ein optimales Displacement von $\delta = 1$ für die Aufstellung der Cooccurencematrix. Winkel von $\alpha = 0^\circ$ und $\alpha = 45^\circ$ Grad erzielten die besten Ergebnisse, rotationsunabhängige Matrizen brachten keine nennenswerte Verbesserung. Die Verwendung von kleinen Fenstern, niedrigen Grauwertquantifizierungen sowie rotationsabhängigen Cooccurencematrizen bringt zudem eine erhebliche Ersparnis an Rechenzeit.

Bei Verwendung der Wavelettransformation hatte eine zusätzliche Berechnung von Cooccurencemerkmalen auf den Tiefpassanteilen der einzelnen Iterationstufen keine Verbesserung der Segmentierung zur Folge. Für die Leber-CT sowie die Ultraschallaufnahmen des Herzens lieferte eine Kombination von Daubechies18:10-Wavelet, quadrierten Waveletkoeffizienten sowie Verwendung der Tiefpassanteile auf allen Iterationslevel die besten Ergebnisse. Für die getaggtten MR-Aufnahmen wurde mit der Kombination von Daubechies18:10-Wavelet, identischen Waveletkoeffizienten sowie Verwendung aller Tiefpassanteile die besten Ergebnisse erzielt.

Bei der Parameteruntersuchung des vektoriellen Region-Growings lieferte die Kombination von Euklidkriterium und z-Normierung die stabilsten und genauesten Ergebnisse. Für das Abstandsmaß γ erwies sich ein Wert von $\gamma = 2$ am geeignetsten.. Für $\gamma = 1$ kam es zu Untersegmentierungen, für $\gamma = 3$ zu Übersegmentierungen.

Wesentliche Unterschiede hinsichtlich Genauigkeit waren zwischen Coocce-rencebasierten sowie waveltbasierten Verfahren nicht festzustellen, beide Verfahren waren jedoch den Merkmalen aus lokalem Mittelwert und lokaler Varianz überlegen. Beim Vergleich mit einem skalaren Region-Growing konnten keine Vorteile der texturbasierten Verfahren beobachtet werden. Einzig bei den Tagging-MR Bildern konnten die texturbasierten Verfahren dominieren, da das skalare Region-Growing bedingt durch die Tagging-Linien in einigen Fällen

zum Auslaufen führte. Bei optimal eingestelltem Grauwertintervall konnte jedoch auch das Tagging-Bild mit dem skalaren Region-Growing zufriedenstellend segmentiert werden.

4 Diskussion

Die Ergebnisse an dem betrachteten Bildmaterial zeigen, dass eine Verwendung von texturanalytischen Verfahren für die interaktive Segmentierung keine nennenswerten Vorteile bringt. Zum einen resultierten daraus keine signifikant besseren Segmentierungsergebnisse, zum anderen sind die Rechenzeiten zur Merkmalsextraktion momentan zu hoch. Problematisch ist auch die Vielzahl an Methoden und zugehörigen Parametern, die für jedes zu segmentierende Organ und von Modalität zu Modalität anders einzustellen und zu optimieren sind. Für spezielle Bilddaten wie dem Tagging-MR, welches charakteristische Texturen bedingt durch die Tagging-Linien aufweist, können texturbasierte Verfahren jedoch durchaus wertvoll sein. Eine Evaluation an weiterem Bildmaterial insbesondere mit schwierig zu segmentierenden Organregionen wie z.B. die Grenze zwischen Leber- und Herzgewebe, wo ein herkömmliches skalares Region-Growing versagt, soll weiteren Aufschluss über den Nutzen von interaktiven, texturanalytischen Segmentierungsverfahren geben.

5 Danksagung

Von MeVis Technology aus Bremen wurde uns freundlicherweise die MT-WICE Bibliothek zur Berechnung der Wavelettransformationen zur Verfügung gestellt. Die Forschungsarbeit wurde von der Deutschen Forschungsgemeinschaft im Rahmen des SFB 414 "Informationstechnik in der Medizin - Rechner und Sensor-gestützte Chirurgie" gefördert.

Literatur

1. Haralick R.M., Shanmugan K., Dinstein I.: Texture Features for Image Classification. *IEEE Trans. on Systems, Man and Cybernetics*, 3(6): 610–621, 1973.
2. Mallat S.: A theory for multiresolution signal decomposition. *IEEE PAMI*, 11: 674–693, 1989
3. Chang T., C.C.Kuo: Tree-structured Wavelet Transform for Textured Image Segmentation. *IEEE Trans. on Image Processing*, 2(4):429–441, 1993
4. Busch Ch.: Wavelet Based Texture Segmentation of Multi-Modal Tomographic Images. *Computer and Graphics*, 21(3): 347–358, 1997
5. Zahlten C., Jürgens H., Peitgen H.O.: Portal vein reconstruction based on topology. *European Journal of Radiology*, 19: 96–100, 1995
6. Cárdenas C.E., Braun V., Hassenpflug P., Thorn M., Hastenteufel M., Kunert T., Vetter M., Fischer L., Lamade W., Meinzer H.P.: Ein framework für die Implementierung von Anwendungssystemen zur Verarbeitung und Visualisierung von medizinischen Bildern. *Bildverarbeitung für die Medizin. Algorithmen, Systeme, Anwendungen*. Springer Verlag, Berlin, Auflage 2001