

Automatische Generierung von Bildmerkmalen für die Segmentierung von CT-Bilddaten mit deformierbaren Modellen

M. P. Mienkina¹, V. Pekar², F. Hoffmann³ und M. R. Kaus²

¹Lehrstuhl für Medizintechnik, Ruhr-Universität Bochum

²Philips Forschungslaboratorien, Sektor Technische Systeme, Hamburg

³Lehrstuhl Elektrische Steuerung und Regelung, Universität Dortmund

Email: martin.mienkina@rub.de

Zusammenfassung. Es wird eine Methode zur Segmentierung von anatomischen Strukturen mit dreidimensionalen, deformierbaren Formmodellen basierend auf Organwahrscheinlichkeitskarten vorgestellt. Diese Karten sind das Ergebnis eines überwachten, Texturmerkmale nutzenden Klassifikationssystems, das den Voxeln der CT-Bilddaten die Wahrscheinlichkeit der Zugehörigkeit zur gesuchten Organklasse zuordnet. Das Formmodell führt seine Adaption beruhend auf einer Organwahrscheinlichkeitskarte aus, was eine automatische Übertragung des Modells zur Segmentierung neuer Organe ermöglicht. Für die Segmentierung von 13 Ohrspeicheldrüsen bzw. 9 Harnblasen wurde eine mittlere Entfernung zur manuellen Segmentierung eines Klinikers von 1,71 mm bzw. 2,52 mm erreicht, im Vergleich zu 4,99 mm bzw. 2,39 mm einer grauwertbasierten Modelladaption.

1 Einleitung

Strahlentherapie wird häufig für die Behandlung von Krebs eingesetzt. Innerhalb eines Zielvolumens soll tumoröses Gewebe durch die Applikation von ionisierender Strahlung zerstört und Risikoorgane möglichst einer geringen Strahlenbelastung ausgesetzt werden. Um dies zu erreichen, benutzen moderne Verfahren wie die intensitätsmodulierte Strahlentherapie z.B. die inverse Strahlentherapie-Planung. Diese Planung benötigt Informationen über die Positionen von Zielvolumen und Risikoorganen, die durch eine Segmentierung erlangt werden.

Die Segmentierung von Weichteilen mittels Computer Tomographie (CT) Bilddaten erweist sich auf Grund des unzureichenden Kontrasts zwischen Weichteilen und umgebendem Gewebe sowie vieler Bildartefakte als schwierig. Zwei wichtige Organe für die Radiotherapieplanung sind die Ohrspeicheldrüse und die Harnblase. Allein auf Bildinformationen basierende, klassische Mustererkennungssysteme ohne Organmodell scheitern daher vielfach. Deswegen wird oft zusätzliches a-priori Formwissen von deformierbaren Formmodellen zur automatischen Segmentierung anatomischer Strukturen in Bilddatensätzen eingesetzt. Neben der Formvariabilität erfordert jedoch vor allem die Variabilität der

Erscheinung verschiedener Organe in der diagnostischen Abbildung eine organspezifische Erstellung der Modelle. Bei der Übertragung bewährter Modelle auf neue Organklassen ist deshalb eine aufwändige Rekonfiguration der Modellparameter erforderlich, zu deren Durchführung Detailkenntnisse des Algorithmus des deformierbaren Modells notwendig sind.

2 Stand der Forschung

Die Adaption eines deformierbaren Modells an eine anatomische Struktur erfolgt typischerweise über die Minimierung der gewichteten Summe einer internen Energie und einer externen Energie. Die interne Energie gewährleistet die Formstabilität des Modells, und die externe Energie sorgt für die Anziehung des Modells zur Oberfläche der gesuchten Struktur.

McInerney und Terzopoulos haben eine Vielzahl von deformierbaren Modellen [1] untersucht. Es kann unterschieden werden zwischen deformierbaren Modellen, die ein statistisches Modell der Kontur besitzen, wie z.B. Active Appearance Models (AAM) oder Active Shape Models (ASM). Im Gegensatz dazu adaptieren Active Contour Models bzw. Geodesic Active Contours unter bestimmten Randbedingungen an das vorliegende Bildmaterial ohne a-priori Formmodell. Pekar et al. [2] haben diese beiden Methoden kombiniert und erreichen dadurch eine Inkorporation von Formwissen in Verbindung mit einer großen Deformationsfreiheit gegenüber möglichen anatomischen Anomalien. Als externe Energie dienen die Grauwertintensität und der Grauwertgradient, die jedoch nur beim Adaptionprozess berücksichtigt werden, wenn diese innerhalb festgelegter Intervalle liegen. Auf Grund der großen Unterschiede zwischen der Repräsentation z.B. eines Knochens und einer Blase in CT-Datensätzen, ist eine manuelle Anpassung der Parameter der externen Energie an neue zu detektierende Struktur-Konturen notwendig.

Es wurden Versuche unternommen, die externe Energie automatisch an neue anatomische Strukturen anzupassen z.B. [3, 4, 5, 6]. Jedoch werden hierbei entweder primitive Merkmale wie der Grauwert bzw. Grauwertgradient benutzt, oder ein Mustererkennungssystem wird ohne dezidierte Evaluation der Systemkomponenten implizit zur Generierung der externen Energie benutzt.

3 Methoden

Im Rahmen dieser Arbeit wird eine automatische Anpassung der externen Energie des deformierbaren Modells an neue anatomische Strukturen durch die Ausführung des Adaptionprozesses auf einer Organwahrscheinlichkeitskarte anstatt auf dem Grauwertbild vorgestellt. Auf Grundlage des Klassifikationsergebnisses eines Mustererkennungssystems wird jedem Voxel die Wahrscheinlichkeit zugeordnet, zur gesuchten Organklasse zu gehören. Dadurch ist die Kontur einer anatomischen Struktur unabhängig von der Erscheinungsform des Organs im Bilddatenmaterial als eine Zone hoher Organzugehörigkeitswahrscheinlichkeit

Tabelle 1. Vergleich von Texturanalyse-Methoden basierend auf einem 7-ANN Klassifikator bei 16 Ohrspeicheldrüsen Datensätzen. Es wird eine 100x100 Pixel große ROI um die Ohrspeicheldrüse eingesetzt. Es wird eine totale Kreuzvalidierung durchgeführt. Bei 3 von 16 CT-Datensätzen versagen alle Verfahren (Sensitivität < 15%). Std. Abw.: Standard Abweichung. A-OCC: Fläche unter der Operating Characteristic Curve (vgl. [12]) basierend auf 7 Datensätzen.

	Sensitivität [%] (Std. Abw.)	Spezifität [%] (Std. Abw.)	Hit-Rate [%] (Std. Abw.)	A-OCC [%]
GROI	40,32 (21,59)	95,12 (1,98)	89,46 (3,32)	89,49
Gabor	38,70 (19,21)	95,52 (1,70)	89,92 (3,05)	90,11
LM	39,78 (22,64)	95,33 (2,19)	89,90 (2,96)	90,13

definiert. Weiterhin wird es möglich, fortgeschrittene Methoden wie die Texturanalyse zur Merkmalsextraktion zu benutzen und das Mustererkennungssystem einer Evaluation zu unterziehen und zu optimieren. Unabhängig von dieser Arbeit entwickelten Pujol und Radeva [7] ein ähnliches System, das die Wahrscheinlichkeit der Zugehörigkeit zur Zieltextrur als Adaptionkriterium benutzt, für die Segmentierung von Intravaskulären Ultraschall (IVUS) Bilddaten.


Für das Klassifikationssystem wurden als Texturanalyse-Methoden Gabor Filterbänke [8], Leung-Malik (LM) Filterbänke [9] und Grauwertumgebungen (GROI) [10] eingesetzt. Als Klassifikator wurde der Approximate Nearest Neighbor (ANN)[11] Algorithmus angewandt. Auf Grundlage einer manuellen Segmentierung erfolgte eine quantitative Analyse der Klassifikationsleistung. Unter der Annahme, dass eine hohe Klassifikationsleistung auch zu einer exakten Segmentierung der gesuchten anatomischen Struktur durch das auf der Organwahrscheinlichkeitskarte basierende deformierbare Modell führt, wurde ein entsprechendes Klassifikationssystem ausgewählt. Um die Segmentierungsleistung der traditionellen und auf Organwahrscheinlichkeitskarten basierenden deformierbaren Modelle zu evaluieren, wird die euklidische Distanz zwischen der Oberfläche des adaptierten Modells und der manuellen Segmentierung berechnet.

4 Ergebnisse

Auf Grundlage der Klassifikation von Ohrspeicheldrüsen in 16 CT-Datensätzen wurde die Grauwertumgebung [10] in Verbindung mit einem 7-ANN Klassifikator für die Segmentierung ausgewählt (vgl. Tab. 1). Die höchste Sensitivität und geringste Komplexität dieses Systems sind ausschlaggebend. Tentative Experimente mit einem Gauß-MAP Klassifikator und Ada-Boost zeigen deren Versagen für diese Anwendung.

Basierend auf diesem Mustererkennungssystem wurden mittels totaler Kreuzvalidierung 13 Ohrspeicheldrüsen-Wahrscheinlichkeitskarten erzeugt. Das darauf beruhende Formmodell weist eine mittlere Abweichung von 1,71mm zur manuellen Ohrspeicheldrüsen-Segmentierung auf. Das nur die Grauwertinformationen als externe Energie nutzende Formmodell erzielt eine mittlere Abweichung von

Abb. 1. Darstellung der Segmentierung der Ohrspeicheldrüse in CT-Bilddaten mit zwei orthogonalen Schnittebenen. Deutlich ist ein Streak Artefakt auf Grund einer metallischen Zahnfüllung zu sehen. '1' entspricht einer Segmentierung mittels Organwahrscheinlichkeitskarten, '2' zeigt die grauwertbasierte Segmentierung, 'manuell' entspricht der manuellen Segmentierung.




4,99mm. Ein gepaarter t-Test der Segmentierungsergebnisse der beiden Methoden ergibt eine Wahrscheinlichkeit der Nullhypothese von $p=0,004$. Es wurden Datensätze mit einer Voxelgröße von $0,9375 \times 0,9375 \times 1,25 \text{mm}^3/\text{voxel}$ und $0,70312 \times 0,70312 \times 1,25 \text{mm}^3/\text{voxel}$ evaluiert. Das neue Verfahren wird anschließend für die Blasensegmentierung automatisch trainiert und liefert bei der Segmentierung von 9 Blasen im Mittel einen Abstand von 2,52mm zur manuellen Segmentierung. Ein traditionelles, speziell zur Blasensegmentierung entwickeltes Formmodell erreicht eine mittlere Abweichung von 2,39mm ($p=0,671$). In Abb. 1 und Abb. 2 ist ein Beispiel der Ohrspeicheldrüsen- bzw. Harnblasen-Segmentierung dargestellt.

5 Diskussion

Es wurde ein neues Verfahren entwickelt, das ein texturbasiertes Mustererkennungssystem nutzt, um die Parameter eines deformierbaren Modells automatisch für den Einsatz bei neuen Organklassen zu konfigurieren. Bei der Ohrspeicheldrüsen Segmentierung versagt das traditionelle, grauwertbasierte Verfahren, wohingegen das auf Organwahrscheinlichkeitskarten basierende Verfahren trotz starker Behinderung durch Streak Artefakte eine zuverlässige Segmentierung durchführt (4,99mm mittlerer Abstand zur manuellen Segmentierung gegenüber 1,71mm). Für die Segmentierung der Blase liefern ein speziell zur Blasensegmentierung entwickeltes, graubasiertes Modell und das automatisch rekonfigurierte, auf Organwahrscheinlichkeitskarten basierende Modell statistisch nicht signifikant differierende Ergebnisse (2,39mm gegen 2,52mm).

Die Kombination eines Mustererkennungssystems und eines deformierbaren Modells führt somit einerseits zu einer zuverlässigen Segmentierung von anatomi-

Abb. 2. Darstellung der Segmentierung der Harnblase in zwei orthogonalen Ebenen.



schen Strukturen in CT-Bilddaten, andererseits wird es Nutzern ohne algorithmische Detailkenntnisse ermöglicht, deformierbare Modelle zur Segmentierung neuer Organklassen einzusetzen.

Literaturverzeichnis

1. McNerney T, Terzopoulos D. Deformable Models in Medical Imaging Analysis: A Survey. *Med Image Anal* 1996;1(2):91–108.
2. Pekar V, McNutt TR, Kaus MR. Automated model-based organ delineation for radiotherapy planning in prostatic region. *Int J Radiat Oncol Biol Phys* 2004;60(3):973–980.
3. Kaus MR, von Berg J, Niessen W, et al. Automated Segmentation of the Left Ventricular in Cardiac MRI. In: *Proc MICCAI*; 2003. p. 432–439.
4. von Ginneken B, Frangi AF, Staal JJ, et al. Active Shape Model Segmentation with Optimal Features. *IEEE Trans Med Imaging* 2002;21(8):924–933.
5. Fenster SD, Kender JR. Sectorized Snakes: Evaluating Learned-Energy Segmentations. *IEEE Trans Pattern Anal Machine Intell* 2001;23(9):1028–1034.
6. Paragios N, Deriche R. Geodesic active contours and level set methods for supervised texture segmentation. *Int J Comput Vis* 2002;46(3):223–247.
7. Pujol P, Radeva P. Texture Segmentation by Statistical Deformable Models. *Int J Image and Graphics* 2004;4(3):433–452.
8. Jain AK, Farrokhnia F. Unsupervised Texture Segmentation Using Gabor Filters. *Pattern Recogn* 1991;24(12):1167–1186.
9. Malik J, Belongie S, Leung TK, et al. Contour and Texture Analysis for Image Segmentation. *Int J Comput Vis* 2001;43(1):7–27.
10. Varma M, Zisserman A. Texture Classification: Are Filter Banks Necessary? In: *Proc CVPR*; 2003. p. 691–698.
11. Arya S, Mount DM. Approximate nearest neighbor searching. In: *Proc SODA*; 1993. p. 271–280.
12. Duda RO, Hart PE, Stork GS. *Pattern Classification*. Wiley, New York; 2001.