Automatische Endokarderkennung in 3D mit approximierenden Thin-Plate-Splines unter Einsatz von Gauß'schen Mischverteilungs-Modellen für die lokale Klassifikation

Schreckenberg M, Dahmen J*, Schummers G, Gueld M*, Meyer-Ebrecht D, Ney H*

Lehrstuhl für Messtechnik und Bildverarbeitung
*Lehrstuhl für Informatik VI
Rheinisch-Westfälische Technische Hochschule (RWTH), 52057 Aachen

Zusammenfassung. Bei der Segmentierung von verrauschten Ultraschalldaten haben sich deformierbare Oberflächenmodelle (hier Thin-Plate-Splines) bewährt, die lokale Fehler durch ihre regularisierenden Eigenschaften korrigieren können. Durch Ankopplung der Merkmalextraktion an das Oberflächenmodell können wir darüber hinaus sowohl bekannte Anisotropien in den Bilddaten gewinnbringend ausnutzen, als auch geometrische Merkmale hinzufügen. Zur Optimierung der lokalen Schätzung der Grenzflächen führen wir die Detektion auf ein 2-Klassen-Problem unter Verwendung von Gauß'schen Mischverteilungen zurück. Die Ergebnisse zeigen, dass durch Hinzunahme geometrischer Merkmale die Fehlerrate bei der lokalen Klassifikation signifikant gesenkt werden kann.

Schlüsselwörter: Aktive Oberfläche, Gauß'sche Mischverteilungen, approximierende Thin-Plate-Splines, Ultraschall, Klassifikation

1 Einleitung

Dieser Beitrag befasst sich mit der Detektion der Endokardkontur des linken menschlichen Ventrikels in 3D-Echokardiographiesequenzen (d.h. 4D Datensätzen). Das Endokard grenzt als auskleidende Haut den blutgefüllten Innenraum der Herzkammer (Cavum) vom Herzmuskel (Myokard) ab. Die Kenntnis der Endokardkontur, insbesondere ihre Bewegung über einen Herzyklus hinweg, erlaubt die quantitative Erfassung diagnostisch relevanter funktioneller Parameter (z.B. Volumen, Ejektionsfraktion, regionale Wandbewegung). Aufgrund der anfallenden Datenmengen sind stabile automatische Detektionsverfahren Voraussetzung für quantitative Messungen. Bilddaten aus der Echokardiographie sind im Allgemeinen zu stark verrauscht, um allein basierend auf der lokalen Grauwertinformation eine zuverlässige Segmentierung durchführen zu können. Es ist vielmehr notwendig, a priori Wissen sowohl über das Abbildungsverfahren als auch über das abgebildete Objekt hinzu zu nehmen. Speziell bei stückweise glatt berandeten Objekten lässt sich globales Kontextwissen gut durch deformierbare Oberflächen modellieren.

2 Thin-Plate Splines versus Aktive Oberflächen

Die globale Glattheit der Modelloberfläche lässt sich durch ihre Krümmungsenergie beschreiben:

$$J_2^2 = \iint \left(\frac{\delta^2 \overrightarrow{X}}{\delta^2 u} + \frac{\delta^2 \overrightarrow{X}}{\delta u \delta v} + \frac{\delta^2 \overrightarrow{X}}{\delta^2 v} \right) du dv \tag{1}$$

$$\overrightarrow{X} \in \mathbb{R}^3, \;\; u \in [-\pi, \pi[, \;\; v \in [-\frac{\pi}{2}, \frac{\pi}{2}]$$

Die Oberfläche soll nun so angepasst werden, dass sie einerseits die lokalen Grenzflächen in den Daten möglichst gut approximiert, andererseits jedoch den Modellannahmen entsprechend glatt bleibt. Im Gegensatz zu dem weit verbreiteten Ansatz, die Oberflächenmodelle durch Minimierung eines Energieterms zu adaptieren [1, 2, 3], betrachten wir hier das vorliegende Problem als Approximationsproblem. Als Oberflächenmodell setzen wir ein auf radialen Basisfunktionen basierendes Thin-Plate-Spline Modell ein, das eine kontinuierliche Darstellung der Modelloberfläche erlaubt, d.h. keine Diskretisierung erfordert.

$$\overrightarrow{X}(u,v) = \overrightarrow{A} + \sum_{i=1}^{n} \overrightarrow{w_i} U(r_i\left((u_i, v_i), (u,v)\right)); \quad U(r) = r^2 \log r \tag{2}$$

$$r_i\left((u_i, v_i), (u,v)\right) = a\cos(\cos(a)\cos(b) + sin(a)sin(b)cos(c))$$

$$a = \frac{\pi}{2} - v_i \quad b = \frac{\pi}{2} - v \quad c = u - u_i \quad c \in [-\pi, \pi[$$

Die Vektoren (u_i, v_i) bezeichnen hierbei die Zentren der Basisfunktionen im 2D Parameterraum, $\overrightarrow{w_i}$ die jeweiligen Gewichte, $\overrightarrow{X}$ den zugehörigen Punkt in $\mathbb{R}^3$ und $\overrightarrow{A}$ den Aufvektor. Der Ansatz (2) minimiert das Energiefunktional (1) für gegebene Stützpunkte $\overrightarrow{X_i}(u_i, v_i)$ [4, 5]. Diese Interpolation kann zu einer Approximation erweitert werden, indem man die Position dieser Stützpunkte als Modell-Freiheitsgrade auffasst und sie so legt, dass (3) minimiert wird.

$$F = \sum g_j \| \overrightarrow{X_j'}(u_j, v_j) - \overrightarrow{X}(u_j, v_j) \| \tag{3}$$

Bei als bekannt angenommenen Zielpunkten $\overrightarrow{X_j'}(u_j, v_j)$ kann das resultierende überbestimmte LGS so in einem einzigen Schritt berechnet werden [6] . Hier liegt ein wesentlicher Vorteil gegenüber herkömmlichen Aktiven Oberflächen, bei denen die Lösung auch bei bekannten $\overrightarrow{X_j'}(u_j, v_j)$ iteriert werden muss.

3 Extraktion lokaler Merkmale

Wir fassen die aktuelle Position der Modelloberfläche im Raum als stetig genauer werdende Approximation des Endokards auf. Mangels zuverlässig verfolgbarer lokaler Strukturen in tangentialer Richtung werden Korrekturen der Oberfläche nur in Richtung ihrer Flächennormalen vorgenommen (Blendenproblem) [7]. Das vorliegende Bildmaterial weist eine Reihe bekannter Eigenschaften auf:

- es treten aufgrund von Interferenzeffekten Speckles auf

– die Verteilungsfunktion der Grauwerte (Einhüllende der Rückstreuamplituden) kann als k-verteilt modelliert werden
– die Grauwerte hängen von der Entfernung zwischen Ort der Rückstreuung und Transducer, vom angeschallten Gewebe und vom Einfallwinkel ab

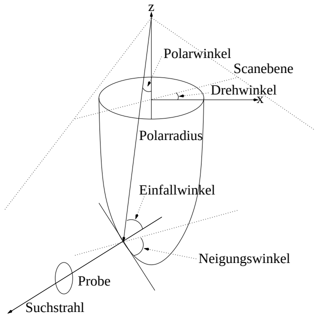

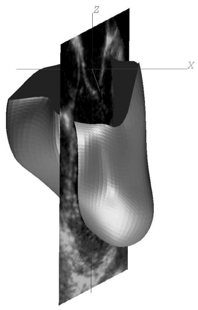

Abb. 1. Extraktion der Merkmale und rekonstruierter Ventrikel

Entlang eines Suchstrahls, der in Richtung der Flächennormalen orientiert ist, werden in einer lokalen Umgebung (Radius: 5 pixel) Grauwertstichproben gewonnen. Daraus werden empirischer Mittelwert und empirische Varianz berechnet. Als geometrische Merkmale werden die Polarkoordinaten der Probe relativ zum Transducer, die Neigung der Modelloberfläche an dieser Stelle und der Einfallwinkel verwendet (s. Abb. 1 (links)). Mit dem im nächsten Abschnitt beschriebenen Mischverteilungsmodell wird basierend auf den beobachteten Merkmalen x die Wahrscheinlichkeit $p(k|x)$ geschätzt, wobei nur die 2 Klassen 'Cavum' und 'Myokard' verwendet werden ($K = 2$). Die Wahrscheinlichkeit $p(2|x)$ (Myokard) wird entlang des Suchstrahls aufgetragen. Die lokale Grenzfläche wird an der Stelle des maximalen positiven Gradienten erwartet. Negative Gradienten werden durch 0 ersetzt (Aussenhaut). Die jeweilige Größe des Gradienten wird als Gewicht g_j bei der Oberflächenapproximation verwendet (3).

4 Lokale Klassifikation über Gauß'sche Mischverteilungen

Für die Klassifikation einer Beobachtung x verwenden wir die Bayes'sche Entscheidungsregel [8]:

$$x \longmapsto r(x) = \underset{k}{\operatorname{argmax}} \{p(k)p(x|k)\} \tag{4}$$

Dabei ist $p(k)$ die a-priori Wahrscheinlichkeit der Klasse k, $p(x|k)$ die klassenbedingte Wahrscheinlichkeit für eine Beobachtung x gegeben die Klasse k und $r(x)$ die Entscheidung des Klassifikators. Da weder $p(k)$ noch $p(x|k)$ bekannt sind, müssen Modelle für diese Verteilungen gewählt und deren Parameter aus den Trainingsdaten geschätzt werden. Bei konvergiertem Oberflächenmodell und symmetrischem Suchstrahl ist hier $p(k) = \frac{1}{2}$. Mit einer Mischverteilung, d.h. einer Linearkombination von Gauß'schen Normalverteilungen $\mathcal{N}(x|\mu_{ki}, \Sigma_{ki})$, die im folgenden auch Mischverteilung-Komponenten genannt werden, setzen wir:

$$p(x|k) = \sum_{i=1}^{I_k} c_{ki} \cdot \mathcal{N}(x|\mu_{ki}, \Sigma_{ki}) \tag{5}$$

Dabei ist I_k die Anzahl der verwendeten Normalverteilungen zur Modellierung der Klasse k, c_{ki} sind Gewichte (mit $c_{ki} > 0$ und $\sum_{i=1}^{I_k} c_{ki} = 1$), μ_{ki} ist der empirische Mittelwertsvektor und Σ_{ki} die empirische Kovarianzmatrix der i-ten Normalverteilung der Klasse k.

Um eine zuverlässige Schätzung der Kovarianzmatrix zu ermöglichen, verwenden wir global gepoolte Kovarianzmatrizen, d.h. wir schätzen nur ein einziges Σ mit $\Sigma_{ki} = \Sigma$ für alle k und i [9]. Die Bestimmung der Parameter erfolgt unter Verwendung des Expectation-Maximization (EM) Algorithmus. Weitere Informationen zu diesem Thema finden sich in [10].

5 Ergebnisse und Diskussion

Der Trainings- und Testdatensatz wurde aus 20 handkonturierten Datensätzen gewonnen. Dabei wurden über 700.000 lokale Stichproben erzeugt. 10% davon wurden zum Test des lokalen Klassifikators verwendet, der Rest zum Training. Die erzielten Fehlerraten sind Abb. 2 zu entnehmen.

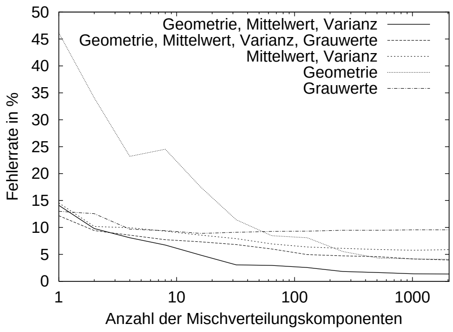

Abb. 2. Klassifikationsfehler bei verschiedenen Kombinationen von Merkmalen

Es ist deutlich zu erkennen, dass die Hinzunahme der unverarbeiteten Grauwerte sogar zu einer Verschlechterung der Klassifikation führt. Besonders bemerkenswert ist, dass die geometrischen Maße einen in etwa gleichwertigen Beitrag leisten wie Mittelwert und Varianz. Allerdings erfordert die Approximation ihrer Verteilung deutlich mehr Mischverteilung-Komponenten. In der Kombination werden die besten Ergebnisse erreicht.
Die mittlere Konturabweichung zwischen Handkontur und automatisch gefundener beträgt bei den verwendeten Daten -0.9 pixel, d.h. das Ventrikelvolumen wird gegenüber den Handkonturen geringfügig unterschätzt.

Abb. 1 (rechts) zeigt das Thin-Plate-Spline Modell des rekonstruierten Ventrikels. Die einzige manuelle Interaktion bestand im Zuschnitt des oberen Ventrikelrands. Für die Berechnung der Modelloberfläche eines typischen Volumendatensatzes werden derzeit 30 Minuten pro zeitlicher Phase benötigt.

Die erzielte Qualität der Konturfindung liegt im Bereich manueller Konturierung. Der hohe Rechenaufwand liegt im Wesentlichen in der Klassifikation begründet (die Approximation des gesamten Oberflächenmodells selbst wird in weniger als 30 s geleistet). Die Resultate wurden mit 2048 Mischverteilung-Komponenten pro Klasse erzielt. Durch diskriminatives Training (anstelle des bislang verwendeten EM-Trainings) kann diese Anzahl erfahrungsgemäß bei nur geringfügig verschlechtertem Klassifikationsfehler drastisch reduziert werden [11]. Der Geschwindigkeitsgewinn ist dabei annähernd linear.

Wir danken H. Kühl und A. Januschke, *MK I, Klinikum RWTH Aachen* für das bereitgestellte Bildmaterial und das Konturieren der Daten.

Literatur

1. V. Chalana et al, “A Multiple Active Contour Model for Cardiac Boundary Detection on Echocardiographic Sequences ”, *IEEE Trans. Med. Img.* , 15:3, 1996
2. T. McInerney, D. Terzeopoulos, “A dynamic finite element surface model for segmentation and tracking in multidimensional medical images with application to cardiac 4D image analysis”, *Computerized Medical Imaging and Graphics*, 19:1, pp. 69-83, 1995
3. R. Ronfard, “Region-Based Strategies for Active Contour Models”, *International Journal of Computer Vision*, 13:2, pp. 229-251, 1994
4. F.L. Bookstein, “Principal Warps: Thin-Plate Splines and the Decomposition of Deformations”, *IEEE Trans. on Pattern Anal. and Machine Intell.*, 11:6, pp. 567-585, 1989
5. G. Wahba, “Spline Models for Observational Data”, *Society for Industrial and Applied Mathematics*, Philadelphia, Pennsylvania, 1990
6. M. Schreckenberg, G. Schummers, D. Meyer-Ebrecht, “3D-Vermessung der regionalen Wandverdickung des Herzmuskels in 3D-Echokardiographiesequenzen”, *21. DAGM Symposium Mustererkennung 1999*, pp. 284-291, Bonn, Germany, 1999
7. M. Schreckenberg, G. von Dziembowski, D. Meyer-Ebrecht, “Erkennung deformierbarer Konturen und Oberflächen in verrauschten Bilddaten durch Einsatz modellgekoppelter anisotroper Merkmalsextraktoren”, *20. DAGM Symposium Mustererkennung 1998*, pp. 219-226, Stuttgart, Germany, 1998
8. R. Duda, P. Hart, ”Pattern Classification and Scene Analysis”, Wiley & Sons, 1973
9. J. Dahmen, J. Hektor, R. Perrey, H. Ney, “Automatic Classification of Red Blood Cells using Gaussian Mixtures Densities”, *Bildverarbeitung für die Medizin 2000*, Munich, Germany, 2000
10. J. Dahmen, K. Beulen, H. Ney, “Objektklassifikation mit Mischverteilungen”, *20. DAGM Symposium Mustererkennung 1998*, pp. 167-174, Stuttgart, Germany, 1998
11. J. Dahmen, R. Schlüter, H. Ney, “Discriminative Training of Gaussian Mixtures for Image Object Recognition”, *21. DAGM Symposium Mustererkennung 1999*, pp. 205-212, Bonn, Germany, 1999