

# Automatische Erstellung von gleichmäßig verteilten Landmarken für statistische Formmodelle

Tobias Heimann, Ivo Wolf und Hans-Peter Meinzer

Abteilung für Medizinische und Biologische Informatik,  
Deutsches Krebsforschungszentrum, 69120 Heidelberg  
Email: t.heimann@dkfz.de

**Zusammenfassung.** Die Minimierung der Beschreibungslänge (MDL) ist eine der vielversprechendsten Methoden, um automatisch die nötigen Punkt-Korrespondenzen für die Erstellung statistischer Formmodelle zu bestimmen. Bisher gibt es allerdings keine Möglichkeit, die Verteilung der erstellten Landmarken auf dem Modell zu beeinflussen, was zu unzureichenden Formdarstellungen führen kann. In dieser Arbeit erweitern wir eine bekannte Methode, welche die Punkte auf einem einzelnen Gitternetz (Mesh) neu konfiguriert, für den Einsatz mit statistischen Formmodellen. In einer abschließenden Evaluation mit Lungen- und Leberdatensätzen zeigen wir, dass unser Verfahren die Generalisierungsfähigkeit und Spezifität der generierten Modelle signifikant verbessert.

## 1 Einleitung

In der medizinischen Bildverarbeitung ist die automatische Segmentierung dreidimensionaler Datensätze noch immer ein weitgehend ungelöstes Problem. Beachtliche Erfolge wurden in den letzten Jahren bei der Verwendung statistischer Formmodelle (auch „Active Shape Models“) [1] erzielt. Hierbei orientiert sich der Computer an einem statistischen Modell der zu findenden Strukturen, das aus einer Menge von Trainingsdaten gewonnen wird. Um ein solches Modell zu erstellen, muss zuerst eine Anzahl korrespondierender Punkte oder Landmarken auf den Trainingsdaten gefunden werden. Zur Lösung dieses Problems existieren mehrere unterschiedliche Ansätze: Eine Möglichkeit ist, die Landmarken durch Registrierung mit einem deformierbaren Template, z.B. mit Hilfe von Thin-Plate-Splines, auf jedes Trainingsmuster abzubilden. Auch über eine geeignete Parametrisierung der Formen wie Spherical Harmonics können Korrespondenzen ermittelt werden. Wir nutzen in unserer Arbeit einen dritten Ansatz, bei dem die Korrespondenzen von einem Initialzustand aus iterativ verbessert werden. Dazu werden ebenfalls Parametrisierungen genutzt, die aber durch eine Kostenfunktion über die Güte des Modells optimiert werden. Die besten Ergebnisse wurden bis jetzt mit einer auf MDL basierenden Kostenfunktion [2] erreicht.

In diesem Beitrag beschäftigen wir uns speziell mit dem Problem der fehlenden Kontrolle über die Verteilung der Landmarken auf den einzelnen Trainingsformen: Da das MDL-Verfahren dazu tendiert, Landmarken von starken

Ausbuchtungen der Formen weg zu bewegen, können sich durch die resultierende ungleichmäßige Triangulierung beträchtliche Differenzen zwischen den Trainingsdaten und ihrer Repräsentation im Modell ergeben (Abb. 1(a)). Gleichmäßig verteilte Landmarken wären hier, genauso wie bei der Nutzung des Modells für die Segmentierung, von großem Vorteil.

## 2 Grundlagen

Um ein statistisches Formmodell zu erstellen, müssen auf allen Trainingsdaten zuerst korrespondierende Landmarken positioniert werden. Beim MDL-Verfahren werden diese Landmarken nicht direkt auf den Eingangsdaten platziert, stattdessen wird jede 3D-Oberfläche zuerst in eine simplere Form überführt und die einzelnen Punkte dort initialisiert und modifiziert. Für Objekte ohne Löcher und Selbstüberschneidungen (Genus 0) ist dieser Parameterraum kugelförmig und über Längen- und Breitengrade definiert. Wir verwenden das in [3] vorgestellte Verfahren, um konforme (winkeltreue) Parametrisierungen  $\Omega$  für alle Trainingsdaten zu erzeugen. Eine beliebige Menge von Punkten  $\Psi$ , normalerweise gleichmäßig auf der Kugel verteilt, lässt sich dann über die Parametrisierungsfunktion  $\Omega_i$  in den Objektraum transformieren und repräsentiert dort das  $i$ -te Trainingsmuster.


Um die initialen, weitgehend zufälligen, Korrespondenzen zu verbessern, lassen wir  $\Psi$  konstant und modifizieren stattdessen die Parametrisierungsfunktionen  $\Omega_i$ , wodurch die Landmarken im Objektraum ebenfalls verschoben werden. Als Optimierungsmethode kommt ein Gradientenabstiegsverfahren zum Einsatz, welches die Parametrisierungen in lokal beschränkten Bereichen auswertet und durch eine Gauss'sche Hüllkurve moduliert in die optimale Richtung verschiebt. Die technischen Details dieses Verfahrens sind in [4] beschrieben.

Die Korrespondenz zwischen den einzelnen Trainingsmustern ist somit ausschließlich durch die Parametrisierungen gegeben, die Punkte auf der Kugel  $\Psi$  sind für alle Trainingsdaten gleich und bestimmen nur noch die Verteilung der Landmarken. Dadurch sind wir in der Lage, diese Punkte zu jedem beliebigen Zeitpunkt umzustrukturieren, ohne die Korrespondenzen zu verlieren.

## 3 Umverteilen von Landmarken

Um eine bestimmte Landmarkenverteilung im Objektraum zu erreichen, verwenden wir eine Modifikation des in [5] beschriebenen Verfahrens, welches zur Umverteilung der Knotenpunkte eines Meshes entwickelt wurde und zusammengefasst wie folgt funktioniert: Die gewünschte Punktdichte wird in einem zweidimensionalen Parameterraum durch ein Graustufenbild kodiert, wobei eine hohe Dichte durch helle Pixel repräsentiert wird. Um eine gleichmäßige Verteilung der Knotenpunkte zu erzielen, wird für jedes Dreieck des Meshes ein Verzerrungsfaktor berechnet, der sich aus der Dreiecksfläche im Objektraum geteilt durch die Dreiecksfläche im Parameterraum ergibt. Alle Dreiecke werden mit ihrem Verzerrungsfaktor als Farbe im Parameterraum gren-

**Abb. 1.** (a) Die stark schwankende Landmarkendichte führt zu einer unzureichenden Beschreibung der transparenten Trainingsform durch das Modell. (b) Auf der Verzerrungskarte im Parameterraum sind die unterbesetzten Regionen deutlich zu erkennen. (c) Dithering der Karte und eine Delaunay-Triangulierung liefern die Positionen der neuen Landmarken. (d) Zurück in den Objektraum transformiert, sind alle Landmarken gleichmäßig verteilt und beschreiben die Form richtig.



dert, wodurch sich eine Verzerrungskarte des Meshes ergibt (Abb. 1(b)). Dieses Graustufenbild wird durch bewährte Halbton-Verfahren (Dithering) auf ein Schwarz/Weiß-Bild reduziert, wobei die Gesamtzahl weißer Pixel – welche die neuen Knotenpunkte darstellen – im Voraus festgelegt wird. Mit Hilfe einer 2D-Delaunay Triangulierung können dann die neuen Punktverbindungen bestimmt werden (Abb. 1(c)). Nach einer Glättung durch den Laplace'schen Fluss werden alle Punkte zurück in den Objektraum transformiert und ergeben die neuen Landmarken-Positionen (Abb. 1(d)).

Anstatt eines einzelnen Meshes haben wir für unser Formmodell eine ganze Reihe von Trainingsdaten, die mit einer Menge von Landmarken (den Knotenpunkten im Mesh) dargestellt werden muss. Dank der verwendeten Korrespondenzoptimierung kennen wir bereits Parametrisierungen für alle Formen, wenn auch in Kugelform. Um diese Parametrisierungen in den erforderlichen 2D-Raum zu transformieren, teilen wir jede Kugel in zwei Hälften und nutzen für beide die stereographische Projektion auf die Ebene, in der das Graustufenbild erstellt wird. Abschließend bilden wir aus allen Bildern derselben Kugelhälfte durch Addition der korrespondierenden Grauwerte ein Durchschnittsbild, auf welchem das Dithering für die neuen Landmarken durchgeführt wird.

#### 4 Evaluation von statistischen Formmodellen

Für die Evaluation von statistischen Formmodellen haben sich die objektiven Maße Generalisierungsfähigkeit und Spezifität bewährt [6]. Die Generalisierungsfähigkeit beschreibt die Fähigkeit des Modells, neue Formen zu repräsentieren. Sie kann durch eine Reihe von „Leave-one-out“-Tests auf den Trainingsdaten quantifiziert werden, indem die Abweichung zwischen der ausgelassenen Form und der besten Annäherung mit dem reduzierten Modell gemessen wird. Spezifität beschreibt die Gültigkeit der Formen, die das Modell

produziert. Der Wert wird geschätzt, indem eine hohe Anzahl (in unserem Fall 10.000) von zufälligen Parameterwerten für das Modell generiert wird und jeweils die Abweichung zum ähnlichsten Muster aus der Trainingsmenge gemessen wird. Um Abweichungen zwischen zwei Formen zu quantifizieren, wird bisher die durchschnittliche Entfernung zwischen korrespondierenden Landmarken berechnet. Mit dieser Methode können allerdings nur Modelle mit gleicher Anzahl von Landmarken und ähnlicher Verteilung zuverlässig verglichen werden [7].

In unserem neuen Evaluierungsverfahren ersetzen wir die landmarkenbasierte Metrik durch eine volumenbezogene: Die zu vergleichenden Formen, repräsentiert durch Landmarken und darauf basierende Gitternetze, werden dabei zuerst in zwei Volumenbilder gerendert. Anschließend werden die Ergebnisse ( $A$  und  $B$ ) mit Hilfe des Tanimoto-Koeffizienten verglichen:

$$C_T = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

Für die Berechnung von Generalisierungsfähigkeit und Spezifität werden die generierten Instanzen des Modells mit den Original-Trainingsdaten verglichen, nicht mit ihrer Modell-Approximation. Dadurch wird das Verfahren sensitiver gegenüber unzulänglichen Formbeschreibungen wie in Abb. 1(a).

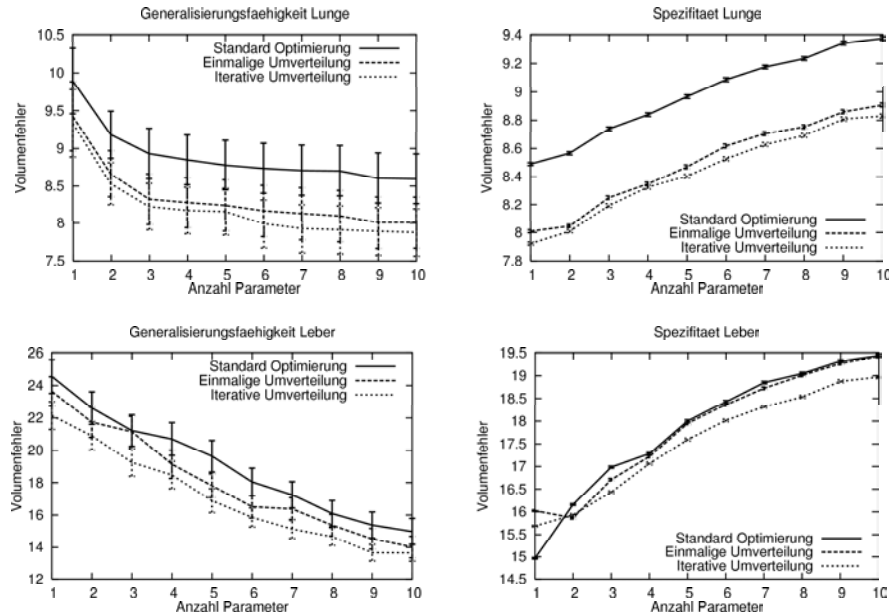
## 5 Ergebnisse

Um das beschriebene Verfahren zu testen, wurden für zwei Mengen von Trainingsdaten (18 Lungen- und 32 Leberdaten) jeweils drei statistische Formmodelle erzeugt: Das erste Modell wurde mit dem Referenzverfahren aus [4] erstellt. Die resultierenden Parametrisierungen wurden an den Algorithmus zur Landmarkenumverteilung weitergeleitet, der die Landmarken gleichmäßig über alle Formen verteilte und so das zweite Modell erzeugte. Bei der Erstellung des dritten Modells wurden die Landmarken bereits während des Optimierungsvorgangs alle 10 Iterationen neu verteilt. Die Ergebnisse der Auswertung mit den Evaluationsmaßen aus Abschnitt 4 sind in Abb. 2 dargestellt. Obwohl sich die Generalisierungsfähigkeit auch nach einer einmaligen Umverteilung schon deutlich verbessert, wird ein signifikanter Unterschied erst durch eine iterative Umverteilung erreicht. Für die Spezifität erbringt die Umverteilung aufgrund der kleineren Standardfehler schon einmalig eine signifikante Verbesserung. Auch hier werden die besten Ergebnisse aber mit einer iterativen Umverteilung erzielt.

## 6 Zusammenfassung

Die Verteilung der Landmarken spielt, über die richtigen Korrespondenzen hinaus, eine erhebliche Rolle bei der Modellerstellung. Gleichverteilte Landmarken verbessern die Qualität des MDL-Verfahrens in Bezug auf Generalisierungsfähigkeit und Spezifität und sollten so zu einer verbesserten Performance des Modells bei der Segmentierung in den klinischen Anwendungen führen. Auch weitere Einsatzbereiche von statistischen Formmodellen, z.B. in Diagnostik und Simulation, können von dem beschriebenen Verfahren profitieren.

**Abb. 2.** Generalisierungsfähigkeit und Spezifität für beide Datensätze. Der Volumenfehler ist spezifiziert als  $100(1 - C_T)$  mit  $C_T$  als Tanimoto-Koeffizient. In beiden Modellen beschreiben die dargestellten zehn Parameter 90% der Gesamtvarianz.



## Literaturverzeichnis

1. Cootes TF, Taylor CJ, Cooper DH, Graham J. Active Shape Models – Their Training and Application. *CVIU* 1995;61(1):38–59.
2. Davies RH, Twining CJ, Cootes TF, Waterton JC, Taylor CJ. 3D Statistical Shape Models Using Direct Optimisation of Description Length. In: *Procs ECCV*. Springer; 2002. p. 3–20.
3. Gu X, Wang Y, Chan TF, Thompson PM, Yau ST. Genus Zero Surface Conformal Mapping and Its Application to Brain Surface Mapping. In: *Procs IPMI*. Springer; 2003. p. 172–184.
4. Heimann T, Wolf I, Williams TG, Meinzer HP. 3D Active Shape Models Using Gradient Descent Optimization of Description Length. In: *Procs IPMI*. Springer; 2005. p. 566–577.
5. Alliez P, Meyer M, Desbrun M. Interactive Geometry Remeshing. *ACM TOG Special issue for SIGGRAPH conference 2002*;21(3):347–354.
6. Styner M, Rajamani KT, Nolte LP, Zsemlye G, Székely G, Taylor CJ, et al. Evaluation of 3D Correspondence Methods for Model Building. In: *Procs IPMI*. Springer; 2003. p. 63–75.
7. Heimann T, Wolf I, Meinzer HP. Optimal Landmark Distributions for Statistical Shape Model Construction. In: *Procs SPIE Medical Imaging (Akzeptiert)*; 2006.