

Texturadaptive Parametrierung aktiver Konturmodelle

Jörg Bredno, Thomas M. Lehmann und Klaus Spitzer

Institut für Medizinische Informatik
Universitätsklinikum der RWTH Aachen
Pauwelsstr. 30, 52057 Aachen
Email: jbredno@mi.rwth-aachen.de

Zusammenfassung. Zu den Aufgaben vieler Bildverarbeitungsapplikationen gehört die unüberwachte Segmentierung. Ein Ballon-Modell kann beliebig geformte Objekte in medizinischen Bildern erkennen, benötigt aber eine geeignete Parametrierung für jedes Bild. Unsere Methode wählt diese Parameter automatisch auf Basis einer globalen Texturanalyse. Cooccurrence-Matrizen von Bildern einer Trainingsmenge werden synergetischen klassifiziert, um dann ihre Ähnlichkeit zu neuen Bildern zu bestimmen. Ein individueller Parametersatz wird aus denen der Prototypen mit Ähnlichkeitsmaßen der Texturmerkmale interpoliert. Die mit der Methode erreichbare Verbesserung wurde auf synthetischem Bildmaterial quantifiziert. Bei der Anwendung auf 1616 realen Radiographien stieg die Erkennungsrate mit adaptiver Parametrierung von 31% auf 71%.

1 Einleitung

Die Quantifizierung medizinischer Bilddaten erfordert meist eine Segmentierung dargestellter Objekte [1]. Oft ist eine manuelle oder nutzergesteuerte Konturerkennung nicht akzeptabel. Bislang ist für eine unüberwachte automatische Segmentierung ein ähnliches Erscheinungsbild dargestellter Objekte nötig. Die daraus resultierende Anforderung reproduzierbarer Bildwerte zur Darstellung unterschiedlicher Gewebetypen wird jedoch nur von wenigen Modalitäten wie beispielsweise der Computertomographie erfüllt. Das Erscheinungsbild von Objekten auf medizinischen Bildern unterliegt starken Variabilitäten und die Parameter eines Segmentierungsalgorithmus müssen meist individuell von Experten eingestellt werden. Die hier vorgestellte Methode zur texturadaptiven Parametrierung aktiver Konturmodelle verwendet einen synergetischen Klassifikator, um die Ähnlichkeit von Bildern zu Prototypen in Bezug auf deren globale Textur zu bestimmen. Anhand dieser Ähnlichkeiten werden dann adaptiv die Parameter für das aktive Konturmodell gewählt, um eine unüberwachte Segmentierung zu ermöglichen.

Diese Arbeit ist eine Erweiterung der von uns bereits vorgestellten automatischen Parametrierung von Ballon-Modellen [2], die bisher nur auf einem Prototypen basierte.

2 Methode

Das zur Segmentierung verwendete Ballon-Modell auf Basis finiter Elemente [3] kann beliebig geformte Objekte in medizinischen Bilddaten detektieren, wenn die Stärke der mechanisch simulierten Einflußgrößen für ein Erscheinungsbild parametrisiert ist. Für jeweils ein Beispielbild und eine exemplarische Handsegmentierung können diese Parameter automatisch bestimmt werden [2], um dann Objekte auf vergleichbaren Bildern zu segmentieren. Wenn eine ausreichende Ähnlichkeit des Erscheinungsbildes nicht gegeben ist, muß eine individuelle Parametrierung des Verfahrens vorgenommen werden. Dazu werden globale Texturmerkmale trainiert, die die Ähnlichkeit von Bildern zu Prototypen aus einer Trainingsmenge quantifizieren. Zum Training werden zunächst Prototypbildern zu signifikant unterschiedlichen Erscheinungsbildern einer Bildmenge identifiziert. Zu jedem dieser Prototypen wird dann eine gültige Parametrierung \vec{P} bestimmt, die als Vektor alle Parameter enthält.

Als globales Texturmerkmal wird die Cooccurrence-Matrix verwendet [4]. Alle Prototypbilder werden auf 256×256 Pixel skaliert und die Grauwerttiefe auf 6 Bit reduziert. Die Cooccurrence-Matrix wird mit einem Displacement von 5 aus diesen Bildern extrahiert. Da es Aufgabe des Ballon-Modells ist, irrelevante Bildstrukturen zu überwindern aber an der Objektgrenze zu stoppen, liegen relevante Einträge abseits der Hauptdiagonalen der Cooccurrence-Matrix. Die Einträge auf der Hauptdiagonalen übersteigen jedoch selbst bei großem Displacement die eigentlich relevanten Daten um Größenordnungen (Abb. 1a). Viele Diskriminanzmaße zwischen diesen Matrizen unterliegen damit der Gefahr mathematischer Unstabilität. Daher werden die Matrizen logarithmiert (Abb. 1b), bevor sie als normierter Textur-Merkmalvektor \vec{c} der Dimension 64×64 in einem synergetischen Klassifikator auf Basis einer Adjunkten-Bestimmung [5] trainiert werden. Dieser Klassifikator bestimmt zu den n Texturmerkmalen \vec{c}_i eine orthonormale Basis aus Adjungierten \vec{c}_j^+ :

$$\vec{c}_i \cdot \vec{c}_j^+ = \delta_{ij} \quad (1)$$

mit der Kronecker-Funktion $\delta_{ij} = 1 \quad \forall \quad i = j, 0$ sonst. Die Adjungierten \vec{c}_j^+ stehen senkrecht auf allen Merkmalsvektoren \vec{c}_i , wenn $i \neq j$. Dabei müssen sie

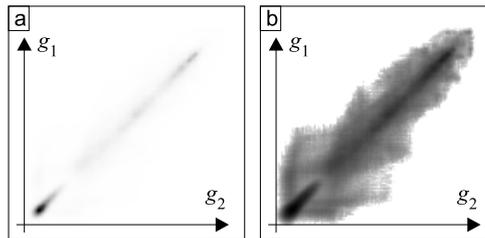


Abb. 1. Cooccurrence-Matrix der Grauwerte g_1 und g_2 einer Radiographie vor (a) und nach (b) der Logarithmierung. Beide Histogramme wurden unabhängig für einen kontrastreichen Ausdruck optimiert.

nicht selbst die Länge eins aufweisen oder in Richtung von \vec{c}_j weisen. Die \vec{c}_j^+ werden als Linearkombination aller \vec{c}_i gebildet:

$$\vec{c}_j^+ = \sum_{k=1}^n a_{jk} \vec{c}_k \quad (2)$$

Nach Multiplikation von (2) mit allen \vec{c}_i und dem Einsetzen von (1) auf der linken Seite erhält man ein lineares Gleichungssystem aus n^2 Gleichungen:

$$I = \begin{pmatrix} 1 & \vec{c}_1 \cdot \vec{c}_2 & \cdots & \vec{c}_1 \cdot \vec{c}_n \\ \vec{c}_2 \cdot \vec{c}_2 & 1 & & \vec{c}_2 \cdot \vec{c}_n \\ \vdots & & \ddots & \vdots \\ \vec{c}_n \cdot \vec{c}_1 & \vec{c}_n \cdot \vec{c}_2 & \cdots & 1 \end{pmatrix} \cdot \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{pmatrix} \quad (3)$$

Hier ist I die Identitätsmatrix. Die a_{jk} können also durch Invertierung der aus den Skalarprodukten aller Prototypmerkmale gebildeten Matrix ermittelt werden.

$$\begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{pmatrix} = \begin{pmatrix} 1 & \vec{c}_1 \cdot \vec{c}_2 & \cdots & \vec{c}_1 \cdot \vec{c}_n \\ \vec{c}_2 \cdot \vec{c}_2 & 1 & & \vec{c}_2 \cdot \vec{c}_n \\ \vdots & & \ddots & \vdots \\ \vec{c}_n \cdot \vec{c}_1 & \vec{c}_n \cdot \vec{c}_2 & \cdots & 1 \end{pmatrix}^{-1} \quad (4)$$

Nach dem Training stehen Parametersätze \vec{P}_j und adjungierte Prototypmerkmale \vec{c}_j^+ zur Verfügung. Für jedes zu bearbeitende Bild wird jetzt vor der Segmentierung der Textur-Merkmalvektor \vec{c}_{bild} gebildet, um dann den individuellen Parametersatz \vec{P}_{bild} zu bestimmen.

$$\vec{P}_{\text{bild}} = \frac{\sum_{j=1}^n w_j \cdot \vec{P}_j}{\sum_{j=1}^n w_j} \quad \text{mit} \quad w_j = \begin{cases} \vec{c}_{\text{bild}} \cdot \vec{c}_j^+ & \forall \quad 0 \leq \vec{c}_{\text{bild}} \cdot \vec{c}_j^+ \leq 1 \\ 1 - \vec{c}_{\text{bild}} \cdot \vec{c}_j^+ & \forall \quad 1 \leq \vec{c}_{\text{bild}} \cdot \vec{c}_j^+ \leq 2 \\ 0 & \text{sonst} \end{cases} \quad (5)$$

Die individuellen Parameter zur Segmentierung werden linear aus den Parametersätzen der Prototypen interpoliert, wobei das Skalarprodukt aus dem Texturmerkmal des Bildes und der adjungierten Texturmerkmale der Prototypen als Wichtungsfaktor verwendet wird. Da die \vec{c}_j^+ nicht mehr normiert sind, kann das Skalarprodukt mit dem normierten Merkmalsvektor \vec{c}_{bild} größer als eins werden, dies weist aber auf eine Abweichung zu den Einträgen in \vec{c}_j hin und wird daher in obiger Fallunterscheidung gesondert betrachtet. Die Methode ist auch für Farbbilder einsetzbar, wenn der Merkmalsvektor aus Within- und Cross-Cooccurrence-Matrizen der Farbkanäle [6] kombiniert wird.

3 Ergebnisse

Zunächst wurde experimentell das Postulat untersucht, daß die Logarithmierung der Einträge der Cooccurrence-Matrix die numerische Stabilität von Distanzmaßen auf diesen Merkmalen erhöht. Zum Test wurden vier Farbbilder aus einer laryngoskopischen Bildsequenz verwendet, diese Bilder zeigen keine stark ausgeprägten Texturen. Als Maß der numerischen Stabilität wurde das Fehlermaß $e = \max_{i,j=1}^n (\vec{c}_i \cdot \vec{c}_j^T - \delta_{ij})$ verwendet, das die maximale Abweichung der Skalarprodukte aus Prototypmerkmalen und Adjungierten von den in Training geforderten Werten angibt. Bei einem Test mit Fließkomma-Arithmetik einfacher Rechengenauigkeit eines Pentium-II-Prozessors und der Matrix-Invertierung des Bildverarbeitungssystems Khoros 2 war der Fehler $e = 0.78$ unakzeptabel hoch, wenn keine Logarithmierung vorgenommen wurde. Nach der Logarithmierung wurde der Fehler auf $e = 0.006$ reduziert.

Da für medizinische Bilddaten üblicherweise kein Goldstandard zur Segmentierung existiert, wurden zum Test der Methode zunächst synthetische Bilder segmentiert. In Bildern der Größe 128×128 Pixel ist das Objekt zu $r(\varphi) < r_0 + d_r \sin(\varphi_0 + k \cdot \varphi)$ mit $r_0 = 50$, $d_r = 10$ und $k = 5$ enthalten. Das Innere und Äußere des Objekts wurden mit normalverteiltem Rauschen mit den Mittelwerten μ_{in} bzw. μ_{out} und einer Standardabweichung σ gefüllt, am Rand des Objektes wurden die mittleren Grauwerte über einen Bereich von 5 Pixeln Breite linear angepaßt, um starke Gradienten zu verhindern. Die Parameter für die synthetischen Bilder wurden aus $\mu_{in} \in \{130, 140, 150\}$, $\Delta = \mu_{out} - \mu_{in} \in \{5, 10, 20\}$ und $\sigma \in \{2, 6, 10\}$ kombiniert. Für jede Kombination wurden 3 Testbilder erzeugt (Abb. 2). Das dabei auftretende Amplituden-Signal-zu-Rauschverhältnis variiert von -6 dB bis 20 dB. Eine Segmentierung erfolgte entweder mit einem einzelnen Parametersatz, trainiert für ein Bild mit $\mu_{in} = 140$, $\Delta = 10$ und $\sigma = 6$, oder adaptiv mit obiger Methode nach einem Training mit 4 bzw. 8 Prototypen aus dieser Bildmenge. Die Ergebnisse wurden mit dem Übereinstimmungsmaß $O = (A \cap B) / (A \cup B) \cdot 100\%$ beurteilt. Hierbei sind A und B das binäre Eingangsbild und das binarisierte Segmentierungsergebnis. Bei Segmentierung mit einem Parametersatz schlug die Segmentierung fehl, O wurde bei den 81 Bildern zu $45,1\% \pm 38,5\%$ bestimmt. Durch Training mit 4 Prototypen wurde dieses Maß

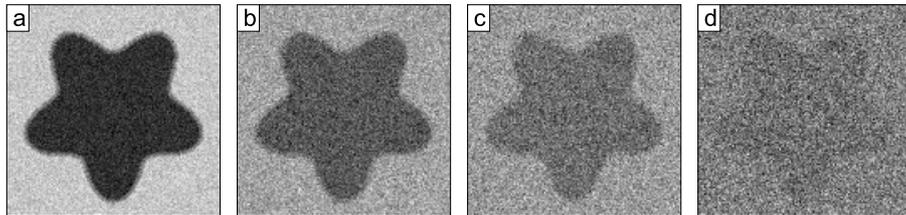


Abb. 2. Synthetische Bilder im Test: Die Darstellungen (a) bis (d) entsprechen den Kombinationen $(\Delta, \sigma) = (20, 2), (20, 6), (10, 6)$ und $(5, 10)$. Die einzelnen Histogramme wurden für einen kontrastreichen Ausdruck optimiert.

auf $87,7\% \pm 22,7\%$ erhöht, bei 8 Prototypen stieg das Übereinstimmungsmaß auf $O = 90,9\% \pm 9,3\%$.

Das Verfahren wurde weiterhin zur Segmentierung von 1616 Radiographien eingesetzt, die im Rahmen des IRMA-Projektes vollautomatisch klassifiziert werden sollen [7]. Hier wurden 19 Prototypen identifiziert und ein Training auf Basis dieser Prototypen vorgenommen. Während mit festem Parametersatz nur 496 Segmentierungen (31%) mit dem subjektiven visuellen Eindruck eines Betrachters übereinstimmten [8], wurde diese Anzahl bei adaptiver Parametrierung auf 1145 (71%) erhöht.

4 Diskussion

In vielen Bereichen der medizinischen Bildverarbeitung müssen heterogene Archive automatisch verarbeitet werden. Mit der texturadaptiven Parametrierung von Auswertungsalgorithmen besteht jetzt die Möglichkeit, solche Aufgaben unüberwacht durchzuführen. Die Methode wurde für die Segmentierung mit einer aktiven Kontur eingesetzt, es besteht aber prinzipiell keine Beschränkung in Hinblick auf den Einsatz der beschriebenen Voranalyse. Einzige Voraussetzung ist, daß bei den Parametern eine Interpolation von Werten zwischen verschiedenen Bildprototypen zulässig ist. Das zum Test verwendete IRMA-Archiv enthält stark variables Bildmaterial, bei dem keine Auswahl nach gut erkennbaren Konturen erfolgt ist. Daher ist die Erhöhung von 31% auf 71% akzeptierter vollautomatischer Segmentierungsergebnisse ein äußerst zufriedenstellendes Ergebnis.

Literatur

1. Duncan JS, Ayache N: Medical Image Analysis: Progress over two decades and the challenges ahead. IEEE Trans. PAMI 22(1): 85-106, 2000.
2. Bredno J, Lehmann T, Spitzer K: Automatische Parameterwahl für Ballon-Modelle. Procs. BVM 2000: 71-75, 2000.
3. Bredno J, Lehmann T, Spitzer K: A general finite element model for segmentation in 2, 3, and 4 dimensions. Procs. SPIE 3979: 1174-1184, 2000.
4. Haralick R, Shanmugam K, Dinstein I: Texture features for image classification. IEEE Trans. SMC 3: 610-621, 1973.
5. Haken H: Synergetic Computers and Cognition. Springer-Verlag, Heidelberg, 1991.
6. Palm C, Metzler V, Mohan B, Dieker O, Lehmann T, Spitzer K: Co-Occurrence Matrizen zur Texturklassifikation in Vektorbildern. Procs. BVM 1999: 367-371, 1999.
7. Lehmann T, Wein B, Dahmen J, Bredno J, Vogelsang F, Kohlen M: Ein strukturiertes Konzept zum inhaltsbasierten Zugriff auf medizinische Bildarchive. Procs. BVM 2000: 218-222, 2000.
8. Bredno J, Brand S, Dahmen J, Wein B, Lehmann T: Kategorisierung von Röntgenbildern mit aktiven Konturmodellen. Proc. BVM 2000: 356-360, 2000.