

Ein lokal-adaptives Ähnlichkeitsmaß als Kriterium der hierarchischen Regionenverschmelzung

Daniel Beier¹, Christian Thies¹, Mark-Oliver Güld¹,
Benedikt Fischer¹, Michael Kohnen² und Thomas M. Lehmann¹

¹Institut für Medizinische Informatik, RWTH-Aachen, 52057 Aachen

²Klinik für Radiologische Diagnostik, RWTH-Aachen, 52057 Aachen
Email: {dbeier, cthies}@mi.rwth-aachen.de

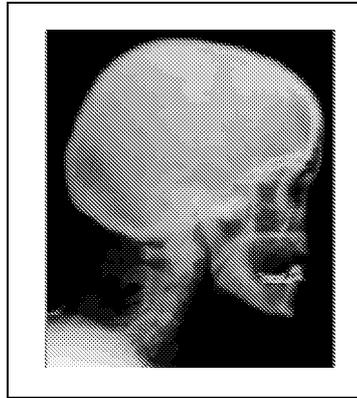
Zusammenfassung. Bei agglomerativen Segmentierungsverfahren basiert die hierarchische Regionenverschmelzung auf dem Vergleich von Ähnlichkeitswerten. Dazu werden Distanzmaße benötigt, welche die Abstände von Regionen beschreibenden Merkmalsvektoren bestimmen. Im Unterschied zu gängigen Distanzmaßen operiert das hier vorgestellte Maß nicht auf statischen Merkmalsvektoren, sondern gewichtet Bereiche adjazenter Regionen, die nahe der jeweiligen Regionengrenze liegen hoch, so dass bei Regionen mit hoher interner Merkmalsvarianz - z.B. große Grauwertverläufe - die Einflüsse solcher Pixel reduziert werden, die sich weit entfernt von der Regionengrenze befinden. Das lokal-adaptive Ähnlichkeitsmaß wurde in einen multiskalaren Segmentierungsalgorithmus integriert. Experimentelle Ergebnisse werden auf medizinischen Bildern verschiedenster Kontexte präsentiert.

1 Einleitung

Bildsegmentierung ist oft der initiale Schritt für viele Prozesse der Bildanalyse, wie z.B. die multiskalare Inhaltsbeschreibung medizinischer Bilder, dem Auffinden von Objekten in Bildern für ein inhaltsbasiertes Image Retrieval oder auch der Objekt-basierten Bildkompression. Diese Verfahren sind in starker Weise von den Ergebnissen der Segmentierungsalgorithmen abhängig. Aufgabe der Bildsegmentierung ist es, relevante Regionen im Bild zu finden und voneinander abzugrenzen. Dabei variiert das notwendige Maß an Detailliertheit je nach Aufgabenstellung. So ist z.B. bei der Betrachtung eines Tumors in einer MR-Aufnahme eine sehr detaillierte Segmentierung des Gewebes notwendig, wohingegen bei der anatomischen Klassifikation von Röntgenbildern nur das dargestellte Körperteil, wie z.B. Kopf, Bein, Hand, etc. extrahiert werden muss.

Segmentierungsalgorithmen, die auf dem agglomerativen Verschmelzen [1,2] bzw. Wachstum [3] von Regionen basieren, benutzen gängige Distanzmaße wie z.B. den Betrag zweier Merkmalsvektoren, die euklidische Distanz, die quadratische Form oder das Ward-Kriterium [4] zur Bestimmung der Ähnlichkeit von Regionen. Die einzelnen Regionen werden dazu durch statische Merkmalsvektoren

Abb. 1. Bei der Betrachtung des gesamten Knochens in dieser Röntgenaufnahme als eine visuell zusammenhängende Region, besitzt diese eine hohe Varianz im Grauwert. Die Kalotte ist wesentlich heller als der Kiefer abgebildet, so dass diese beiden Teilregionen eine große Abweichung bzgl. des mittleren Grauwertes besitzen, semantisch gehören sie jedoch zusammen.



beschrieben, die sich durch Mittelwertbildung über die Regionenpixel ergeben. Diese statischen Mittelwertsvektoren bilden die Parameter des Distanzmaßes. Sie sind nur dann repräsentativ für eine ganze Region, wenn die Varianz der Merkmalswerte innerhalb der Region gering ist. Fließende Verläufe von Merkmalswerten innerhalb visuell zusammenhängender Regionen - z.B. im Grauwert (Abb. 1) - führen jedoch zu einer hohen Varianz. Daher liefern statische Merkmale nicht immer relevante Segmente.

Ein agglomerativer Segmentierungsansatz liefert z.B. in frühen Iterationen des Verschmelzungsprozesses kleine Regionen mit homogener Merkmalsverteilung. Dabei ergibt sich der visuelle Unterschied und somit der Regionenrand aus dem Kontrast. In späteren Schritten werden in der Regel große Regionen mit ausgeprägten internen Merkmalsgradienten betrachtet, und der visuelle Unterschied resultiert aus der lokalen Merkmalsverteilung der benachbarten Teilbereiche adjazenter Regionen. Daher wird ein Ähnlichkeitsmaß benötigt, das von der lokalen Merkmalsverteilung abhängt.

2 Das lokal-adaptive Distanzmaß

Um die Ähnlichkeit adjazenter Regionen R_i und R_j nahe ihrer gemeinsamen Grenze zu erfassen, muss ein Distanzmaß die Koordinaten der Regionenpixel betrachten. Ferner muss es diese lokalen Distanzen zur Berechnung der Gesamtähnlichkeit $\text{dist}(R_i, R_j)$ der benachbarten Regionen R_i und R_j nutzen. Das vorgestellte Distanzmaß basiert auf der Gewichtung der quadrierten Differenz der Merkmalsvektoren $\mu(p_i)$ und $\mu(p_j)$ zweier Pixel $p_i \in R_i$ und $p_j \in R_j$ mittels des Kehrwertes der euklidischen Distanz $d_2(p_i, p_j)$ der Pixelkoordinaten. Eine große räumliche Entfernung zwischen p_i und p_j führt somit zu einer schwa-

chen Gewichtung dieses Pixelpaares. Die Gewichtungsfaktoren aller Pixelpaare in Form ihrer euklidischen Distanz können effizient vorberechnet und in einer Matrix der Größe Bildbreite \times Bildhöhe gespeichert werden. Das lokal-adaptive Distanzmaß ist wie folgt definiert:

$$\text{dist}_P(p_i, R_j) = A_{p_i} \cdot \sum_{p_j \in R_j} \frac{1}{d_2(p_i, p_j)} (\mu(p_i) - \mu(p_j))^2 \text{ für } p_i \in R_i \text{ mit} \quad (1)$$

$$A_{p_i} = \left(\sum_{p_j \in R_j} \frac{1}{d_2(p_i, p_j)} \right)^{-1}$$

$$\text{dist}_R(R_i; R_j) = A_{R_i} \cdot \sum_{p_i \in R_i} \frac{1}{\min_{p_j \in R_j} \{d_2(p_i, p_j)\}} \text{dist}_P(p_i, R_j) \text{ mit} \quad (2)$$

$$A_{R_i} = \left(\sum_{p_i \in R_i} \frac{1}{\min_{p_j \in R_j} \{d_2(p_i, p_j)\}} \right)^{-1}$$

(analog für Pixel $p_j \in R_j$)

$$\text{dist}(R_i, R_j) = \frac{|R_i|}{|R_i| + |R_j|} \text{dist}_R(R_i; R_j) + \frac{|R_j|}{|R_i| + |R_j|} \text{dist}_R(R_j; R_i) \quad (3)$$

Hierbei stellt $\text{dist}_P(p_i, R_j)$ die durch die euklidische Distanz gewichtete Ähnlichkeit eines Pixels $p_i \in R_i$ zu allen Pixeln der Nachbarregion R_j dar. Mit $\text{dist}_R(R_i; R_j)$ wird die Ähnlichkeit der gesamten Region R_i zu ihrer Nachbarregion R_j bewertet, wobei die einzelnen Summanden zusätzlich durch den Kehrwert der euklidischen Distanz zum minimal entfernten Pixel der Nachbarregion R_j gewichtet werden. Schließlich ist $\text{dist}(R_i, R_j)$ die größenabhängige Bewertung der beiden Regionen zueinander.

Die räumliche Distanz $d_2(p_i, p_j)$ kann zusätzlich durch monoton steigende Funktionen noch stärker gewichtet werden, z.B. durch: $f(d_2(p_i, p_j))$ mit $f(x) = x^2$, $f(x) = \exp(x)$ für $x \geq 0$.

3 Umsetzung

Das neue Distanzmaß wurde in einen Segmentierungsalgorithmus integriert, der auf einem agglomerativen Prozess zur Regionenverschmelzung basiert [1]. Beim Vergleich zweier Regionen wird vorab die Merkmalsvarianz beider Regionen betrachtet und die aufwändige Ähnlichkeitsberechnung mit dem lokal-adaptiven Distanzmaß nur durchgeführt, wenn mindestens eine Region eine hohe Merkmalsvarianz aufweist. Ansonsten erfolgt die Distanzberechnung zweier Regionen durch die euklidische Distanz ihrer gemittelten Merkmalsvektoren.

Da bei der Berechnung des lokal-adaptiven Distanzmaßes jedes Pixel einer Region mit allen Pixeln der Nachbarregion verglichen wird und sich die Bewertung für eine Region als Summe der Einzelbewertungen der Regionenpi-

xel ergibt, lässt sich die Laufzeit-Komplexität des neuen Distanzmaßes durch $O(|R_i| \cdot |R_j|) + O(|R_i|) + O(|R_j|) \subset O(N^2)$ abschätzen.

4 Experimente

Das neue lokal-adaptive Ähnlichkeitsmaß wurde in einen multiskalaren Segmentierungsalgorithmus zum agglomerativen Regionenverschmelzen integriert und auf ausgewählten Grauwertbildern einer radiologischen Datenbank getestet. Dabei war das alleinige Merkmal zur Regionenbeschreibung die Grauwertintensität der Pixel. Untersucht wurden unter anderem drei Röntgenaufnahmen von Schädel, Thorax und Hand sowie zwei laterale Kernspin Tomographien von Kopf und Knie. Es fand ein qualitativer Vergleich der Ergebnisse mit dem statischen und dem neuen Maß statt.

In frühen Iterationen ergeben sich für naturgemäß kleine Regionen nahezu identische Partitionierungen des Bildes verglichen zum alten statischen Ansatz [1], der nur die mittleren Grauwerte von Regionen vergleicht. Auf allen Bildern ergeben sich mit dem neuen Verfahren bei späten Iterationen mit größeren Regionen Partitionierungen, die intuitiv nachvollziehbar sind (Abb. 2, 3).

5 Diskussion

Das vorgestellte lokal-adaptive Distanzmaß liefert bei der Betrachtung adjazenter Regionen innerhalb eines Segmentierungsalgorithmus eine Ähnlichkeitsbewertung, die Teilbereiche dieser Regionen nahe der Regionengrenze höher bewertet als Bereiche, die weit entfernt von dieser Grenze liegen. Damit wird die Abhängigkeit der Regionenverschmelzung von der Merkmalsdynamik - z.B. dem Grauwert - innerhalb von Regionen aufgehoben. Das beschriebene Verfahren ist merkmalsunabhängig.

Die visuelle Signifikanz der resultierenden Partitionen ermöglicht eine zuverlässige Extraktion des Bildinhalts und eignet sich somit z.B. zum inhaltsbasierten Bilddatenbankzugriff.

6 Ausblick

Aus algorithmischer Sicht kann die quadratische Laufzeit beim paarweisen Vergleich benachbarter Regionen durch geschickte Indizierung noch optimiert werden. Bei Verfahren, die auf dem Wachstum oder Verschmelzen von Regionen basieren, können Teilsummen effizient gespeichert und weitergegeben werden.

Eine weitere Verbesserung des Algorithmus zur Regionenverschmelzung könnte durch Einbeziehen von Kanteninformationen in das Ähnlichkeitsmaß erreicht werden. Auffällig ist, dass bei vielen Bildern einzelne Pixel in der Nähe von scharfen Kanten bis in hohe Iterationsstufen hinein eigene kleine Regionen bilden. Durch Berücksichtigung der Regionengröße bzw. der Iterationsstufen im

Abb. 2. Bei der Segmentierung einer Röntgenaufnahme des Kopfes (links) werden durch die statischen Distanzmaße semantisch zusammenhängende Regionen getrennt (Mitte). Der Unterkiefer verschmilzt mit dem Hintergrund. Mit Hilfe des neuen Distanzmaßes wird der Unterkiefer Teil des Schädels (rechts).

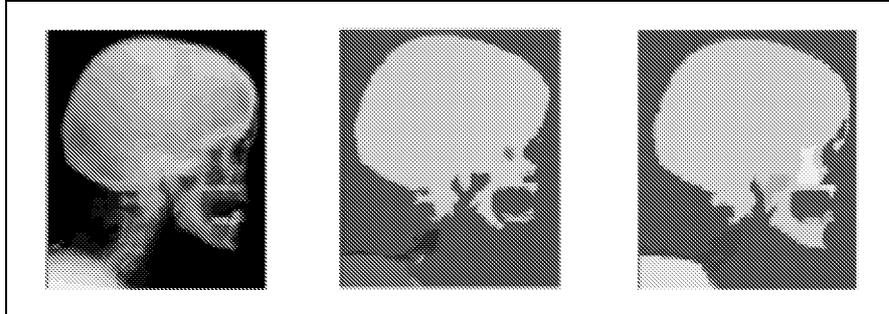
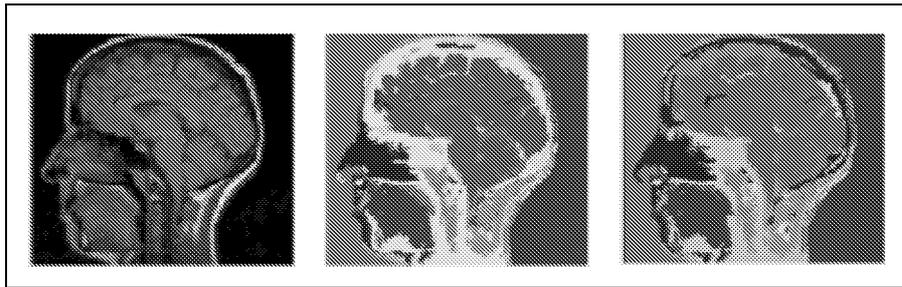


Abb. 3. Bei der sagittalen MR-Aufnahme des Kopfes (links) verschmelzen mit dem statischen Distanzmaß (Mitte) Teile des Rachenraums, der Nasenhöhle, des Liquorraums und der Schädeldecke zu einer unplausiblen Region (gelb). Mit dem neuen Distanzmaß wird dieses vermieden (rechts).



Ähnlichkeitsmaß könnte eine Verschmelzung solcher Regionen mit benachbarten großen Regionen in frühen Iterationsstufen erzwungen werden.

Wünschenswert ist ferner ein lokal-adaptives Ähnlichkeitsmaß, das (analog zum Ward-Kriterium) den minimalen globalen quadratischen Fehler für eine Partitionierung liefert.

Literaturverzeichnis

1. Thies C, Malik A, Keysers D, et al.: Hierarchical feature clustering for content-based retrieval in medical image databases. *Procs SPIE* 5032(1): 598–608, 2003.
2. Haris K, Estradiadis SN, Maglaveras N, et al.: Hybrid image segmentation using watersheds and fast region merging. *IEEE Trans on Image Processing* 7(12): 1684–1699, 1998.
3. Adams R, Bischof L: Seeded Region Growing. *IEEE Trans on Pattern Analysis and Machine Intelligence* 16(6): 641–647, 1994.
4. Ward JH: Hierarchical grouping to optimize an objective function. *American Stat Assoc* 58: 236–245, 1963.