

Merkmalsgesteuerte Segmentierung in der medizinischen Mustererkennung

M. Beller, R. Stotzka, H. Gemmeke

Institut für Prozessdatenverarbeitung und Elektronik
Forschungszentrum Karlsruhe, Germany
Email: Michael.Beller@ipe.fzk.de

Zusammenfassung. Es wird eine neuartige Methodik zur merkmalsgesteuerten Segmentierung vorgestellt, die eine Verallgemeinerung des Constrained Region Growings (CRG) darstellt. Dazu werden Unterscheidungsmerkmale von Objekten aus einer Datenbasis verwendet, um mit diesen Merkmalen weitere Objekte zu segmentieren. Die Merkmale werden automatisch bestimmt und ein Klassifikator aufgebaut. Dieser wird zusammen mit den Merkmalen in den Segmentierungsprozess zurückgekoppelt. Mit dieser Methode werden Objekte der selben Problemklasse segmentiert und mit den Ergebnissen eines normalen Regionenwachstums verglichen.

1 Einleitung

Die Unterscheidbarkeit verschiedener Objekte, z.B. unterschiedlicher Blutzellen in Mikroskopbildern, basiert häufig auf der Qualität der Segmentierung der einzelnen Objekte. Durch die Segmentierung werden die Objektgrenzen ermittelt und das Objekt vom Hintergrund getrennt. Aus den segmentierten Objekten wird durch die Merkmalsextraktion eine formale Beschreibung abgeleitet, mit der die Objekte klassifiziert werden. Die Segmentierung stellt folglich einen wichtigen Schritt dar, der sehr genau durchgeführt werden sollte.

Meist wird die Segmentierung manuell durchgeführt, da menschliche Experten hierzu sehr gut in der Lage sind. Manuelle Segmentierungen sind zeitaufwändig, daher sollten Bilddaten automatisch ausgewertet werden. Dazu müssen automatische Segmentierungsverfahren verwendet werden. Das Ergebnis einer automatischen Segmentierung sollte dem einer manuellen Segmentierung durch einen Experten (Goldstandard) qualitativ gleichwertig sein, sonst können wichtige Unterscheidungsmerkmale, z.B. die Morphologie, verloren gehen. Dadurch würde sich auch das Klassifikationsergebnis verschlechtern.

Einfache Segmentierungsverfahren können bei verminderter Bildqualität oder komplexen Objekten versagen [1]; Expertenwissen über die zu segmentierenden Objekte in eine für den Rechner verständliche Form umzusetzen ist oft nur schwer möglich. Daher wurde eine Methodik entwickelt, mit der der Segmentierungsprozess problemabhängig modifiziert wird. Die vorgestellte Methodik soll gemäß den Vorüberlegungen eine dem Goldstandard vergleichbare und somit im Sinne der nachfolgenden Klassifikation gute Segmentierung produzieren.

2 Stand der Technik

Eines der am häufigsten verwendeten Segmentierungsverfahren ist das Region Growing [2]. Aufgrund eines festen Homogenitätskriteriums werden Pixel zu Regionen zusammengefasst. Meist wird dazu der Gradient eines Bildes mit einer Schwelle θ verwendet. An unscharfen Kanten oder Verläufen der Bildobjekte kann die Segmentierung versagen. Durch eine Anpassung des Homogenitätskriteriums an das Segmentierungsproblem versuchen wir, dies zu vermeiden. Die Homogenität einer Region ist durch die Ähnlichkeit der sie bildenden Elemente gegeben, z.B. Gradient, ähnliche Textur innerhalb der Region oder spezielle Ausprägungen des Regionenrandes. Wir verwenden das Seeded Region Growing [2,3,6], bei dem die Regionen von einem Saatpunkt ausgehend wachsen. Es existieren Methoden, ein Regionenwachstum mit (zusätzlichen) vom Gradienten verschiedenen Randbedingungen zu versehen. Dadurch entstehen andere Segmentierungen als beim normalen Region Growing. Diese Form der Segmentierung wird bisher als Constrained Region Growing (CRG) [2,6] bezeichnet. Die wenigen beschriebenen CRG-Algorithmus sind mit nur wenigen Randbedingungen aufgebaut, die zudem empirisch für die Problemstellung ausgewählt werden. Warfield et al. beschreiben ein solches CRG in [6]. Sie verwenden zusätzlich zu beobachteten Unterscheidungsmerkmalen Expertenwissen in Form eines anatomischen Atlanten zur Formulierung ihrer Randbedingungen (engl.: constraints). Pohle et al. [3] schätzen mittels des Gradienten und einfacher morphologischer Eigenschaften die Homogenität während der Segmentierung und passen die Segmentierungsparameter dementsprechend an.

Die folgenden Ansätze basieren zwar nicht auf Region Growing, verwenden jedoch verschiedene Randbedingungen zur Steuerung von Segmentierungsalgorithmen: Metzler et al. [4] segmentieren wissensbasiert. Aus einer Datenbasis von Regionenbildern werden mit evolutionären Algorithmen neue Regionenbilder erzeugt. Dazu fassen sie die Segmentierung als hochdimensionales Optimierungsproblem auf und kombinieren ein globales und ein lokales Optimierungsverfahren zu einem iterativen Schema, das verschiedene Bildeigenschaften als Randbedingungen für die Segmentierungen verwendet.

Paclik et al. [5] benutzen Eigenschaften aus Spektralbildern, um Randbedingungen für ihre texturbasierte Segmentierung zu schaffen. Dazu verwenden sie unüberwachtes Clustering zur Segmentierung. Texturlose Objekte können so nicht gefunden werden. Unüberwachtes Clustering vergrößert das Risiko, die Pixel in falsche Klassen einzusortieren.

Ginneken [7] und Cremers [8] beschränken ihre Segmentierungsmöglichkeiten durch statistische Modelle der äußeren Form, die von Trainingssets abgeleitet sind. Objekte, von denen die Grundgesamtheit ihrer Formen nicht geschätzt werden kann oder solche, deren Form nicht ausschlaggebend ist, können auf diese Weise nicht segmentiert werden.

Die in der Literatur beschriebenen Segmentierungsverfahren, die zusätzliche Randbedingungen vorgeben, sind stark anwendungsspezifisch. In unserem Ansatz werden die benötigten Randbedingungen für die Segmentierung vom Algorithmus selbst gewählt und in die Segmentierung zurückgekoppelt. Die Rand-

bedingungen bestehen aus Merkmalen zur Unterscheidung verschiedener Objektklassen. Durch ein breites Spektrum von verwendbaren Merkmalen wird eine Unabhängigkeit von menschlichen Beobachtungen sichergestellt. Ausserdem können so Merkmale eingebunden werden, die der Mensch nicht berücksichtigen kann, z.B. auch Feinheiten der Textur.

3 Merkmalsgesteuerte Segmentierung

Zunächst wird die Methodik für eine allgemeine merkmalsgesteuerte Segmentierung vorgestellt. Danach folgt eine Beschreibung der Anwendung dieser Methodik für mikroskopische Grauwertbilder angefärbter Blutzellen.

Ausgehend von einer Datenbasis digitaler Bilder und ihrer Referenzsegmentierungen wird im ersten Schritt ein Klassifikationssystem aufgebaut: Die Eigenschaften oder Merkmale M_R (z.B. Grauwerte, Texturen, ...) der Regionen werden berechnet. Mittels einer Merkmalsselektion werden nur die treffendsten n Merkmale M_R^* zur Beschreibung der Objekte ausgewählt. Die ausgewählte Merkmalskombination besteht aus denjenigen Merkmalen, die die verschiedenen Regionen gut trennen. Sie beschreibt auch, in welchen Merkmalen sich Regionen der gleichen Klasse besonders ähneln. Ein Klassifikator C_R erstellt Trenngrenzen zwischen den verschiedenen Klassen von Objekten (Zellkern, Zellplasma, ...). Für den Klassifikator lässt sich, da die Grundgesamtheit der Objekte nur durch eine Stichprobe repräsentiert ist, ein Generalisierungsfehler E_G schätzen. Das Regionenwachstum arbeitet pixelbasiert, daher werden zusätzlich pixelbezogene Eigenschaften M_P aus der Datenbasis extrahiert, z.B. aus einem 3×3 Fenster um jedes Pixel. Aus diesen werden ebenfalls die m treffendsten Merkmale M_P^* selektiert. Diese Merkmale stellen die innere Homogenität der Objekte dar. Es wird ein zweiter Klassifikator C_P aufgebaut, der die Pixel der Objekte und des Hintergrunds gut unterscheiden kann.

Die gewonnenen Daten werden im zweiten Schritt in einem CRG-Algorithmus verwendet. Dabei handelt es sich um die Klassifikatoren sowie die Merkmalsmengen M_P^* und M_R^* . Ausgehend von einem Startpunkt werden die M_P^* jedes Nachbarn berechnet. C_P entscheidet über die Regionenzugehörigkeit der Nachbarn. Dieses Vorgehen erzeugt Regionen, die in den Pixeleigenschaften homogen sind. Nach der Segmentierung wird von C_R überprüft, ob die entstandenen Regionen der Zielklassifikation gerecht werden, d.h. die Regionenmerkmale werden extrahiert und die Regionen entsprechend klassifiziert.

Die vorgestellte Methodik wird auf mikroskopische Grauwertbilder angefärbter Blutzellen (speziell Lymphozytenkerne) angewendet. Dazu wird auf eine von Experten vorsegmentierte Stichprobe von 39 Lymphozyten zurückgegriffen. Jeder Lymphozytenkern wurde von 2 Experten 5 mal manuell segmentiert, um die Inter-/Intra-Observer-Variability zu begrenzen. Die Klassenzugehörigkeiten der verschiedenen Regionen (Zellkern, ...) sind bekannt. Wir gehen davon aus, dass die manuelle Segmentierung es im vorliegenden Fall ermöglicht, die genaueste Beschreibung der Objekte in Form von Merkmalen zu erstellen, was zu einer optimalen Klassifikation führt. Der Startpunkt für das CRG wurde manuell vor-

gegeben. Es wird nur die 4er Nachbarschaft berücksichtigt, um einzelne diagonale Regionenverschmelzungen zu vermeiden. Bei den verwendeten Merkmalen handelt es sich im vorliegenden Fall um 6 statistische Merkmale (s. Abb. 1). Der Klassifikator C_P ist ein Baumklassifikator, der die Schwellwerte für jedes Merkmal M_P^* zu einer Entscheidung kombiniert.

4 Ergebnisse

Die resultierenden Segmentierungen zeigen gegenüber dem normalen Region Growing erhebliche Verbesserungen. Als objektives Qualitätsmaß werden der Mean-Square-Error (MSE) und der Root-Mean-Square-Error (RMSE) zur Referenzsegmentierung aus der Datenbasis verwendet (s. Tab. 1). Visuell betrachtet werden Fehlsegmentierungen stark verringert.




Abb. 1. Lymphozytensegmentierungen. Oben: Original und herkömmliches Region Growing bei verschiedenen Schwellwerten. Unten: manuelle Segmentierung und Constrained Region Growing. Die schwarzen Bereiche stellen die jeweilige Segmentierung des Kerns abhängig vom Schwellwert des Gradienten θ dar. Das CRG beinhaltet den Gradienten und die statistischen Maße *Mittelwert*, *Standardabweichung*, *Maximaler Grauwert*, *Schiefe*, *Kurtosis* und *Entropie*.

| θ | MSE(RG) | MSE(CRG) | RMSE(RG) | RMSE(CRG) |
|----------|---------|----------|----------|-----------|
| 6 | 4360 | 4376 | 66 | 66 |
| 7 | 14231 | 4023 | 119 | 63 |
| 8 | 16987 | 1966 | 130 | 44 |
| 10 | 16914 | 1460 | 130 | 38 |

Tabelle 1. Segmentierungsqualität. Während beim normalen Regionenwachstum MSE und RMSE für $\theta \geq 6$ fast immer steigen, sinken sie bei unserer Methode stetig ab.

5 Diskussion

Es wurde ein neuartiger Ansatz für die merkmalsgestützte regionenbasierte Segmentierung vorgestellt. Der klassische Zuordnungsprozess über den Gradienten und einen Schwellwert wird auf anwendungsspezifische deskriptive Merkmale für Pixel und Regionen und geeignete Klassifikatoren erweitert. Die Homogenität wird durch Informationen aus vorsegmentierten Objekten und deren Merkmalen beschrieben und als Randbedingung für das Constrained Region Growing benutzt. Diese Randbedingung wird automatisch ermittelt.

Im vorgestellten Anwendungsbeispiel wird aus Gründen der Einfachheit und Rechenzeit nur auf 6 ausgewählte statistische Merkmale und einen einfachen Baumklassifikator zurückgegriffen. Die Segmentierungsergebnisse sind besser als beim normalen Region Growing. Wir verwenden z. Zt. maximal 75 Merkmale statistischer, geometrischer und textueller Natur und verschiedene Selektor/Klassifikator-Kombinationen, die wir manuell in die Segmentierung einfügen. Diese Rückkopplung kann jedoch automatisch stattfinden. Die Komplexität gegenüber herkömmlichen Segmentierungsmethoden steigt stark an, da im ungünstigsten Fall für jedes Pixel alle Eigenschaften der Umgebung berechnet werden müssen. Eine Beschränkung auf weniger Eigenschaften kann hier Abhilfe schaffen. Allerdings kann dadurch die Qualität der Segmentierung sinken.

Literaturverzeichnis

1. Beller M, Stotzka R, Gemmeke H, Weibezahn KF, Knedlitschek G: Bildverarbeitung für ein motorisiertes Lichtmikroskop zur automatischen Lymphozytenidentifikation. Bildverarbeitung für die Medizin 2003 196–200, 2003
2. Wan SY, Higgins WE: Symmetric Region Growing. IEEE Transactions on Image Processing 12 (9):1007–1015, 2003
3. Pohle R, Toennies KD: Segmentation of medical images using adaptive region growing. Proceedings of SPIE Medical Imaging 2001 4322:1337–1346, 2001.
4. Metzler V, Vandenhouten R, Krone J, Grebe R: Wissensbasierte Bildsegmentierung mittels stochastischer Optimierung. Digitale Bildverarbeitung in der Medizin, Tagungsband 5.Freiburger Workshop 1997
5. Paclík P, Duin RPW, van Kempen GMP, Kohlus R: Supervised Segmentation of Textures in Backscatter Images. Proceedings 16th International Conference on Pattern Recognition 490–493, 2002
6. Warfield SK, Dengler J, Zaers J et al.: Automatic Identification of Gray Matter Structures from MRI to Improve the Segmentation of White Matter Lesions. Journal of Image Guided Surgery 1 (6):326–338, 1995
7. Ginneken Bv, Frangi AF, Staal JJ, Haar Romeny BM ter, Viergever MA: Active Shape Model Segmentation with optimal Features. IEEE Transactions on Medical Imaging 21 (8):924–993, 2002
8. Cremers D, Kohlberger T, Schnörr C: Nonlinear Shape Statistics in Mumford-Shah Based Segmentation. 7th European Conference on Computer Vision, 2003