

# Vesselness-geführte Level-Set Segmentierung von zerebralen Gefäßen

Nils D. Forkert<sup>1</sup>, Alexander Schmidt-Richberg<sup>2</sup>, Jan Ehrhardt<sup>2</sup>, Jens Fiehler<sup>3</sup>,  
Heinz Handels<sup>2</sup>, Dennis Säring<sup>1</sup>

<sup>1</sup> Institut für Medizinische Informatik, Universitätsklinikum Hamburg-Eppendorf,

<sup>2</sup> Institut für Medizinische Informatik, Universität zu Lübeck,

<sup>3</sup> Klinik und Poliklinik für Neuroradiologische Diagnostik und  
Intervention, Universitätsklinikum Hamburg-Eppendorf

n.forkert@uke.uni-hamburg.de

**Kurzfassung.** Die Extraktion von zerebralen Gefäßstrukturen ist trotz hoher Forschungsaktivität in diesem Bereich noch immer eine große Herausforderung. Insbesondere die in ihrem Verlauf immer dünner werdenden Gefäße, welche sich durch abnehmende Kontraste darstellen, sind ein Problem für Segmentierungsmethoden. In diesem Beitrag wird eine Level-Set Methode vorgestellt, welche unter Zuhilfenahme der Richtungsinformation aus dem Vesselnessfilter eine verbesserte Gefäßsegmentierung erlaubt. Die von einem Vesselnessfilter berechnete Richtung eines Gefäßes wird hierbei verwendet, um das Gewicht der für die Glättung zuständigen internen Energie der Level-Set Funktion ortsabhängig zu variieren. Die Idee hierbei ist es, die interne Energie niedriger zu gewichten, falls der Gradient des Level-Sets ähnlich der vorgegebenen Richtung des Vesselness Filters ist. Eine erste quantitative Evaluation basierend auf drei 3D-TOF-MRA-Bildsequenzen mit vorhandenen manuellen Segmentierungen zeigte, dass die Vesselness geführte Gefäßsegmentierung in der Lage ist Gefäße, insbesondere kleine, besser zu detektieren als die korrespondierende Methode ohne Integration der Richtungsinformation. Zusammenfassend zeigen die ersten Ergebnisse, dass die vorgestellte Methode einen vielversprechenden Ansatz darstellt, um eine verbesserte Gefäßsegmentierung, insbesondere die von kleinen Gefäßen, zu erlauben.

## 1 Einleitung

Die Segmentierung der zerebralen Blutgefäße in hochauflösenden 3D-Bildfolgen wird für eine Vielzahl von klinischen Anwendungen, wie zum Beispiel Operationsplanungen und Blutflusssimulationen, benötigt. Zur Segmentierung von Gefäßstrukturen aus unterschiedlichsten Bildsequenzen wurde in der Vergangenheit eine Vielzahl an Methoden vorgestellt. Intensitätsbasierte Ansätze, wie z.B. [1, 2], führen, hervorgerufen durch die verringerten Kontraste und Partialvolumeneffekte, meistens zu einer ungenügenden Detektion von kleinen, dünnen Gefäßstrukturen. Topologie-basierte Ansätze, wie zum Beispiel Vesselness-Filter [3], erlauben zwar eine verbesserte Hervorhebung von kleinen Gefäßen, weisen jedoch Probleme bei der Segmentierung von Gefäßstrukturen auf, welche sich nicht durch eine

typische Gefäßform, wie z.B. der Fall bei Aneurysmen, darstellen. Neben der verbesserten Hervorhebung von kleinen Gefäßen bieten Vesselnessfilter den Vorteil, dass durch die berechnete Hesse-Matrix auch die Hauptrichtung der Gefäße für jedes Voxel bestimmt werden kann. Level-Set Methoden gelten allgemein als mächtig und vergleichbar schnell und es wurden bereits einige Ansätze zur Gefäßsegmentierung vorgestellt (z.B. [4]). Ein Problem hierbei stellt jedoch die Wahl des Gewichts der inneren Energie dar. So verhindert eine starke Krümmung der Gefäße die Ausbreitung der Level-Sets in kleine Gefäße, wenn das Gewicht der internen Energie zu hoch gewählt wurde. Demgegenüber führt ein zu gering gewähltes Gewicht zu einer falschen Entwicklung der Level-Sets in nicht-vaskuläre Gewebe. Ziel dieser Arbeit ist es eine Level-Set Methode vorzustellen, bei der die Richtungsinformation dazu verwendet wird, das Gewicht der internen Energie adaptiv anzupassen. Dieses Vorgehen basiert auf der Annahme, dass es so möglich ist, Gefäße besser zu detektieren als bei einer festen Definition des Gewichts der internen Energie.

## 2 Methoden

### 2.1 Vesselness-Richtungsinformation

Um das interne Gewicht der Level-Set Segmentierung adaptiv auf Basis der vorgegeben Hauptrichtung der Gefäße variieren zu können, ist es zunächst notwendig diese Information voxelweise zu bestimmen. In dieser Arbeit wurde hierzu der Vesselness-Filter von Sato et al. [3] verwendet. Hierbei werden die Eigenwerte der Hesse-Matrix

$$H = \begin{bmatrix} I_{xx} & I_{xy} & I_{xz} \\ I_{yx} & I_{yy} & I_{yz} \\ I_{zx} & I_{zy} & I_{zz} \end{bmatrix} \quad (1)$$

analysiert, wobei  $I_{xx}, I_{xy}, \dots$  die zweiten partiellen Ableitungen des Bildes  $I(x)$  mit  $x = (x, y, z)$  und  $\Omega \subset \mathbb{R}^3$  darstellen. Die Eigenwerte von  $H$  seien definiert mit  $\lambda_1, \lambda_2$  und  $\lambda_3$  ( $\lambda_1 > \lambda_2 > \lambda_3$ ) mit den korrespondierenden Eigenvektoren  $e_1, e_2$  und  $e_3$ . Der Eigenvektor  $e_1$  repräsentiert somit die Richtung, bei der die zweite partielle Ableitung ihr Maximum erreicht (Abb. 1 links). Diese Richtungsinformation wird im Folgenden für die adaptive Anpassung des Gewichts der internen Energie der Level-Set-Methode verwendet.

### 2.2 Vesselness-geführte Level-Set-Segmentierung

Um die zerebralen Gefäße aus einer 3D-Bildsequenz zu extrahieren, wurde in dieser Arbeit ein variationeller Level-Set Ansatz verwendet. Aus mathematischer Sicht wird hierbei die Oberfläche eines Objektes implizit als zero-level Kurve der Level-Set Funktion  $\phi : \Omega \mapsto \mathbb{R}$  (Zero-Level-Set) beschrieben. Das optimale Level-Set wird durch Minimierung des Energiefunktional

$$\mathcal{J}[\phi] := \mathcal{E}[F; \phi] + \omega^\phi \cdot \mathcal{I}[\phi] \quad (2)$$

bestimmt, wobei  $F(x)$  die zugrundeliegende 3D-Bildsequenz ist. Dieses Funktional besteht aus zwei Termen, die die interne bzw. externe Energie repräsentieren. Der Regionen-basierte äußere Energieterm ist dabei definiert als

$$\mathcal{E}[F; \phi] := \int_{\Omega} (1 - H(\phi(x)) p_{in}(F(x))) + H(\phi(x)) p_{out}(F(x)) dx \quad (3)$$


Diese Formulierung erlaubt es, a-priori Wissen über die Intensitätsverteilung innerhalb  $p_{in}$  und außerhalb  $p_{out}$  der Gefäße einzubeziehen. Basierend auf einer initialen Segmentierung und dem zugrundeliegenden Datensatz, können diese Verteilungen mittels einer Parzen-Window-Strategie [5] abgeschätzt werden. Die interne Energie ist definiert durch

$$\mathcal{I}[\phi] = \int_{\Omega} \|\nabla H(\phi(x))\| dx \quad (4)$$

wobei  $H$  die Heavyside-Funktion darstellt, welche dazu verwendet wird, das Innere und Äußere des Objektes zu beschreiben. Die Funktion  $\omega^{\phi} : \Omega \mapsto [0, c]$  wird verwendet um das Gewicht der internen Energie lokal, basierend auf den Winkel  $\alpha$  zwischen  $e_1$  und  $\nabla\phi$ , zu variieren und ist durch

$$\omega^{\phi}(x) := c \cdot (1 - \cos^2(\alpha(x))) \quad \text{with} \quad \cos(\alpha(x)) = \frac{e_1(x) \cdot \nabla\phi(x)}{\lambda_1(x) \cdot \|\nabla\phi(x)\|} \quad (5)$$

definiert. Der Parameter  $c$  kontrolliert dabei die Glättung der Segmentierung, wobei dessen Einfluss durch den zweiten Term gewichtet wird. Wenn  $\alpha$  nahe 0 oder  $\pi$  ist (Abb. 1 rechts: (1)), konvergiert das Gewicht  $\omega^{\phi}$  gegen 0 und es wird keine Glättung angewendet, was der Segmentierung erlaubt sich in kleine Gefäße zu entwickeln. Wenn die Vektoren jedoch nahezu orthogonal zueinander stehen (Abb. 1 rechts: (2)), wird  $\omega^{\phi}$  gleich zu  $c$  und die Segmentierung wird ganz normal geglättet. Zur Lösung von (2) wird vereinfachend die Abhängigkeit des Gewichts  $\omega^{\phi}$  von  $\phi$  vernachlässigt.



**Abb. 1.** Schicht eines 3D-TOF-MRA-Datensatz mit Vesselness-Eigenvektoren (links) und Illustration der richtungsabhängigen Glättung (rechts).

**Tabelle 1.** Quantitative Ergebnisse der Evaluation der vorgestellten Methode mittels Tanimoto-Koeffizienten  $T(A, B)$ .

Datensatz	initial	standard LS	Vesselness-geführte LS
#1	0,629	0,605	0,764
#2	0,739	0,738	0,834
#3	0,743	0,731	0,756
∅	0,704	0,691	0,785


### 2.3 Material und Experimente

Zur ersten Evaluation der vorgestellten Methode wurden drei Time-of-Flight (TOF) MRA-Bildsequenzen verwendet. Die Datensätze wurden ohne Verwendung von Kontrastmitteln mit einem 1,5T Siemens MAGNETOM Sonata Scanner aufgenommen. Jeder Datensatz besteht aus 132 Schichten mit einer Ortsauflösung von  $0,41 \times 0,41 \times 0,8 \text{ mm}^3$ . Manuelle Segmentierungen des zerebralen Gefäßsystems von medizinischen Experten standen für alle Datensätze zur Verfügung und wurden als Goldstandard verwendet. Die manuellen Segmentierungen wurden dabei mittels Volume-Growing und manueller Korrektur in den orthogonalen Sichten erstellt. Zur Initialisierung der Gefäßsegmentierung für die Level-Set Methode wurde ein aktueller Gefäßsegmentierungsansatz [6] verwendet, für den in früheren Arbeiten eine ausreichende Segmentierungsgüte nachgewiesen wurde. Die Gefäßstrukturen wurden mit der vorgestellten Vesselness-geführten Level-Set Methode segmentiert und zusätzlich mit dem selben Ansatz, jedoch ohne Adaptierung des Gewichts der internen Energie. Zur Evaluation der Güte der Segmentierungsergebnisse wurden diese mit dem korrespondierenden Goldstandard unter Verwendung des Tanimoto-Koeffizienten  $T(A, B) = \frac{|A \cap B|}{|A \cup B|}$  verglichen, wobei Werte nahe 1 auf eine gute Übereinstimmung hindeuten.

## 3 Ergebnisse

Tabelle 1 zeigt die Resultate der quantitativen Evaluation der vorgestellten Methode. Die Ergebnisse zeigen, dass die Level-Set Methode ohne Integration der lokal adaptiven Gewichtung der internen Energie zu keiner Verbesserung der initialen Segmentierung führen, sondern tendenziell sogar eine geringe Verschlechterung der quantitativen Ergebnisse zu erkennen ist. Die visuelle Beurteilung der Segmentierungsergebnisse zeigte, dass zwar Übersegmentierung, hervorgerufen durch Rauschartefakte, verringert werden, dass es jedoch auch zu Eliminierung der Segmentierung von kleinen Gefäßen kommt (Abb. 2). Demgegenüber zeigen die quantitativen Ergebnisse, dass die vorgestellte Vesselness-geführte Level-Set Segmentierung zu einer verbesserten Evolution der Segmentierung in kleine Gefäße führt, so dass im Mittel eine quantitative Verbesserung der initialen Segmentierung um 0,081 (Tanimoto-Koeffizient) erreicht wird.

**Abb. 2.** Ausgewählte Schicht eines 3D-TOF-MRA-Datensatzes: Initiale Segmentierung mit Rauschartefakten (links), standard Level-Set Segmentierung mit glättungsbedingten Verlust von Gefäßstrukturen (Mitte) und Vesselness-geführte Level-Set Segmentierung (rechts).



## 4 Diskussion

Die ersten quantitativen und visuellen Ergebnisse zeigen, dass die vorgestellte Methode durch die adaptive Veränderung des Gewichtes der internen Energie des Level-Sets eine verbesserte Segmentierung von zerebralen Gefäßen ermöglicht. Um diese Ergebnisse zu verifizieren, wird derzeit eine Evaluation, basierend auf weiteren Datensätzen, durchgeführt. Zusätzlich ist ein Vergleich mit anderen Methoden zur Gefäßsegmentierung geplant. In diesem Rahmen soll auch untersucht werden, welchen Einfluss die gewählte Initialsegmentierung auf die Ergebnisse des vorgestellten Ansatzes hat. Darüber hinaus soll die vorgestellte Methode auch auf weitere Gefäßstrukturen in anderen Organen angewandt werden, um so die generelle Funktionalität zu testen. Zusammenfassend erscheint die vorgestellte Methode aussichtsreich, exakte Segmentierungen, insbesondere von kleinen Gefäßen, welche sich durch geringe Kontraste darstellen, zu ermöglichen.

## Literaturverzeichnis

1. Hassouna MS, Farag AA, Hushek S, et al. Cerebrovascular segmentation from TOF using stochastic models. *Med Image Anal.* 2006;10(1):2–18.
2. Chapman BE, Stapelton JO, Parker DL. Intracranial vessel segmentation from time-of-flight MRA using pre-processing of the MIP z-buffer. *Med Image Anal.* 2004;8(2):113–26.
3. Sato Y, Nakajimaothers S, Shiraga N, et al. Three-dimensional multi-scale line filter for segmentation and visualization of curvilinear structures in medical images. *Med Image Anal.* 1998;2(2):143–68.
4. Lorigo LM, Faugeras OD, Grimson WE, et al. CURVES: Curve evolution for vessel segmentation. *Med Image Anal.* 2001;5(3):195–206.
5. Parzen E. On estimation of a probability density function and mode. *Ann Math Stat.* 1962;33(3):1065–76.
6. Forkert ND, Säring D, Wenzel K, et al. Fuzzy-based extraction of vascular structures from time-of-flight MR images. *Stud Health Technol Inform.* 2009;150:816–20.