

Ocena metody zbiorów poziomicowych stosowanych do segmentacji trójwymiarowych obrazów fantomów cyfrowych oraz obrazów naczyń krwionośnych mózgu TOF-SWI rezonansu magnetycznego

Evaluation of level set method in segmentation of 3D digital phantom images and brain vessels TOF-SWI MR images

Michał Strzelecki¹, Andrzej Materka¹, Marek Kociński¹, Piotr Szczypiński¹,
Andreas Deistung², Jürgen Reichenbach²

¹ Instytut Elektroniki, Politechnika Łódzka, ul. Wólczańska 211/215, 90-924 Łódź, tel. +48 (42) 631 26 31,
e-mail: mstrzel@p.lodz.pl

² Friedrich Schiller University, Medical Physics Group, Philosophenweg 3, D-07743 Jena, Germany

Streszczenie

W pracy zbadano dokładność metody segmentacji *level set* stosowanej do analizy trójwymiarowych obrazów fantomów przedstawiających fragmenty naczyń oraz układ drzew krwionośnych. Badano przydatność metody do detekcji cienkich naczyń (o średnicy mniejszej niż rozmiar woksela obrazu) oraz jej odporność na zakłócenia. Oceny metody dokonano za pomocą obiektywnej miary ilościowej opisującej dokładność segmentacji. Metodę *level set* wykorzystano również do segmentacji rzeczywistych trójwymiarowych obrazów TOF-SWI (*Time Of Flight and Susceptibility Weighted Imaging*) rezonansu magnetycznego naczyń krwionośnych mózgu wraz z metodą Sato, wykorzystującą filtrację wieloskalową. Wstępne wyniki, w postaci trójwymiarowych modeli naczyń krwionośnych, są obiecujące. W pracy przedstawiono kierunki dalszych badań prowadzących do uzyskania dokładniejszych modeli układu krwionośnego, zwłaszcza dla naczyń o małych średnicach.

Słowa kluczowe: segmentacja obrazów 3D, metoda *level set*, cyfrowe fantomy naczyń krwionośnych, obrazy 3D TOF-SWI MR układu krwionośnego mózgu, modelowanie naczyń krwionośnych

Abstract

The objective of this work is to evaluate performance of the level set approach applied to segmentation of 3D images of computer-simulated blood-vessel phantoms and artificial vascular trees. The segmentation of thin vessels with diameter smaller than voxel size and influence of noise on segmentation results, were studied. Quantitative measures of segmentation accuracy were used for the methods evaluation. The level set technique was also used for segmentation of 3D TOF-SWI MR (*Time Of Flight and Susceptibility Weighted Magnetic Resonance Imaging*) brain vessels images. Also, the multiscale filtering approach was applied. Preliminary results in the form of 3D vein and artery models are promising. Further work aimed at more accurate modeling of brain vasculature, focused on thin vessels detection is also addressed.

Key words: 3D image segmentation, level set, computer-simulated vascular trees, 3D TOF-SWI MR images of brain vasculature, blood vessel modeling

Wprowadzenie

Analiza trójwymiarowych obrazów rezonansu magnetycznego (3D MRI – *magnetic resonance imaging*) naczyń krwionośnych mózgu jest bardzo ważna z punktu widzenia diagnostyki i terapii chorobowych zmian układu krwionośnego. Przykładem może być analiza sieci naczyń krwionośnych nowotworów mózgu. Jedną z metod analizy takich obrazów jest segmentacja, polegająca na oddzieleniu struktury naczyń krwionośnych od innych tkanek, w celu m.in. oszacowania objętości układu naczyń. Wynik segmentacji może być podstawą do modelowania naczyń – dla symulacji przepływu krwi w naczyniach lub wykrycia patologicznych przewężeń. Innym ważnym zagadnieniem związanym z segmentacją obrazów układu krwionośnego jest śledzenie naczyń, polegające na wykryciu takich pikseli lub wokseli obrazu, które zawierają nawet niewielki fragment naczynia. Metody segmentacji naczyń krwionośnych powinny być dokładne, tzn. jednoznacznie wykrywać te woksle obrazu, które zawierają naczynia krwionośne. Należy tu zdefiniować dwa problemy, które mają wpływ na jakość segmentacji i w konsekwencji na poprawność diagnozy. Pierwszy jest związany z naczyniami, których średnica jest mniejsza od rozmiarów woksela obrazu. W takim przypadku wksel, poza fragmentem naczynia, będzie odwzorowywał również inne tkanki. Drugim problem są zakłócenia występujące w obrazach MR, które mogą prowadzić do błędnej klasyfikacji części wokseli (woksle należące tła obrazu mogą zostać sklasyfikowane jako fragmenty naczyń lub odwrotnie).

Istnieje wiele metod segmentacji obrazów naczyń krwionośnych mózgu. Mogą one być podzielone na trzy grupy. Pierwsza z nich obejmuje metody związane z przetwarzaniem obrazów, jak np. filtracja wykonywana dla wielu skal obrazu, filtracja morfologiczna lub wyznaczanie szkieletu układu krwionośnego [1-3]. Inna grupa metod wykorzystuje matematyczne modelowanie obrazu, co polega na dopasowaniu hiperpowierzchni do kształtu naczyń krwionośnych. Metody te wykorzystują aktywny kontur lub zbiory poziomicowe (*level set*) [4-7]. Trzecia grupa metod bazuje na wiedzy *a priori* doty-

czącej układu krwionośnego mózgu, odwzorowanej w atlasach anatomicznych [8]. Takie atlasy służą jako pewien wzorzec wykorzystywany przy prezentacji i ocenie wyników segmentacji sieci naczyń uzyskiwanych dla różnych pacjentów. Przegląd metod segmentacji obrazów naczyń krwionośnych można znaleźć w dostępnej literaturze [9].

Obrazy 3D układu krwionośnego mózgu można uzyskać np. z wykorzystaniem angiografii rezonansu magnetycznego (MRA – *Magnetic Resonance Angiography*). Ta metoda obrazowania pozwala na uzyskanie obrazów tętnic (TOF – *Time of Flight*) lub żył (sekwencja SWI – *susceptibility weighted imaging*). W pracy analizowano obrazy uzyskane metodą łączącą techniki TOF i SWI, opracowaną na uniwersytecie w Jenie. Pozwala ona uzyskać obrazy żył i tętnic z wykorzystaniem pojedynczej sekwencji TOF-SWI [10]. W wyniku segmentacji takich obrazów można uzyskać kompletny model naczyń krwionośnych mózgu, bez konieczności dopasowywania niezależnie uzyskanych obrazów tętnic i żył.

Wzrosło zainteresowanie metodami segmentacji z wykorzystaniem zbiorów poziomicowych, ze względu na ich stosunkowo dużą prędkość działania, a także zdolność do dokładnego odwzorowania złożonego kształtu naczyń. Metody te są często stosowane jako jeden z etapów w procesie segmentacji [11]. Są one również stosunkowo odporne na nierównomierny rozkład jasności w obrazach, co często ma miejsce w przypadku rzeczywistego obrazowania MR [12, 13]. Z tych względów zdecydowano wykorzystać metodę zbiorów poziomicowych do analizy obrazów 3D naczyń krwionośnych. Badano odporność tej metody na zakłócenia występujące w obrazach MR oraz skuteczność wykrywania cienkich naczyń, których średnica jest mniejsza od rozmiarów woksela obrazu. Ponieważ takie naczynia nie mogą być w pełni odwzorowane, w przeprowadzonych symulacjach przyjęto, że poziom jasności woksela jest proporcjonalny do objętości fragmentu naczynia w nim zawartego. W przypadku wystąpienia zakłóceń, algorytm segmentacji może błędnie klasyfikować woksela obrazu. Aby zbadać wpływ tego efektu na jakość segmentacji, metoda level set została wykorzystana do analizy sztucznie wygenerowanych obrazów 3D cyfrowych fantomów przedstawiających walce o różnych średnicach oraz symulowane drzewa naczyń krwionośnych [14]. Metodę tę zastosowano również do segmentacji rzeczywistych obrazów MR żył mózgu wraz z metodą Sato użytą do segmentacji obrazów MR tętnic dla porównania [15].


Materiały i metody

Do wstępnego oszacowania dokładności algorytmu segmentacji wygenerowano cyfrowe fantomy w kształcie walców o różnych średnicach, zakończone półkulami (rys. 1) [18]. Walce te modelują fragmenty naczyń krwionośnych. Rzeczywistą objętość takich walców można wyznaczyć na podstawie wzoru (1):


$$V_0 = \pi R^2 L + (4/3) \pi R^3 \quad (1)$$

gdzie R i L oznaczają odpowiednio promień i długość walca.

Wygenerowano 6 klas walców o różnych średnicach, $D = \{1, 2, 4, 6, 8, 10\}$ wokseli. Każda klasa zawierała 32 próbki walców wygenerowanych dla różnych kątów azymutu i elewacji. Długość walców we wszystkich klasach była jednakowa i wynosiła 80 wokseli. Wektorowe obrazy cylindrów zostały skwantowane do postaci cyfrowej. Jasności wokseli w tych obrazach były proporcjonalne do objętości fragmentu walca w nich zawartego. Analizowane obrazy zostały zakłócone szumem Rice'a, typowo występującym w obrazach MR, dla różnych wartości parametru s tego zakłócenia, $s = \{1, 3, 5, 10\}$ [16]. Rozmiary tych obrazów wynosiły $100 \times 100 \times 100$ wokseli.



Rys. 1 Przykłady obrazów cyfrowych fantomów – walców o jednakowej długości ($L=80$ wokseli), kątach azymutu i elewacji (45° , 45°) i różnych średnicach $D = \{1, 4, 10\}$ wokseli



Rys. 2 Obraz 3D wygenerowanego drzewa, projekcja MIP (a). Obrazy drzew z określoną minimalną średnicą gałęzi, wynoszącą odpowiednio 1,5 (b) oraz 3 wokselse (c)

W celu oceny algorytmu segmentacji, zarówno ilościowej, jak i jakościowej, wygenerowano fantomy w postaci sztucznych drzew naczyń krwionośnych, które bardziej odpowiadają rzeczywistemu układowi naczyń mózgu. Do generacji drzew zastosowano własny symulator, wykorzystujący algorytm Karcha [17]. Opis tego symulatora oraz algorytmu generacji drzew można znaleźć w dostępnej literaturze [18]. Wygenerowano wiele klas drzew o różnych parametrach (liczbie gałęzi wylotowych, przepływie przez gałąź wejściową Q_{inp} oraz przez gałęzie wyjściowe Q_{out}). Każda klasa liczyła 32 próbki, a obrazy miały rozmiary $256 \times 256 \times 256$ wokseli. Obraz przykładowego drzewa – projekcja maksymalnej intensywności, (MIP – *maximum intensity projection*) pokazano na rys. 2a. Dla zbadania wpływu grubości gałęzi drzewa na dokładność segmentacji wygenerowano klasy drzew, których najcięższe gałęzie miały określoną średnicę w wokselah, $d = \{0.5, 1.0, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0\}$. Obrazy takich drzew o określonych minimalnych średnicach gałęzi pokazano na rys. 2b, c. Obrazy drzew zostały zakłócone szumem Rice'a w taki sam sposób, jak obrazy walców.

Analizowano również rzeczywiste obrazy 3D MR naczyń krwionośnych ludzkiego mózgu. Obrazy te uzyskano, stosując sekwencję TOF-SWI: $TE1/TE2/TR/FA/BW1/BW2 = 3,42 \text{ ms}/25 \text{ ms}/42 \text{ ms}/20^\circ \text{ TONE}/271 \text{ Hz/px}/78 \text{ Hz/px}$, bez zastosowania środka cieniującego [12]. Przykładowy taki obraz pokazano na rys. 9a. Rekonstrukcję obrazów, mającą miejsce po akwizycji danych, utrudniają dwa problemy: nierównomierny rozkład jasności spowodowany m.in. łączeniem poszczególnych fragmentów oraz artefakty, będące skutkiem niejednorodności sygnału MR [19].

Segmentacja z wykorzystaniem zbiorów poziomicowych pozwala na znalezienie granicy między dwoma (lub więcej) obszarami obrazu za pomocą funkcji ϕ , której wartości są zdefiniowane w dziedzinie intensywności obrazu. Kształt i położenie tej funkcji zmienia się w czasie, począwszy od określonego stanu początkowego. Granicę między obszarami obrazu uzyskuje się przez rozwiązanie równania $\phi = 0$. Oznacza to znalezienie stanu ustalonego, w którym funkcja ϕ przestaje zmieniać swoje wartości. Wynik segmentacji zależy od sposobu, w jaki ewoluuje funkcja ϕ . W niniejszej pracy przyjęto tzw. model Chan-Vese, opisany równaniem (2) [20]:

$$\frac{\partial \varphi(x,y,z,t)}{\partial t} = \delta(\varphi) [\mu \kappa(\varphi) - \lambda_1 (I(x,y,z) - \bar{x}_1)^2 + \lambda_2 (I(x,y,z) - \bar{x}_2)^2] \quad \lambda_1, \lambda_2, \mu > 0 \quad (2)$$

gdzie t jest czasem, δ – pochodną ciąglej funkcji aproksymującej funkcję sigum φ , $I(x,y,z)$ oznacza poziom jasności wokselu obrazu; \bar{x}_1, \bar{x}_2 są odpowiednio średnimi jasnościami obszarów leżących na zewnątrz i wewnątrz funkcji φ , κ jest krzywizną funkcji φ , μ jest stałą. Funkcja φ osiąga stan ustalony, gdy prawa strona równania (2) osiąga minimum. Ma to miejsce wtedy, gdy kształt funkcji dopasuje się do jednorodnych obszarów obrazu. Zadaniem współczynnika κ jest zapewnienie maksymalnie gładkiego kształtu funkcji φ . Równanie (2) jest rozwiązywane iteracyjnie [19].

W przypadku, gdy celem analizy jest segmentacja, przyjmuje się $\lambda_1 = \lambda_2 = 1$. Średnie jasności obszarów \bar{x}_1, \bar{x}_2 pozostają stałe podczas ewolucji funkcji φ .

Jeśli metoda *level set* ma prowadzić do śledzenia naczyń, należy przyjąć $\lambda_1 > \lambda_2$, zaś średnie jasności obszarów są wyznaczać po każdej iteracji rozwiązywania równania (2). W tym przypadku minimalizacja elementu równania (2) związanego z λ_1 (odpowiadającego obszarowi na zewnątrz funkcji φ) jest bardziej istotna niż drugiego elementu (odpowiadającego obszarowi wewnątrz funkcji φ). Takie ustalenie reguł minimalizacji (2) oznacza, że obszar zewnętrzny nie powinien zawierać naczyń krwionośnych, tylko tło obrazu. Naczynia wypełniają zatem obszar wewnętrzny. Potencjalną wadą tego rozwiązania jest możliwość przypisania zakłóconego przez szum wokselu tła do obszaru naczyń.

Algorytm segmentacji Sato wykorzystuje różnice intensywności między naczyniami krwionośnymi a otaczającą je tkanką [15]. Dla każdego wokselu obliczana jest macierz pochodnych cząstkowych drugiego rzędu – hesjan. Ponieważ dane angiograficzne zawierają naczynia krwionośne różniące się rozmiarami średnic, stosuje się filtrację z wykorzystaniem filtru Gaussa o różnych częstotliwościach granicznych. Wyznaczenie wartości własnych hesjanu umożliwia zaproponowanie miary, która uwydatni długie, ciągłe struktury w obrazie (odpowiadające naczyniom krwionośnym) przy jednoczesnym tłumieniu elementów tła. Wynikiem filtracji jest obraz rastrowy odzwierciedlający sieć naczyń krwionośnych o wszystkich wartościach średnic [18].

Do ilościowej oceny dokładności algorytmów segmentacji wykorzystano współczynnik Jaccarda (\mathcal{J}). Jest on zdefiniowany następującym wzorem [21]:

$$\mathcal{J} = \frac{\#(V_E \cap V_S)}{\#(V_E \cup V_S)} \quad (3)$$

gdzie V_E jest zbiorem wokseli binarnego (niezakłóconego) obrazu walca lub drzewa, natomiast V_S jest zbiorem wokseli po segmentacji obrazu walca lub drzewa z dodanym szumem, zaś $\#$ oznacza liczbę elementów zbioru.

Zakłócone szumem Rice'a obrazy cyfrowych fantomów oraz drzew zostały poddane analizie z wykorzystaniem dwóch rodzajów metody *level set* (segmentacja i śledzenie). Do oceny algorytmów porównano uzyskane w wyniku ich działania obrazy V_S oraz binarne wersje obrazów niezakłóconych V_E . Binarne wersje tych obrazów uzyskano przez progowanie: każdy woksel obrazu o jasności większej od zera został przypisany do drzewa naczyń (lub walca). Suma niezerowych wokseli obrazu dała wartość V_E . Następnie, do oceny wyników segmentacji śledzenia naczyń, wyznaczono współczynnik \mathcal{J} , którego wartość jest proporcjonalna do liczby wokseli występujących w obrazach oryginalnych i uzyskanych w wyniku segmentacji. Zatem wartość współczynnika \mathcal{J} określa wpływ zakłóceń na uzyskane wyniki.


Wyniki i dyskusja

Objętości V_E walców w cyfrowych obrazach fantomów zostały wyznaczone jako ważona suma wokseli o niezerowej jasności (współczynnikami wag były jasności poszczególnych wokseli, które odwzorowują objętość fragmentu naczynia w nich zawartego). Na podstawie tych obrazów wyznaczono błędy dyskretyzacji prowadzące do różnic między rzeczywistą objętością walca (1) a objętością wyznaczoną w obrazach cyfrowych. Procentową wartość błędu objętości wyznaczono ze wzoru (4):

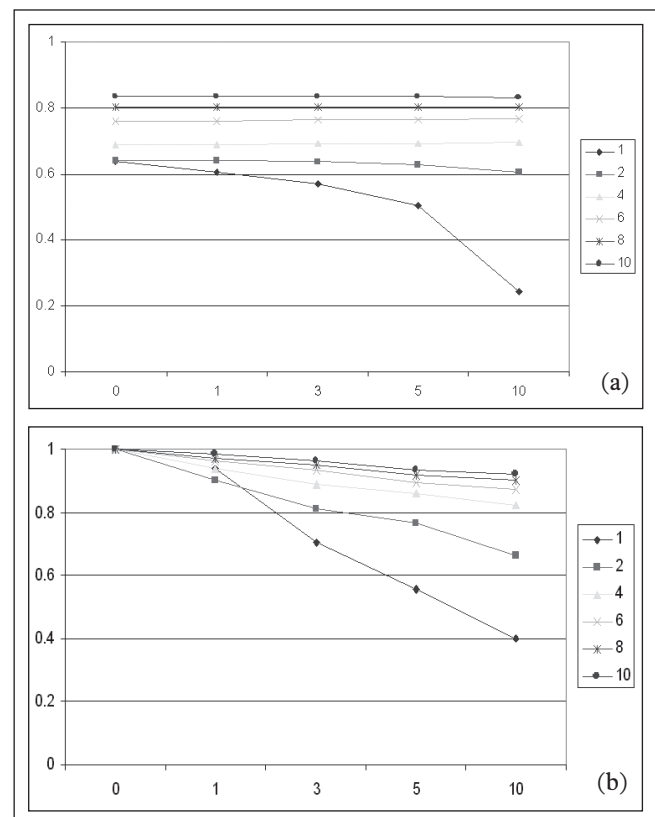
$$e = 100(V_E - V_0)/V_0 \quad (4)$$

Rozkłady wartości tego błędu wyznaczonego dla 32 próbek każdej z klas fantomów pokazano na rys. 3.


Na rys. 4 pokazano rozkład wartości współczynnika \mathcal{J} uzyskany metodą *level set* dla walców o różnych średnicach




Rys. 3 Rozkłady wartości błędów objętości e dla cyfrowych fantomów – walców o różnych średnicach



Rys. 4 Porównanie wartości współczynnika \mathcal{J} w funkcji parametru zakłócenia s dla dwóch odmian metody *level set*: segmentacji (a) oraz śledzenia (b) dla obrazów walców



Rys. 5 Wyniki segmentacji przykładowego obrazu drzewa metodą level set (segmentacja) (a) oraz błędy klasyfikacji wokseli (b): przypadki fałszywie pozytywne (niewykryte wokselse należące do drzewa)



Rys. 6 Porównanie wartości współczynnika J (w funkcji s) dla dwóch rodzajów metody level set zastosowanej do segmentacji obrazów drzew


w funkcji współczynnika szumu Rice'a s . Dla średnic większych od 1 i dla większości wartości parametru s (poza maksymalną), wartości współczynnika J (uśrednionego dla 32 próbek) przekraczają 0,6 (segmentacja) oraz 0,8 (śledzenie), co świadczy o dobrym podobieństwie pomiędzy obrazami po segmentacji a obrazami wzorca (rys. 4a, b). Większe wartości współczynnika J dla przypadku śledzenia wynikają z wykrycia większej liczby wokseli zawierających niewielkie fragmenty walca (o małych poziomach jasności). W przypadku segmentacji część tych wokseli została zaklasyfikowana jako tło obrazu. Dla średnic równych 1, nawet dla niedużych wartości zakłócenia s , wartość J maleje, zatem odwzorowanie kształtu fantomów po segmentacji jest w tym przypadku niedokładne.

Na podstawie rys. 5 można zaobserwować, że w przypadku obrazów drzew błędy segmentacji narastają dla cienkich gałęzi drzewa. Dodatkowo, wartości tych błędów rosną w przypadku większych zakłóceń. Artefakty, występujące w rzeczywistych obrazach MR (np. w postaci nierównomiernego lub nieciągłego rozkładu jasności), powodują dodatkowe pogorszenie dokładności segmentacji [12]. Rozkład wartości współczynnika J dla obrazów drzew pokazano na rys. 6.


Następnie przeprowadzono segmentację obrazów drzew z określonymi minimalnymi średnicami gałęzi. Przykładowe wyniki uzyskane dla współczynnika szumu $s=3$ i kilku wybranych minimalnych średnic gałęzi pokazano na rys. 7 dla metody level set (śledzenie). Wyniki segmentacji zaznaczono zielonym kolorem, błędnie wykryte wokselse nienależące do drzewa (przypadki fałszywe negatywne) zaznaczone są niebieskim, zaś wokselse drzewa, które nie zostały wykryte (fałszywe pozytywne) – kolorem czerwonym.

Podobnie jak w poprzednim przypadku, błędy segmentacji występują głównie dla cienkich gałęzi. Minimalna średnica gałęzi poprawnie wykrytych zależy od wielkości zakłócenia. Zależność tę przedstawiono na rys. 8, jako zależność wartości parametru J od współczynnika s .

Na rys. 9b pokazano model 3D żył uzyskany na podstawie segmentacji metodą level set (śledzenie). Na początku obraz



Rys. 7 Wyniki segmentacji (level set, śledzenie) dla drzew z określoną minimalną średnicą gałęzi wynoszącą: 1 woxsel (górny rząd), 2,5 wokselse (środkowy rząd) i 4 wokselse (dolny rząd). Kolor zielony – wynik segmentacji (a), kolor niebieski: wokselse fałszywie negatywne (b), kolor czerwony: wokselse fałszywie pozytywne (c)




Rys. 8 Rozkład wartości współczynnika J w zależności od parametru zakłócenia s dla różnych wartości minimalnych średnic gałęzi drzew d

z rys. 9a poddano progowaniu dla arbitralnie ustalonej dużej wartości progu. Uzyskany w ten sposób obraz fragmentów naczyń posłużył jako obraz wejściowy dla metody level set. Duże naczynia są odtworzone poprawnie, natomiast w modelu występują fragmenty czaszki oraz szczeliny podłużnej mózgu. Wskazuje to na konieczność zastosowania dodatkowych metod przetwarzania uzyskanego po segmentacji obrazu binarnego. Do tego celu można wykorzystać np. atlas anatomiczny, w celu określenia rodzaju wykrytych obiektów – pozwoli to pominąć obiekty niebędących naczyniami.


Przykładowe wyniki uzyskane dla filtracji wieloskalowej (metoda Sato) pokazano na rys. 10. Można zaobserwować, że naczynia o grubości odpowiadającej skali filtracji zostały rozjaśnione. Progowanie obrazów z rys. 10 pozwala na rekonstrukcję drzewa tętnic. Przykład takich rekonstrukcji pokazano na rys. 11. Struktura tych drzew zależy od wartości skali oraz progu.

Podsumowanie

W artykule dokonano oceny metody segmentacji level set z wykorzystaniem obrazów cyfrowych fantomów, przedsta-



Rys. 9 Obraz SWI MR naczyń mózgu, przekrój osiowy, projekcja MIP (a). Obraz żył (projekcja MIP) uzyskany na podstawie segmentacji level set (śledzenie)




Rys. 10 Wyniki filtracji wieloskalowej metodą Sato dla obrazów TOF MR tętnic (projekcje MIP), przy różnych współczynnikach skali: $\sigma=0,5$ (a), $\sigma=0,8$ (b), $\sigma=1,0$ (c), $\sigma=3,0$ (d)

wiających sztucznie wygenerowane fragmenty naczyń oraz drzewa naczyń krwionośnych. Metodę tę, wraz z metodą Sato, wykorzystującą filtrację wieloskalową, zastosowano do segmentacji obrazów 3D TOF-SWI MR naczyń krwionośnych mózgu, uzyskując modele 3D drzew żył i tętnic. Obydwie metody są skuteczne w detekcji obszarów naczyń oraz odporne na zakłócenia występujące w obrazach TOF-SWI. Charakteryzują się dobrym odwzorowaniem grubych naczyń, tzn. takich, których średnica jest większa od rozmiarów woksela obrazu. Do oceny dokładności tych metod niezbędne są obrazy rzeczywistych fantomów modelujących naczynia krwionośne. Do detekcji cieńszych naczyń potrzebne jest zastosowanie modeli hybrydowych, wykorzystujących np. analizę tekstury do charakterystyki tkanek wypełnionych naczyniami o średnicach mniejszych od rozmiaru woksela [18]. Dalsze prace będą dotyczyły rozwoju takich metod oraz oceny ich dokładności przy tworzeniu trójwymiarowych modeli układu krwionośnego mózgu. ■

Podziękowanie

Praca powstała w ramach programu polsko-niemieckiego DWM/36/DFG/2007.



Rys. 11 Modele 3D drzewa tętnic uzyskane na podstawie metody Sato dla różnych skal i wartości progów: $\sigma=0,5$, próg=50 (a); $\sigma=1,0$, próg=30 (b)

Literatura

1. F. Frangi, W. J. Niessen, K. L. Vincken, M. A. Viergever: *Multiscale Vessel Enhancement Filtering*, Proc. of MICCAI 1998, s. 130-137.
2. N. Passat, C. Ronse, J. Baruthio, J.-P. Armspach: *Automatic parameterization of grey-level hit-or-miss operators for brain vessel segmentation*, Proc. of ICASSP 2005, vol. 2, s. 737-740.
3. E. Sorantin, C. Halmaj, B. Erdohelyi, K. Palagyi, L. Nyul, K. Olle, B. Geiger, F. Lindbichler, G. Friedrich, K. Kiesler: *Spiral-CT based assessment of tracheal stenoses using 3-dskeletonization*, IEEE Transactions on Medical Imaging, vol. 21(3), 2002, s. 263-273.
4. Y. Hu, W. Rogers, D. Coast, C. Kramer, N. Reichek: *Vessel boundary extraction based on a global and local deformable physical model with variable stiffness*, Journal of Magnetic Resonance Imaging, vol. 16(8), 1998, s. 943-951.
5. J. Chen, A. Amini: *Quantifying 3-D vascular structures in MRA images using hybrid PDE and geometric deformable models*, IEEE Transactions on Medical Imaging, vol. 23(10), 2004, s. 1251-1262.
6. R. Manniesing, B.K. Velthuis, M.S. van Leeuwen, I.C. van der Schaaf, P.J. van Laar, W.J. Niessen: *Level set based cerebral vasculature segmentation and diameter quantification in CT angiography*, Medical Image Analysis, vol. 10, 2006, s. 200-214.
7. L. Lorigo, W. Grimson, L. Eric, O. Faugeras, R. Keriven, R. Kikinis, A. Nabavi, C.F. Westin: *Two geodesic active contours for the segmentation of tubular structures*, Proc. Comput. Vision Pattern Recognition (CVPR), 2000, s. 444-451.
8. N. Passat, C. Ronse, J. Baruthio, J.P. Armspach, C. Maillot: *Magnetic resonance angiography: From anatomical knowledge modeling to vessel segmentation*, Medical Image Analysis, vol. 10, 2006, s. 259-274.
9. J. Suri, K. Liu, L. Reden, S. Laxminarayan: *A review on MR vascular image processing algorithms: acquisition and pre-filtering: Part I & II*, IEEE Transactions on Information Technology In Biomedicine, vol. 6(4), 2002, s. 324-337, 338-360.
10. A. Deistung, E. Dittich, J. Sedlacik, A. Rauscher, J. Reichenbach: *ToF-SWI: A dual-echo sequence for simultaneous time-of flight angiography and susceptibility weighted imaging*, Proc. of 17th Scientific Meeting, International Society for Magnetic Resonance in Medicine, 2009, s. 2650.
11. C. Kirbas, F. Quek: *A review of vessel extraction techniques and algorithms*, ACM Computing Surveys, vol. 36(2), 2004, s. 81-121.

12. A. Deistung, E. Dittrich, J. Sedlacek, A. Rauscher, J. Reichenbach: *ToF-SWI: Simultaneous time of flight and fully compensated susceptibility weighted imaging*, Journal of Magnetic Resonance Imaging, vol. 29(6), 2009, s. 1478-1484.
13. K.W. Sum, P. Cheung: *Vessel extraction under non-uniform illumination: A level set approach*, IEEE Transaction on Biomedical Engineering, vol. 55(1), 2008, s. 358-360.
14. M. Strzelecki, P. Szczypinski, A. Materka, M. Kocinski, A. Sankowski: *Level-set segmentation of noisy 3D images of numerically simulated blood vessels and vascular trees*, Proc. of 6th International Symposium on Image and Signal Processing and Analysis, s. 742-747.
15. Y. Sato, S. Nakajima, H. Atsumi, T. Koller, G. Gerig, S. Yoshida, R. Kikinis: *3D multi-scale line filter for segmentation and visualization of curvilinear structures in medical image*, 1997, <http://www.spl.harvard.edu/archive/spl-pre2007/pages/papers/yoshi/cr.html>.
16. R. Nowak: *Wavelet-based Rician noise removal for magnetic resonance imaging*, IEEE Transactions on Image Processing, vol. 8, 1999, s. 1409-1418.
17. R. Karch, F. Neumann, M. Neumann, W. Schreiner: *A three-dimensional model for arterial representation, generated by constrained constructive optimization*, Computers in Biology and Medicine, vol. 29, 1999, s. 19-38.
18. M. Kociński: *Quantitative analysis of vascular trees represented by digital images*, PhD Thesis, Technical University of Lodz, Faculty of Electrical, Electronic, Computer and Control Engineering, 2009.
19. A. Materka, M. Strzelecki, P. Szczypinski, M. Kocinski, A. Deistung, J. R. Reichenbach: *Arteries tracking in simultaneous TOF-SWI MR images: image characteristics and preliminary results*, Proceedings of 6th International Symposium on Image and Signal Processing and Analysis, s. 748-753.
20. T. Chan, L. Vese: *Active Contours Without Edges*, IEEE Transactions on Image Processing, vol. 10(2), 2001, s. 266-277.
21. P. Tan, M. Steinbach, V. Kumar: *Introduction to data mining*, Addison Wesley, 2005.

otrzymano / received: 06.04.2010 r.
zaakceptowano / accepted: 12.05.2010 r.