

## Andrzej SKALSKI<sup>1</sup>, Tomasz ZIELIŃSKI<sup>2</sup>

<sup>1</sup> AKADEMIA GÓRNICZO-HUTNICZA W KRAKOWIE, KATEDRA METROLOGII

<sup>2</sup> AKADEMIA GÓRNICZO-HUTNICZA W KRAKOWIE, KATEDRA TELEKOMUNIKACJI

# Segmentacja i dopasowywanie cyfrowych obrazów medycznych: przetwarzanie nagrań wideo-endoskopowych strun głosowych oraz danych tomograficznych zmian rakowych

Mgr inż. Andrzej SKALSKI

Absolwent wydziału Elektrotechniki, Automatyki, Informatyki i Elektroniki Akademii Górniczo-Hutniczej w Krakowie. Obecnie doktorant oraz asystent w Katedrze Metrologii wyżej wymienionego wydziału. Zainteresowania naukowe koncentrują się wokół zagadnień związanych z analizą i przetwarzaniem obrazów medycznych w szczególności z metodami segmentacji oraz algorytmami image registration.



e-mail: skalski@agh.edu.pl

Prof. dr hab. inż. Tomasz ZIELIŃSKI

Absolwent kierunku Elektronika Wydziału EAIiE Akademii Górniczo-Hutniczej. Od 1982 do 2006 roku był zatrudniony w Katedrze Metrologii AGH, obecnie jest pracownikiem Katedry Telekomunikacji AGH. Zajmuje się algorytmami cyfrowego przetwarzania sygnałów w zastosowaniach pomiarowych w telekomunikacji i biomedycynie, w szczególności metodami analizy czasowo-częstotliwościowej sygnałów.



e-mail: tzielin@agh.edu.pl

### Streszczenie

Celem artykułu jest wprowadzenie do zagadnienia segmentacji i dopasowywania cyfrowych obrazów medycznych 2D i 3D, np. z endoskopii i tomografii komputerowej, oraz krótki przegląd stosowanych metod. Na tym tle zaprezentowano nowe, oryginalne wyniki prac własnych autorów, dotyczących analizy cyfrowych nagrań wideo strun głosowych. Badania te mają na celu estymację parametrów ruchu tych strun dla ludzi zdrowych oraz chorych, np. ze zmianami nowotworowymi. W tym ostatnim przypadku wskazana jest analiza danych wideo przed i po terapii laserowej. W artykule porównano poprzednie wyniki autorów uzyskane dla metody segmentacji metodą poziomicy (*level sets*) z metodą rozrostu obszarów (*region growing*). W końcowej części pracy zaprezentowano przykład zastosowania dopasowywania danych tomograficznych pacjenta podczas radioterapii zmian nowotworowych.

**Słowa kluczowe:** obrazy medyczne, endoskopia, tomografia komputerowa, struny głosowe, segmentacja, metoda poziomicy, metoda rozrostu obszarów, dopasowywanie obrazów, radioterapia, rak prostaty.

## Segmentation and Registration of Digital Medical Images: Processing Endoscopic Videos of Vocal Folds and Tomographic Data of Cancer Changes

### Abstract

In the paper introduction to segmentation and registration of medical 2D/3D data, coming from medical endoscopy and computed tomography, is done and a brief description of the most popular methods is presented. On this background, as an example, new original results of vocal folds video analysis are given. In this case evaluation of vocal folds motion parameters for people in good health and sick persons with cancer changes is addressed, especially before and after the laser treatment. In the paper previous segmentation results obtained for level sets methods are compared with application of a region growing approach. Finally, application of registration to computed tomography data before cancer radiotherapy is shown in the paper.

**Keywords:** medical images, endoscopy, computed tomography, vocal folds, segmentation, level set method, region growing, image registration, radiotherapy, cancer changes.

### 1. Wstęp

Obecnie w diagnostyce i terapii medycznej coraz większą rolę odgrywają dane cyfrowe 2D/3D, otrzymywane z różnych urządzeń skanujących typu kamery endoskopowe i laparoskopowe, echografy ultrasonograficzne oraz urządzenia rentgenowskie i tomografy komputerowe [1]. Dane te mają postać zbiorów liczb, zebranych w macierze 2D lub 3D, reprezentujących np. intensywność kolorów (endoskopia) lub gęstość materii (tomografia).

Na ich podstawie przeprowadzana jest diagnostyka stanu poszczególnych narządów człowieka (wielkość, kształt, kolor, tekstura) oraz monitorowany postęp prowadzonej terapii. Do podstawowych operacji cyfrowego przetwarzania sygnałów w zastosowaniach medycznych należy operacja segmentacji (*image segmentation*) [2, 3], czyli łączenia ww. liczb (pikseli, wokseli) w grupy odpowiadające jednemu narządowi lub tej samej cesze, np. zaczerwienienie, oraz operacja dopasowywania do siebie dwóch zbiorów liczb (*image registration*) [2, 4, 5], np. przedstawiających ten sam narząd w dwóch różnych badaniach, dwóch różnych chwilach lub pochodzących z różnych urządzeń.

W pierwszej części artykułu dokonano skrótego wprowadzenia do problematyki segmentacji i dopasowywania do siebie danych medycznych. W jego drugiej części przedstawiono praktyczny przykład zastosowania omawianych metod do segmentacji obrazu strun głosowych w nagraniach wideo oraz do dopasowywania do siebie konturów strun z poszczególnych klatek filmu w celu wyznaczania ich parametrów ruchu przed i po terapii laserowej zmian rakowych. W porównaniu z poprzednią publikacją autorów [6], obecnie dodatkowo zastosowano i przetestowano skuteczność segmentacji obrazu strun za pomocą metody rozrostu obszarów. Artykuł kończy przykład zastosowania metod segmentacji i dopasowywania danych tomograficznych pacjenta w radioterapii zmian rakowych, wcześniej opisany w [7].

### 2. Segmentacja obrazów

Przez segmentację obrazów 2D/3D (*image segmentation*) rozumie się podział zbioru pikseli (2D) lub wokseli (3D) na rozłączne podzbiory, które reprezentują różne struktury anatomiczne w przypadku obrazów medycznych. Ta definicja dotyczy wszystkich tzw. metod „twardych” (*hard segmentation*), które dają jednoznaczny odpowiedź na temat przynależności poszczególnych pikseli (wokseli) w obrazie. W ostatnich latach nastąpił również rozwój tzw. „miękkich” technik segmentacji (*soft segmentation*), opartych o analizę statystyczną, w których jest wyznaczana wartość prawdopodobieństwa przynależności pikseli/wokseli do poszczególnych struktur. W dalszej części artykułu nazwa wokseli będzie używana również w odniesieniu do pikseli.

Segmentacja jest operacją niezwykle ważną w przetwarzaniu i analizie obrazów, gdyż pozwala na wizualizację interesujących nas obiektów (organów), umożliwiając jednocześnie eliminację elementów niepożądanych, często zaciemniających obraz. Dodatkowo wyniki segmentacji można wykorzystać w dalszej analizie na przykład w systemach do wykrywania zmian chorobowych. Najczęściej używane algorytmy można podzielić na 4 główne grupy.

**Pierwsza grupa** zawiera metody bazujące na wartościach intensywności wokseli. Zwykle algorytmy te nie wykorzystują

informacji o przestrzennych właściwościach wokseli. Najprostszą metodą segmentacji jest progowanie (*thresholding*). Wymaga ono jedynie zdefiniowania wartości progu, poniżej której woksle będą zakwalifikowane jako tło, a powyżej – jako obiekt, lub odwrotnie. Podejście to posiada wiele wad. Między innymi nie wykorzystuje innych informacji o obrazie oprócz wartości intensywności wokseli. Nawet pobieżna analiza typowych obrazów wskazuje, iż w większości przypadków informacja tylko o intensywności jest niewystarczająca. Bardziej złożone metody wykorzystują dodatkowo informację o krawędziach, korzystając przykładowo z gradientu. Tak jest w przypadku detektora krawędzi Canny'ego, zaproponowanego w [8], oraz metody wododziałowej (*watershed*) [9].

**Drugą grupę** stanowią algorytmy wykorzystujące informacje o wartościach intensywności z uwzględnieniem lokalnego podobieństwa otaczających wokseli (*region based segmentation*). Algorytm rozrostu obszaru (*region growing*) oraz rozmytego „sąsiedztwa” (*fuzzy connectedness*) są typowymi przedstawicielami tej grupy. Segmentacja jest inicjowana od wybranych punktów obrazu zwanych ziarnami. Obszar ulega rozrostowi o kolejny wksel jeżeli sąsiedni punkt spełnia warunek przynależności. W najprostszym przypadku warunek sprowadza się do kontroli sąsiednich wokseli pod kątem posiadania zbliżonych wartości intensywności:

$$|I(X_i) - \mu| < T \quad (1)$$

gdzie  $I(X_i)$  – wartość intensywności woksela,  $T$  – próg,  $\mu$  – wartość średnia jasności obszaru. W rzeczywistych systemach wykorzystujących tą metodę warunek przynależności musi być zwykle bardziej złożony w celu uzyskania zadawalających wyników.

**Trzecią grupę** tworzą metody bazujące na modelach. Algorytmy segmentują obrazy startując od przyjętego modelu, który jest modyfikowany w kolejnych iteracjach uwzględniając właściwości wokseli, występujących w obrazach. Modyfikacje modeli zazwyczaj są ograniczane z wykorzystaniem wiedzy apriori. Najczęściej stosowane metody z tej grupy to modele deformowane (*snakes*) [10], metoda poziomic (*level sets*), zaproponowana w [11], oraz inne parametryczne metody, wykorzystujące na przykład transformację Hougha [12]. Metoda poziomic [13, 14] pozwala na śledzenie hiperpowierzchni ewoluującej w czasie (w kolejnych iteracjach) pod wpływem pola zdefiniowanego w jej punktach. Dzięki reprezentacji hiperpowierzchni jako poziomic funkcji skalarnej  $\Phi(t, X)$ , zdefiniowanej we wszystkich punktach powierzchni (*implicit function*), nie ma konieczności parametryzowania tej powierzchni. Kontur  $C$  jest reprezentowany przez poziomicę zerową funkcji  $\Phi(t, X)$ . Zasadnicze równanie metody opisujące zmianę funkcji  $\Phi(t, X)$  w czasie  $t$  ma postać:

$$\frac{\partial \Phi(t, X)}{\partial t} + \mathbf{F} \cdot |\nabla \Phi(t, X)| = 0 \quad (2)$$

Ostatnią, **czwartą grupę** stanowią algorytmy hybrydowe łączące metody z wyżej wymienionych grup.

### 3. Dopasowywanie obrazów

Dopasowywanie obrazów (image registration) jest jednym z podstawowych zadań przetwarzania obrazów medycznych. Zadanie to można określić jako operację dopasowywania dwóch lub większej liczby obrazów podobnych do siebie w sensie określonego kryterium. Kryterium podobieństwa może być zdefiniowane w różny sposób, najczęściej jest to suma kwadratów różnic (SSD, sum of square of the difference), współczynnik korelacji (CC, correlation coefficient) lub informacja wzajemna (MI, mutual information). Obrazy mogą być pozyskiwane w różnych chwilach, z różnych punktów widzenia lub przy użyciu różnych typów czujników.

Intensywny rozwój metod dopasowywania obrazów przypada na okres ostatnich 20 lat. Globalne metody używające transfor-

macji afinicznej zostały już bardzo dokładnie zbadane jednakże algorytmy wyznaczające lokalne deformacje są ciągle w centrum zainteresowania wielu naukowców, zwłaszcza w zastosowaniach biomedycznych [15, 16].

Metody dopasowywania można podzielić na dwie zasadnicze grupy, które bazują na wartościach intensywności wokseli lub na odpowiadających sobie punktach charakterystycznych dwóch obrazów. Przedstawicielem grupy wykorzystującej intensywność wokseli jest algorytm Demon [17, 18]. W metodzie tej wektor sił dla każdego woksela w obrazie źródłowym (source image) dopasowuje wksel w obrazie docelowym (target image). Wyznaczane pole sił bazuje na równaniu przepływu optycznego (optical flow) z renormalizacją w celu uniknięcia niestabilności równania dla małych wartości gradientu w obrazie. Innym przykładem jest technika Free Form Deformation (FFD). Transformacja w tej metodzie jest wyznaczana na podstawie ekstremum funkcji podobieństwa, definiowanej w sąsiedztwie punktów kontrolnych siatki, które nie są związane z żadnymi charakterystycznymi punktami obrazu. W kolejnym kroku deformacje są wyliczane z pola przemieszczeń siatki punktów kontrolnych przy wykorzystaniu jednej z gładkich metod interpolacji.

Rueckert et al. [19] zaproponowali wyznaczanie wartości parametrów transformacji afinicznej i wykorzystanie ich do uwzględnienia globalnego przemieszczenia obrazów. Natomiast lokalne deformacje są wyliczane w tym podejściu przy użyciu metody B-spline. Końcowe pole deformacji jest wyliczane poprzez minimalizację funkcji kosztów, która zawiera kombinację „gładkości” transformacji oraz miary podobieństwa obrazów. Jako miary podobieństwa autorzy użyli kryteriów SSD oraz CC. Charakter zaproponowanych miar ogranicza zastosowanie metody praktycznie tylko do obrazów monomodalnych. W zastosowaniach do obrazów multimodalnych zwykle stosuje się miarę opartą o informację wzajemną [19].

Szeroki przegląd metod dopasowywania obrazów można znaleźć w [4].


### 4. Diagnostyka strun głosowych

Obecnie w diagnozowaniu stanu strun głosowych, ich zmian chorobowych oraz zaburzeń mowy coraz częściej stosuje się endoskopowe zapisy wideo (*high-speed videoendoscopy* HSV) [20]. Środowisko medyczne oczekuje stworzenia automatycznej metody wspierającej proces diagnostyczno-decyzyjny [21]. Segmentacja stanowi niezwykle ważny i konieczny etap w analizie sekwencji obrazów pochodzących z HSV. Na rysunku 1 przedstawiono przykładowe wyniki segmentacji obrazu strun głosowych, przeprowadzonej z użyciem metody rozrostu obszaru oraz metody poziomic [22], zmodyfikowanej i zaadaptowanej do potrzeb systemu analizy HSV [6].


Jak można zaobserwować klasyczna metoda rozrostu obszarów (rys 1e) nie daje poprawnych rezultatów w sytuacji gdy oświetlenie sceny powoduje powstanie ciemniejszych miejsc w anatomicznych zagłębieniach. Sytuacja taka jest konsekwencją cech charakterystycznych tej metody. W prezentowanych wynikach algorytm wykorzystuje warunek opierający się na parametrach statystycznych obszaru takich jak wartość średnia i odchylenie standardowe. W celu poprawy działania algorytmu należałoby wprowadzić bardziej złożony warunek określający wartość progu uwzględniający charakterystykę analizowanych obrazów. Jak możemy zobaczyć na rysunkach 1c i 1f metoda poziomic spisuje się znacznie lepiej. Należy zwrócić uwagę, iż w wyżej wymienionej metodzie zaimplementowano mechanizm niwelujący wpływ rozbłysków na obrazach [6].

Zastosowanie algorytmu wyznaczającego deformacje pomiędzy dwoma obrazami w połączeniu z segmentacją pozwala wyznaczyć wektory przemieszczenia dla każdego punktu konturu. Podejście takie umożliwia analizę ruchu konturów strun głosowych w czasie. Uzyskujemy pełną informację o kierunku, zwrocie i wartości przemieszczenia każdego piksela. Wstępne badania [6] pokazały dużą przydatność metody do analizy zaburzeń ruchu jednej lub

obu strun głosowych. Na rysunku 2 przedstawiono wynik działania algorytmu B-Spline FFD [19], zaimplementowanego przy wykorzystaniu biblioteki ITK [23]. Rysunek 2d przedstawia rezultat zastosowania wynikowego pola deformacji do obrazu źródłowego. Jak można zaobserwować wyznaczone pole bardzo dobrze modeluje ruch strun głosowych. Potwierdzeniem tego jest rysunek 2c przedstawiający moduł różnicy wartości intensywności pomiędzy obrazem docelowym i po deformacji.

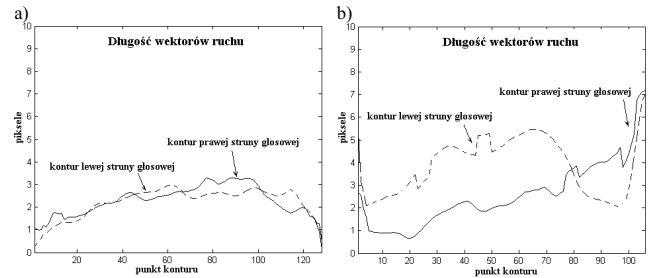


Rys. 1. Przykładowe wyniki segmentacji strun głosowych; a), d) Obraz wejściowy; b), e) Białe obszar w centrum – wynik działania algorytmu rozrostu obszaru; c), f) Białe obszar w centrum – wynik działania algorytmu poziomic [6]  
Fig. 1. Example of vocal folds segmentation; a), d) Input image; b), e) White area in the centre – result of Region Growing segmentation; c), f) White area in the centre – result of Level Set segmentation [6]



Rys. 2. Przykład dopasowania obrazów strun głosowych pochodzących z HSV przy wykorzystaniu metody B-Spline FFD [22]; a) Obraz źródłowy; b) Obraz docelowy c) Moduł różnicy obrazu docelowego oraz źródłowego po zastosowaniu wyznaczonego pola deformacji; d) Obraz źródłowy po zastosowaniu wyznaczonego pola deformacji  
Fig. 2. Example of vocal folds image registration based on B-Spline FFD [22]; a) Source image; b) Target image; c) Absolute difference between target and warped image; d) Warped image

Na rysunku 3 przedstawiono przykładowe, wyznaczone wykresy, obrazujące długości wektorów przemieszczenia dla poszczególnych punktów konturów w przypadku zdrowych strun głosowych (rys 3a) oraz dla strun po usunięciu zmian nowotworowych (rys. 3b). Wyraźnie widać podobieństwo krzywych dla lewej i prawej struny w przypadku osoby zdrowej oraz nieregularność i różnice w wektorach przemieszczenia dla osoby chorej.



Rys. 3. Długość wektorów ruchu dla poszczególnych punktów konturu; a) Osoba zdrowa; b) Pacjent po laserowym usunięciu nowotworu  
Fig. 3. Length of displacement vectors for contour points; a) Healthy vocal folds; b) Vocal folds after laser treatment

W celu oceny ilościowej jakości segmentacji porównano otrzymane wyniki z manualnie wyodrębnioną przestrzenią między strunami głosowymi. W przypadku przedstawionym na rysunkach 1a-1c poprawna klasyfikacja pikseli została przeprowadzona w 94.80 % przez metodę poziomic oraz w 90.95 % przez metodę rozrostu obszarów, natomiast w przypadku przedstawionym na rysunkach 1d-1f otrzymano 93.40 % dla metody poziomic oraz 64.92 % dla metody rozrostu obszarów (w odniesieniu do wyniku uzyskanego podczas manualnej segmentacji). Jako błędną klasyfikację uznano sytuację gdy w wyniku segmentacji manualnej piksel został zakwalifikowany jako obszar pomiędzy strunami głosowymi a algorytm automatyczny takiego piksel nie zakwalifikował oraz w sytuacji odwrotnej czyli kiedy piksel nie był sklasyfikowany, a algorytm automatyczny ten piksel zakwalifikował.


## 5. Radioterapia zmian rakowych

Algorytmy segmentacji i dopasowywania obrazów medycznych 3D stosuje się także podczas zabiegów radioterapeutycznych. Precyzyjne skierowanie wiązki napromieniowującej na zmianę nowotworową jest procesem niezwykle ważnym: powinno się maksymalnie napromieniować guza przy jednoczesnej minimalizacji wpływu wiązki na zdrowe struktury anatomiczne. Podczas radioterapii kluczowym zadaniem jest uwzględnienie pozycji pacjenta oraz wewnętrznych przemieszczeń jego organów.

Na około 2 tygodnie przed zabiegiem przeprowadza się dokładne, wysokoenergetyczne, klasyczne badanie tomograficzne RTPCT (*Radiation Therapy Planning CT*) pacjenta, na podstawie którego projektuje się maski dla procesu radioterapii. Natomiast jeden dzień przed zabiegiem lub w trakcie wykonuje się zgrubne, niskoenergetyczne badanie tomograficzne CBCT (*Cone Beam CT*), którego celem jest stwierdzenie zmian w położeniu i wielkości organów lub kontrola położenia pacjenta. Potem dokonuje się segmentacji organów w obu zapisach i dopasowuje się je do siebie. Parametry dopasowania wykorzystywane są następnie do modyfikacji masek używanych do naświetlania.

Przy napromieniowaniu zmiany nowotworowej w prostaty ruchy wewnętrzne gruczołu krokowego powodują, iż tradycyjne metody dopasowywania bazujące na strukturach kostnych (*affine registration*) są niewystarczające. Konieczne jest wyznaczenie lokalnych deformacji organów [24]. Również w przypadku nowotworu zlokalizowanego w okolicach szyi [25] możemy zaobserwować znaczne deformacje w strukturze guza w kolejnych etapach radioterapii. Na rysunku 4 przedstawiono przykładowe wyniki dopasowywania obrazów w tym ostatnim przypadku, wykonywanego z zastosowaniem algorytmów *Demon* i *B-Spline FFD*

(przeprowadzone badania szczegółowo opisano w [7]). Należy zwrócić uwagę na duże różnice obrazów z rysunków 4a i 4b.



Rys. 4. Przykład dopasowywania obrazów pochodzących z tomografii komputerowej RTPCT i CBCT; a) Obraz źródłowy RTPCT; b) Obraz docelowy CBCT; c) Różnica pomiędzy obrazem źródłowym i docelowym; *Demon*: d) Graficzne przedstawienie wynikowej transformacji; e) Obraz źródłowy po transformacji; f) Różnica pomiędzy b) i e); *B-Spline FFD*: g) Graficzne przedstawienie wynikowej transformacji; h) Obraz źródłowy po transformacji; i) Różnica pomiędzy b) i h)

Fig. 4. Example of image registration for images coming from RTPCT and CBCT [7]; a) Source RTPCT image; b) Target CBCT Image; c) Difference between b) and a); *Demon*: d) Graphical representation of displacement field; e) Warped image; f) Difference between b) and e); *B-spline FFD*: g) Graphical representation of displacement field; h) Warped image; i) Difference between b) and h);

## 6. Podsumowanie

W artykule przedstawiono podstawy segmentacji i dopasowywania do siebie obrazów medycznych oraz ich znaczenie praktyczne. Z powodu szybko rosnącej dostępności cyfrowych zapisów medycznych, np. endoskopowych i tomograficznych, i ich bardzo prawdopodobnego, szerokiego zastosowania do badań przesiewowych w niedalekiej przyszłości, należy się spodziewać, że wkrótce rola tych metod będzie jeszcze większa.

## 7. Podziękowania

Autorzy bardzo dziękują dr Dimitarowi Deliyskiemu z Voice and Speech Laboratory z University of South Carolina w Columbia (USA) za udostępnienie im nagrań wideo strun głosowych w ramach realizacji projektu NIH „Efficacy of Laryngeal High-Speed Videoendoscopy” oraz prof. Christopherowi Moore'owi z Christie Hospital w Manchesterze (UK) i dr Bogdanowi Matuszewskiemu z Applied Digital Signal and Image Processing Centre z University of Central Lancashire w Preston (UK) za wyrażenie zgody na wykorzystanie w niniejszej pracy wyników badań z publikacji [7], powstałej w ramach realizacji projektu ECSON [26].

## 8. Literatura

- [1] J. Jan: Medical Image Processing, Reconstruction and Restoration: Concepts and Methods. CRC Press, 2005.
- [2] T.S. Yoo (Ed.): Insight into Images: Principles and Practice for Segmentation, Registration and Image Analysis. A.K. Peters Ltd. 2004.
- [3] J.S. Suri, S. Kamaledin Setarehdan, S. Singh (Eds): Advanced Algorithmic Approaches to Medical Image Segmentation. Springer 2002.
- [4] J. Modersitzki: Numerical Methods for Image Registration. Oxford University Press 2004.
- [5] A.A. Goshtasby: 2-D and 3-D Image Registration for Medical, Remote Sensing and Industrial Applications. Wiley-Interscience 2005.
- [6] A. Skalski, T. Zieliński, D.D. Deliyski: Analysis of Vocal Fold Movement in High Speed Videoendoscopy Based on Level Set Segmentation and Image Registration. Zgłoszone na konferencję Medical Image Computing and Computer Assisted Interventions MICCAI, NY 2008.
- [7] J.-K. Shen, B. J. Matuszewski, L. -K. Shark, A. Skalski, T. Zieliński, C. J. Moore: Demons, B-spline FFD, and Spring Mass System Deformable Image Registration – A Critical Evaluation. IEEE Mediviz 08 Conference, London, UK, 2008 – w druku.
- [8] J. Canny: A Computational Approach To Edge Detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 8 no. 6, pp. 679-714, 1986.
- [9] L. Vincent, P. Soille: Watersheds in Digital Spaces: An Efficient Algorithm Based on Immersion Simulations. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 13, no. 6, 1991
- [10] C. Xu, J. L. Prince: Snakes, Shapes, and Gradient Vector Flow. Transactions on Image Processing, vol. 7 no. 3, pp. 359-369, March 1998.
- [11] S. Osher, J. Sethian: Fronts propagating with curvature-dependent speed: Algorithms based on the Hamilton-Jacobi formulation. Journal of Computational Physics, vol. 79 pp. 12-49, 1988.
- [12] J. Illingworth, J. Kittler: A survey of the Hough transform. CVGIP, vol. 44, no. 1, pp. 87-116, 1988.
- [13] J. A. Sethian: Level Set Methods and Fast Marching Methods, Cambridge University Press, 2nd edition, 1999.
- [14] S. Osher, N. Paragios (Eds.): Geometric Level Set Methods in Imaging, Vision, and Graphics. Springer, 2006.
- [15] W.R. Crum, T. Hartkens and D.L.G. Hill: Non-rigid Image Registration: Theory and Practice. The British Journal of Radiology, vol. 77, pp. 140-143, 2004.
- [16] D.J. Hawkes, D. Barratt, J.M. Blackall and et. al.: Tissue Deformation and Shape Models in Image-guided Interventions: A Discussion Paper. Medical Image Analysis, Vol. 9, pp. 163-175, 2005.
- [17] J.-P. Thirion: Image matching as a diffusion process: an analogy with Maxwell's demons. Medical Image Analysis, vol. 2 no. 3, 1998.
- [18] J.-P. Thirion: Fast Non-Rigid Matching of 3D Medical Images. Technical Report No. 2547 INRIA, May 1995.
- [19] D. Rueckert, L. I. Sonoda, C. Hayes, D. L. G. Hill, M.O. Leach, D. J. Hawkes: Nonrigid Registration Using Free-Form Deformations: Application to Breast MR Images. IEEE Transactions on Medical Imaging, vol. 18, no. 8, pp. 712-721, 1999.
- [20] D.D. Deliyski, P.P. Petrushev, H.S. Bonilha, T.T. Gerlach, B. Martin-Harris, R.E. Hillman: Clinical Implementation of Laryngeal High-Speed Videoendoscopy: Challenges and Evolution. Folia Phoniatri Logop. vol. 60, pp. 33-44, 2008.
- [21] J. Lohscheller, H. Toy, F. Rosanowski, U. Eysholdt, M. Dollinger.: Clinically evaluated procedure for the reconstruction of vocal fold vibrations from endoscopic digital high-speed videos. Medical Image Analysis vol. 11, pp. 400-413, Elsevier, 2007.
- [22] C. Li, C. Xu, M. D. Fox: Level Set Evolution Without Reinitialization: A New Variational Formulation. IEEE CVPR, pp. 430-436, 2005.
- [23] www.itk.org
- [24] B. J. Matuszewski, J. K. Shen, L. -K. Shark, C.J. Moore: Estimation of internal body deformation using an elastic registration technique. IEEE 3rd International Conference on Biomedical Visualisation, pp. 15-20, 2006.
- [25] D. Maties, D. R. Haynor, H. Vesselle, T. K. Lewellen, W. Eubank: PET-CT Image Registration in the Chest Using Free-form Deformations, IEEE Transactions on medical imaging, vol. 22, no. 1, 2003.
- [26] Projekt ECSON: Engineering and Computational Science for Oncology Network, web: <http://www.ecson.org>.