

Szybkie, wstępne wyznaczanie płaszczyzny symetrii głowy na podstawie obrazów pochodzących z tomografii komputerowej

Streszczenie. W artykule zaproponowano metodę szybkiego, wstępnego wyznaczania płaszczyzny symetrii mózgu. Przedstawiony algorytm bazuje na rozwiązaniu problemu bezpośredniego, średniokwadratowego dopasowania elipsoidy do rozrzuconej przestrzennie chmury punktów, odwzorowujących anatomiczną budowę czaszki. Może on zostać wykorzystany w metodach obliczeniowych wymagających wstępnej informacji o orientacji głowy pacjenta w przestrzeni i jej płaszczyźnie symetrii.

Abstract. In the paper a method of the fast, initial coarse brain symmetry plane calculation is presented. Proposed algorithm is based on solving the problem of the direct least mean ellipsoid fitting to a scattered data, which maps the skull anatomy. Algorithm can be used in more specialized techniques that require an initial information about patients head orientation and its symmetry plane. **A method of the fast, initial coarse brain symmetry plane calculation**

Słowa kluczowe: płaszczyzna symetrii mózgu, dopasowywanie elipsy orientacja głowy, tomografia mózgu

Keywords: brain symmetry plane, ellipsoid fitting, head orientation, brain tomography

doi:10.12915/pe.2014.05.25

Wstęp

W wielu obszarach zastosowań przetwarzania danych medycznych, odnoszących się do ludzkiego mózgu, ważnym aspektem jest identyfikacja anatomicznego punktu charakterystycznego jakim jest szczelina podłużna mózgu, dzieląca go na dwie półkule. Jej prawidłowa identyfikacja stanowi ważne lub wręcz kluczowe zagadnienie w takich problemach jak segmentacja struktury mózgu, dopasowywanie obrazów mózgowia, czy też detekcja zmian patologicznych (udary i guzy).

Płaszczyzna oddzielająca obie półkule nazywana jest płaszczyzną strzałkową (PS) i praktycznie pokrywa się ze szczeliną podłużną, jeśli w mózgu nie występują anomalie struktury. W ogólnym przypadku, warunek ten może nie być spełniony. Wówczas wyznaczanie PS i szczeliny podłużnej nie jest tożsame. Z racji swoich właściwości anatomicznych PS może bezpośrednio lub pośrednio stanowić punkt startowy dla algorytmów bardziej specjalizowanych, nakierowanych na operowanie na danych konkretnych struktur mózgu i optymalizowanych pod kątem detekcji cech charakterystycznych dla tych struktur. Jednocześnie, przy występowaniu zaburzeń w tych strukturach, ważną kwestią z punktu widzenia poprawnego działania algorytmów docelowych staje się znalezienie odpowiedniego punktu startowego. W takich sytuacjach pomocne może okazać się wykorzystanie właściwości kości mózgowcowej, jako struktury sąsiedniej. Kości te są najczęściej pozbawione znaczących przestrzennych deformacji i są niewrażliwe na anomalie jakie wystąpiły w mózgowiu. Tym samym zapewniają, z określoną dokładnością i przy założeniu braku większych zaburzeń w nich samych, stabilny i wiarygodny punkt startowy obliczeń. Wśród istniejących podejść do wyznaczania PS, na wykorzystaniu kości czaszki (łącznie z innymi strukturami) opierają się algorytmy opisane w publikacjach [1,2]. Można w tym miejscu nadmienić, że w pracy [1] budowa kości stanowi główną składową informacji płynącej z obrazu, a wynik wyznaczania PS jest traktowany jako dokładny i docelowy.

W obszarze przetwarzania danych obrazowych, w rozmaitych zastosowaniach i formach, jest wykorzystywane dopasowywanie elipsoidy do zbioru danych. Przykładowo, deformowanie powierzchni elipsoidy stanowi element algorytmu segmentacji struktury prostaty na obrazach ultrasonograficznych, co opisano w artykule [3]. Z kolei w publikacji [4] elipsa jest wykorzystywana na kłatkach zapisu HSV do analizy drgań strun głosowych. Autorzy artykułu [5] używają estymacji elipsoidy w danych 3-D, w oparciu o algorytm opisany w pracy [8], do segmentacji głowy i

tułowia człowieka w sekwencji obrazów wykonywanych z różnych ujęć. Algorytm [6], z którego wywodzi się [8], opiera się na rozwiązaniu problemu określanego w literaturze jako dopasowanie powierzchni do rozrzuconej przestrzennie chmury punktów. Cechuje się on niską złożonością obliczeniową, ograniczoną do rozkładu na wektory własne oraz niewrażliwością na translację, rotację i skalowanie. Te właściwości sprawiły że doczekał się on kilku wersji rozwojowych przedstawionych w [7-9], na nim bazuje również implementacja [10], którą posłużono się w niniejszej pracy. Algorytmy [6-10] różnią się w podejściu do kwestii ograniczeń, wymuszających elipsoidalny kształt dopasowywanej powierzchni, niezależnie od rozkładu przestrzennego chmury punktów. Punkty te mogą reprezentować dane różnego rodzaju, a w rozważanym przez nas zastosowaniu odzwierciedlają anatomiczną budowę wewnętrznej strony mózgowcowej.

Implementacja

Pierwszym krokiem zaproponowanego algorytmu jest wybranie z danego zbioru (woluminu) danych tomografii komputerowej (TK) lub rezonansu magnetycznego (MR) odpowiednich przekrojów, reprezentujących obszar mózgowcowej, oznaczanych dalej jako S_{prop} . Zabieg ten jest podyktowany możliwością wykorzystania bardziej sferycznej budowy górnej części czaszki, co stanowi istotną zaletę działania zasadniczego elementu przedstawianej metody. Z drugiej strony, dla przekrojów z grupy S_{prop} znacznie prostsze i szybsze staje się prawidłowe wyodrębnienie struktury miękkiej mózgowia, co jest niezbędne w następnych etapach działania algorytmu.

Selekcja odpowiednich przekrojów S_{prop} przeprowadzana jest na dwa sposoby. Pierwszy z nich znajduje zastosowanie w przypadku części woluminów TK zapisanych w standardzie DICOM, u których występuje kilka różnych (zazwyczaj dwie) grubości przekrojów (ang. *slice thickness*). Przekroje reprezentujące część głowy, powyżej linii oczu, mają w takich przypadkach inną (zazwyczaj większą) grubość niż pozostałe i to one właśnie zostają wybrane do dalszego przetwarzania jako zbiór S_{prop} .

Drugi ze sposobów, będący modyfikacją metody przedstawionej w [11], jest bardziej uniwersalny z uwagi na to, iż opiera się na właściwościach obrazu, wynikających z budowy anatomicznej głowy. W przedstawianym algorytmie jest on wykorzystywany w przypadku, gdy dany zbiór przekrojów cechuje się występowaniem przekrojów o więcej niż dwóch różnych grubościach, lub też jeśli wszystkie przekroje mają taką samą grubość. Wówczas, spośród

całego woluminu wyszukiwany jest przekrój charakteryzujący się maksymalną średnią wartością przypisaną do pikseli. Dla danych MR znajduje się on mniej więcej na wysokości łuków brwiowych, dla TK około 20 mm niżej. Wszystkie przekroje znajdujące się powyżej niego przechodzą jako zbiór S_{prop} do dalszego przetwarzania, wraz z informacją o rozkładzie ich grubości.

Następnym krokiem jest wyznaczenie masek struktury mózgowia na przekrojach uprzednio wyznaczonej grupy S_{prop} . W tym celu opracowany został prosty algorytm automatycznej segmentacji kości czaszki bazujący na progowaniu. Wartości progów są wyznaczane w oparciu o histogram wartości danego przekroju lub na podstawie informacji zawartych w opisie DICOM.

Z masek wyznaczonych w powyższy sposób, metodą wykrywania krawędzi Canny'ego [12], są generowane obrysy struktury mózgowia. Na podstawie współrzędnych wokseli tych obrysów, powstaje chmura N punktów, oznaczonych jako $\mathbf{p}_{k=1..N}(x,y,z_{slice})$, których rozkład odzwierciedla wewnętrzną powierzchnię czaszki (rysunek 1). W przypadku, gdy grubość poszczególnych przekrojów ze zbioru S_{prop} nie jest taka sama, wartości współrzędnych punktów \mathbf{p} zostają przeliczone na jedną grubość i opisane jako (x,y,z) . Utworzone ostatecznie w ten sposób punkty \mathbf{p} stanowią dane wejściowe dla właściwego procesu dopasowywania elipsoidy, realizowanego za pomocą algorytmu zaczerpniętego z [10].

Algebraiczną reprezentację parametryczną elipsoidy:

$$(1) \quad F(x, y, z) = ax^2 + by^2 + cz^2 + dx + ex + fxz + gx + hy + iz + j = 0$$

można zapisać w formie wektorowej:

$$(2) \quad F_a(\mathbf{x}) = \mathbf{x}\mathbf{a} = 0$$

gdzie:

$$(3) \quad \mathbf{a} = [a, b, c, d, e, f, g, h, i, j]^T$$

$$(4) \quad \mathbf{x} = \begin{bmatrix} x_k^2, y_k^2, z_k^2, xy_k, xz_k, yz_k, x_k, y_k, z_k, 1 \\ \vdots \\ x_N^2, y_N^2, z_N^2, xy_N, xz_N, yz_N, x_N, y_N, z_N, 1 \end{bmatrix}$$

Przyjmując, zgodnie z [6], $F_a(\mathbf{x}_k)$ jako miarę odległości punktu $\mathbf{x}_k(x,y,z)$ od powierzchni $F_a(\mathbf{x}) = 0$, określaną również jako *odległość algebraiczna* (ang. *algebraic distance*) [8], problem dopasowywania powierzchni do chmury punktów \mathbf{x} może być rozpatrywany jako minimalizacja sumy kwadratów wyrażenia (6):

$$(5) \quad \min_a F_A(\mathbf{a}) = \min_a \sum_{k=1}^N [F(\mathbf{x}_k)]^2 = \min_a \sum_{k=1}^N (\mathbf{x}_k \mathbf{a})^2$$

W ogólnym przypadku, opisanym w [6], algorytm dopasowuje powierzchnię, a wymuszenie by konkretnie była nią elipsoida wiąże się z narzuceniem dodatkowych ograniczeń na wektor \mathbf{a} [8,9]. Ponieważ w zaproponowanej implementacji nie stosowano ograniczeń, elipsoidalność powierzchni otrzymywanej w procesie dopasowania wynika z liczby przestrzennego rozkładu oraz rozrzutu punktów chmury \mathbf{p} . Jednocześnie brak dodatkowych ograniczeń sprowadza problem wyznaczenia minimum funkcji celu (6) do rozwiązania równania (7):

$$(6) \quad \mathbf{a} = (\mathbf{x}^T \mathbf{x})^{-1} \mathbf{x}^T \mathbf{I}_{pn}$$

gdzie: \mathbf{I}_{pn} oznacza wektor jednostkowy o rozmiarze macierzy \mathbf{x}

Punkt centralny elipsoidy, jest wyznaczany analitycznie w oparciu o zerowanie się w tym punkcie gradientu formy kwadratowej:

$$(7) \quad \mathbf{x}_c = - \begin{bmatrix} \mathbf{A}_{(1,1)} & \mathbf{A}_{(1,2)} & \mathbf{A}_{(1,3)} \\ \mathbf{A}_{(2,1)} & \mathbf{A}_{(2,2)} & \mathbf{A}_{(2,3)} \\ \mathbf{A}_{(3,1)} & \mathbf{A}_{(3,2)} & \mathbf{A}_{(3,3)} \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{a}(7) \\ \mathbf{a}(8) \\ \mathbf{a}(9) \end{bmatrix}$$

gdzie: $\mathbf{A}_{<i,j>}$ jest elementem (i -ty wiersz, j -ta kolumna) macierzy kwadratowej opisującej elipsoidę we współrzędnych jednorodnych:

$$(8) \quad \mathbf{A} = \begin{bmatrix} \mathbf{a}(1) & \mathbf{a}(4) & \mathbf{a}(3) & \mathbf{a}(7) \\ \mathbf{a}(4) & \mathbf{a}(2) & \mathbf{a}(6) & \mathbf{a}(8) \\ \mathbf{a}(3) & \mathbf{a}(6) & \mathbf{a}(3) & \mathbf{a}(9) \\ \mathbf{a}(7) & \mathbf{a}(8) & \mathbf{a}(9) & -1 \end{bmatrix}$$

Następnie po translacji do centrum uzyskuje się macierz \mathbf{R} :

$$(9) \quad \mathbf{R} = \mathbf{T}\mathbf{A}\mathbf{T}^{-1}$$

gdzie: \mathbf{T} – macierz translacji we współrzędnych jednorodnych.

Tak uzyskana macierz \mathbf{R} jest poddawana następnie rozkładowi na wektory i wartości własne:


$$(10) \quad [\mathbf{v}, \boldsymbol{\lambda}] = \text{eig} \begin{bmatrix} \mathbf{R}_{<1,3,1,3>} \\ \mathbf{R}_{<4,4>} \end{bmatrix}$$

gdzie: \mathbf{v} – macierz wektorów własnych, $\boldsymbol{\lambda}$ – macierz diagonalna wartości własnych.

Wektory własne \mathbf{v} wyznaczają poszczególne osie symetrii, natomiast ich długość jest związana z wartościami własnymi $\lambda_{i=1,3}$, zależnością:

$$(11) \quad r_i = \frac{1}{\sqrt{\lambda_i}}$$

Ponieważ chmura punktów \mathbf{p} odzwierciedla kształt czaszki w danej reprezentacji (z uwzględnieniem grubości poszczególnych przekrojów), a nie jej kształt rzeczywisty, przy idealnym dopasowaniu do idealnie symetrycznej czaszki najkrótsza z osi elipsoidy należy do płaszczyzny strzałkowej, a dwie pozostałe do płaszczyzny poprzecznej. Na rysunku 1 przedstawiono przykładową chmurę punktów \mathbf{p} , dopasowaną do niej elipsoidę za pomocą proponowanego algorytmu oraz fragment wyznaczonej za jej pomocą PS.



Rys. 1. Elipsoida (niebieski) dopasowana do chmury punktów \mathbf{p} (czerwony).

Walidacja algorytmu

Algorytm został zaimplementowany i testowany przy użyciu pakietu Matlab 2011, na komputerze klasy PC wyposażonym w procesor 2.0 GHz Dual Core i 8GB pamięci RAM.

Jako dane testowe posłużyły trzy serie woluminów przekrojów, dwie w reprezentacji TK i jedna MR. Pierwszą serię stanowi 28 sztucznie wygenerowanych zbiorów TK, z których każdy powstał na podstawie zaczerpniętego z bazy [13], rzeczywistego TK, liczącego 174 przekroje, o rozdzielczości 512 na 512 pikseli. Dla każdego z przekrojów

tego woluminu została ręcznie wyznaczona linia pokrywająca się z PS i dzieląca go na dwie półkule. Następnie pojedyncza półkula została odbita względem PS, tworząc w ten sposób strukturę idealnie symetrycznego mózgowia. Na bazie tak przygotowanego woluminu, wygenerowano serię 6 nowych, z których każdy był obracany za pomocą transformacji afinicznej dookoła obu osi o znane, założone kąty.

Druga seria testowa, utworzona w analogiczny sposób jak seria pierwsza, powstała w oparciu o bazy, syntetyczny wolumin MR zaczerpnięty z bazy [14]. Odzworowuje on pozbawiony zaburzeń mózg zobrazowany w rozdzielczości równej 1 mm wzdłuż wszystkich osi.


W skład trzeciej serii wchodziły rzeczywiste woluminy TK, pochodzące od 6 pacjentów, każdy rozdzielczości 512 na 512 pikseli i łącznej liczbie przekrojów wahającej się od 19 do 27. Ich grubość w każdym z woluminów, zawierała się w przedziałach: od 3 mm do 7 mm dla górnej i od 2.3 mm do 3 mm dla dolnej części głowy.

Jako miarę poprawności wyznaczania PS dla woluminów spreparowanych przyjęto wartości modułów: $|\theta - \theta_R|$, $|\psi - \psi_R|$, oraz $|x_c - x_{cR}|$, gdzie poszczególne symbole oznaczają: θ_R – rzeczywisty kąt obrotu woluminu wokół prostej wyznaczonej przez przecięcie płaszczyzny strzałkowej i czołowej, ψ_R – kąt obrotu woluminu wokół prostej wyznaczonej przez przecięcie płaszczyzny strzałkowej i poprzecznej), x_{cR} – punkt względem którego dokonywano obrotu i translacji woluminu bazowego, θ , ψ , x_c – analogiczne parametry elipsoidy, wyznaczonej przez algorytm. Znane kąty θ_R, ψ_R , oraz współrzędne punktu x_{cR} są uznawane za parametry definiujące rzeczywistą, poszukiwaną płaszczyznę PS.


W ramach testów przebadano wpływ sposobu wybierania przekrojów ze zbioru S_{prop} , a przez to liczbę i rozkład punktów chmury p , na dokładność wyznaczania PS i czas obliczeń. Najlepsze wyniki, zarówno dla MR i TK, uzyskano przy wybieraniu przekrojów z krokiem od 5 mm do 7 mm z warstwy o grubości 30 mm, rozciągającej się od przekroju o maksymalnej średniej wartości pikseli wwyż.

Za miarę dokładności algorytmu przyjęto wartość uzyskiwanego błędu maksymalnego. Założenie to wynika z przewidywanego zastosowania proponowanego algorytmu, polegającego na wyznaczaniu punktu startowego dla bardziej wyspecjalizowanych algorytmów. W takich zastosowaniach najważniejszą kwestią jest minimalizacja ryzyka nieosiągnięcia zbieżności przez algorytm docelowy (specjalizowany), na skutek błędnie wyznaczonego punktu startowego.


Wykresy 2a-2c przedstawiają obciążone największymi błędami wyniki dopasowania PS, uzyskane w ramach testów przeprowadzonych na pierwszej i drugiej serii woluminów. Krzywe różnic $\Delta\theta(\psi, \theta)$, $\Delta\psi(\psi, \theta)$ oraz odległości $\Delta x_c(\psi, \theta)$ (odległość centrum dopasowanej elipsoidy x_c od punktu x_{cR} , względem którego obracano preparowane woluminy) zostały wykreślone dla tych wartości drugich współrzędnych, dla których błędy dopasowania były największe.



Rys. 2a. Maksymalne uzyskane różnice pomiędzy rzeczywistą a wyznaczoną PS w zakresie kąta θ dla serii spreparowanych woluminów TK (linia przerywana) i MR (linia ciągła) w funkcji odchylenia o kąt ψ i θ .




Rys. 2b. Maksymalne uzyskane różnice pomiędzy rzeczywistą a wyznaczoną PS w zakresie kąta ψ dla serii spreparowanych woluminów TK (linia przerywana) i MR (linia ciągła) w funkcji odchylenia o kąt ψ i θ .



Rys. 2c. Maksymalne uzyskane odległości pomiędzy centrum dopasowanej elipsoidy x_c a punktem x_{cR} , względem którego obracano preparowane dla woluminów TK (linia przerywana) i MR (linia ciągła)

Z zestawionych rezultatów wynika, że algorytm jest bardziej wrażliwy na odchylenia w zakresie kąta ψ niż θ . Nie można wskazać wyraźnej tendencji do wzrostu lub zmniejszania się błędu wraz ze wzrostem odchylenia względem ψ lub θ . Dotyczy to wszystkich badanych kombinacji kątów ψ i θ , o jakie były odchyłone woluminy testowe. Nieco mniejszą dokładność algorytm osiąga przy operowaniu na zbiorach w reprezentacji TK (średni błąd dopasowania $\Delta\theta = 1,2^\circ$ i $\Delta\psi = 1,5^\circ$ dla TK oraz $\Delta\theta = 1,1^\circ$ i $\Delta\psi = 1,4^\circ$ dla MR). W trakcie testów, w badanym zakresie odchyżeń woluminu o kąt ψ (od 0° do 18°), nie uwidaczniał się negatywny wpływ tego odchylenia na prawidłowe wyznaczanie zbioru przekrojów S_{prop} , a przez to na dokładność wyznaczania PS.

Przykładowe wyniki wyznaczania PS na tle pojedynczych przekrojów dla spreparowanych, symetrycznych woluminów TK przedstawia rysunek 3.




Rys. 3. Wyznaczona, przykładowa PS na tle pojedynczych przekrojów dla spreparowanych, symetrycznych woluminów TK o odchyleniu: $\theta=0^\circ, \psi=0^\circ$ (lewy), $\theta=15^\circ, \psi=-2^\circ$ (prawy)

Zestawienie wyników otrzymanych przy użyciu opracowanego algorytmu w zakresie średniego czasu oraz maksymalnych błędów wyznaczania PS dla reprezentacji TK i MR zawiera tabela nr 1. Przedstawione rezultaty zostały otrzymane dla dwóch rodzajów ustawień algorytmu, zapewniających: 1) największą dokładność 2) najkrótszy czas wyznaczania PS.

Tabela 1. Zestawienie wyników uzyskanych dla pierwszej i drugiej serii testowej.

Odległość pomiędzy przekrojami: 5 mm			
Rodzaj wol.	$\max \theta - \theta_R [^\circ]$	$\max \psi - \psi_R [^\circ]$	średni czas[s]
TK	1,2	1,5	2,5
MR	0,8	1,5	2,4
Odległość pomiędzy przekrojami: 7 mm			
TK	1,4	1,7	2,1
MR	0,8	1,4	2,1

Ponieważ zbiory woluminów rzeczywistych jakimi dysponowaliśmy, zaczerpnięte z baz [15,16], nie były opatrzone żadnymi informacjami ekspertów o rzeczywistym położeniu PS, walidacja algorytmu polegała na wizualnej ocenie wyników pod kątem symetrii wyznaczanych połówek. W tym celu, po dokonaniu przekształceń afinicznych o kąty θ, ψ i translację Δx_c , na testowych woluminach pozostawiano najbardziej wyróżniające się krawędzie, wyodrębnione za pomocą algorytmu detekcji krawędzi Canny'ego. Każdy z woluminów w takiej postaci został podzielony na dwie części wyznaczone uprzednio PS, względem której odbito następnie część woluminu leżącą po jej lewej stronie. Naniesione na siebie krawędzie obu stron przekroju pojedynczego dla woluminu TK przedstawia rysunek 4.



Rys. 4. Przykładowy wynik wyznaczania PS dla rzeczywistego woluminu TK: przecięcie PS z pojedynczym przekrojem (z lewej) i naniesione na siebie krawędzie z lewej (niebieski) i prawej (czerwony) strony PS dla tego samego przekroju. Kolorem zielonym zaznaczono pokrywające się krawędzie obu stron

Podsumowanie

W artykule przedstawiono algorytm umożliwiający szybkie, wstępne wyznaczenie płaszczyzny strzałkowej mózgu na podstawie danych medycznych typu TK i MR, zapisanych w formacie DICOM.

Podsumowując można powiedzieć, że dokładność algorytmu zależy silnie od rozdzielczości danych, na jakich on operuje. Z kolei czas obliczeń determinują głównie wstępne etapy, na których generowana jest chmura punktów.

Jako pierwszy możliwy kierunek rozwoju opracowanej metody można wskazać, przede wszystkim, dodanie ograniczeń zapewniających, iż dopasowana powierzchnia będzie elipsoidą. Drugim kierunkiem jest dążenie do eliminacji punktów lub grup punktów, które najbardziej odbiegają od średniej odległości algebraicznej od powierzchni dopasowywanej elipsoidy. Jako potencjalne rozwiązania mogące znaleźć zastosowanie w tym przypadku, autorzy wskazują na metody RANSAC [17], oraz rozmaite algorytmy regresji odpornej [18].

Jednak w większości zastosowań przewidzianych dla proponowanego algorytmu, zabiegi mające na celu poprawić jego dokładność w wyznaczaniu PS mogą się okazać nieuzasadnione. Wynika to z faktu, iż docelowe algorytmy bazują na charakterystycznych cechach anatomicznych ich organów zainteresowania, mózgowia lub

poszczególnych jego części, podczas gdy proponowany algorytm opiera się na kształcie wewnętrznej części mózgowc czaszki. Tym samym proponowany algorytm niepotrzebnie wchodziłby w obszar działania specjalizowanego algorytmu docelowego.

Praca została sfinansowana ze środków przyznanych na działalność statutową Katedry Telekomunikacji Akademii Górniczo-Hutniczej, nr umowy 11.11.230.018.

LITERATURA

- [1] Liu, Y., Collins, R., Rothfus, W.E., Robust midsagittal plane extraction from normal and pathological 3-D neuroradiology images, *IEEE Trans. Med. Imaging*, 20, (2001), 173–192
- [2] Ruppert, G.C.S., Teverovskiy, L., Chen-Ping Yu, Falcao, A.X., A new symmetry-based method for mid-sagittal plane extraction in neuroimages, *IEEE Int. Symposium on Biomedical Imaging: From Nano to Macro (2011)*, 285 - 288
- [3] Mahdavi, S., Salcudean, S., 3D Prostate Segmentation based on Ellipsoid Fitting, Image Tapering and Warping, 30th Annual International IEEE EMBS Conference, August 20-24, 2008
- [4] Skalski, A., Zielinski, T., Deliyiski, D., Analysis of vocal folds movement in high speed videoendoscopy based on level set segmentation and image registration, *ICSES '08. International Conference on Signals and Electronic Systems*, (2008), 223-226, 14-17 Sept. 2008
- [5] Grammalidis, N., Strintzis, M., Using 2-D and 3-D Ellipsoid Fitting for Head and Body Segmentation and Head Tracking, *Computer Graphics International*, (2000), *Proceedings*, 221 – 226, 19-24 June 2000
- [6] F.L. Bookstein, Fitting Conic Sections to Scattered Data, *Computer Graphics and Image Processing*, 9 (1979), 36-71,
- [7] P.D. Sampson, Fitting Conic Sections to Very Scattered Data: An Iterative Refinement of the 2stein Algorithm, *Computer Graphics and Image Processing*, 18 (1982), 97-108,
- [8] Fitzgibbon, A. W., Pilu, M and Fischer, R. B.: Direct least squares fitting of ellipses, *Proc. of the 13th International Conference on Pattern Recognition*, (1996), 233–237
- [9] Halir, R., Flusser J.: Numerically stable direct least squares fitting of ellipses; *Proc. of the 6th International Conference in Central Europe on Computer Graphics and Visualization*, (1998), 125–132
- [10] <http://www.mathworks.com/matlabcentral/fileexchange/24693-ellipsoid-fit>, dostęp 28.01.2014
- [11] Hu, Q., Nowiński, W.: A rapid algorithm for robust and automatic extraction of the midsagittal plane of the human cerebrum from neuroimages based on local symmetry and outlier removal. *Neuroimage*, 20 (2003), 2133–2163.
- [12] Canny, J., *A Computational Approach To Edge Detection*, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 8, (1986), 679-714
- [13] <http://www.osirix-viewer.com/datasets/>, dostęp 28.01.2014
- [14] <http://brainweb.bic.mni.mcgill.ca/brainweb/>, dostęp 28.01.2014
- [15] <http://www.mini.pw.edu.pl/~aidmed/udary.html>, dostęp 28.01.2014
- [16] <http://www.cancerimagingarchive.net/>, dostęp 28.01.2014
- [17] M.A. Fischler, R.C. Bolles, Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. *Comm. of the ACM* 24, (1981), 381–393.
- [18] Andersen, R., *Modern Methods for Robust Regression*, *Sage University Paper Series on Quantitative Applications in the Social Sciences*, (2008), 107-132

Autorzy: mgr inż. Artur Kos, AGH Akademia Górniczo-Hutnicza, Katedra Telekomunikacji, Al. Mickiewicza 30, 30-059, Kraków, E-mail: kosar@agh.edu.pl; dr inż. Andrzej Skalski, AGH Akademia Górniczo-Hutnicza, Katedra Metrologii i Elektroniki, Al. Mickiewicza 30, 30-059, Kraków, E-mail: skalski@agh.edu.pl; prof. dr hab. inż. Tomasz Zieliński, AGH Akademia Górniczo-Hutnicza, Katedra Telekomunikacji, Al. Mickiewicza 30, 30-059, Kraków, E-mail: tzielin@agh.edu.pl;