

## Modyfikacja algorytmu aktywnych modeli kształtu eliminująca wpływ anizotropii danych tomograficznych

**Streszczenie.** W artykule zaproponowano modyfikację algorytmu automatycznej segmentacji ASM, uwzględniającą anizotropię danych medycznych w reprezentacjach TK i MR na etapie generowania modelu statycznego. Przedstawiono również nową metodę generowania zbiorów punktów uczących/treningowych, wymaganych przez algorytm ASM, opartą o zmodyfikowany algorytm ICP. Zaproponowaną metodę przetestowano na testowej serii 15 rzeczywistych woluminów TK, osiągając średnią dokładność segmentacji, wyrażoną współczynnikiem Dice'a, na poziomie 0.8014.

**Abstract.** In the paper a modified ASM algorithm, that considers a CT and MRI medical data anisotropy at the stage of statistic shape model generation, is proposed. Additionally, a new, non-rigid ICP algorithm-based method of creating the ASM training data points sets is presented. The proposed approach had been tested on a series of 15 real patients CT volume data, reaching a mean accuracy of the segmentation 0.8014, measured by the Dice coefficient. **A modified ASM algorithm, that considers a CT and MRI medical data anisotropy at the stage of statistic shape model generation**

**Słowa kluczowe:** model statystyczny, segmentacja, radioterapia, ASM, dopasowanie, ICP, chmura punktów

**Keywords:** statistic shape model, segmentation, ASM, registration, ICP, points cloud

### Wstęp

Jednym z najczęściej występujących rodzajów nowotworów wśród męskiej części populacji jest rak prostaty. Przy wyższym stopniu zaawansowania choroby, typową terapią stosowaną w przypadku osób młodszych jest operacja chirurgiczna, zaś w przypadku osób starszych – radioterapia [1]. W procesie planowania tej drugiej, wykonywana jest tomografia komputerowa (TK) obszaru miednicy pacjenta. Ponieważ wszystkie obrisy są wykonywane przekrój po przekroju, jest to czynność zajmująca najwięcej czasu w całym procesie planowania radioterapii. Z tego powodu dąży się do stworzenia algorytmów automatycznej segmentacji, mających za zadanie automatyczne przyporządkowywanie pikseli (lub wokseli) na danych z tomografii komputerowej (CT) lub z obrazowania rezonansu magnetycznego (MRI) do konkretnych struktur anatomicznych ciała człowieka. Nie jest to zadanie łatwe, ponieważ przy niskim stosunku sygnału do szumu i słabym kontraście brak jest wyraźnego przejścia pomiędzy poszczególnymi organami [2]. Prawidłowe zlokalizowanie krawędzi danego organu staje się wówczas niemożliwe przy wykorzystaniu informacji płynących tylko z samego obrazu. W tym celu opracowuje się algorytmy automatycznej segmentacji, wykorzystujące dodatkową wiedzę *a priori*, zawartą w np. w formie statystycznych modeli medycznych i atlasów. Jednym z takich algorytmów jest algorytm Aktywnego Modelu Kształtu (ang. *Active Shape Model*, ASM) [3,4], wykorzystywany w niniejszej pracy, który znalazł już wiele zastosowań w przetwarzaniu trójwymiarowych obrazów medycznych [5,6]. Wiedza *a priori*, na podstawie której algorytm ten generuje statyczny model danego obiektu, ekstrahowana jest z obrazów reprezentujących ten sam lub zbliżony kształtem obiekt (np. twarz człowieka).

Model ASM zawiera:

- informacje o położeniu oraz kształcie danego obiektu, odwzorowane za pomocą zbioru (chmury) przyległych do niego punktów (*punkty modelu*, *punkty charakterystyczne*, *landmarks*),

- lokalny rozkład wartości wokół tych punktów,
- zakres wariacji wymienionych cech.

Modyfikacją algorytmu ASM jest Aktywny Model Wyglądu (ang. *Active Appearance Model*, AAM) [5,6], który dodatkowo uwzględnia również informację o teksturze rozpiętej na zbiorze *punktów modelu*. Jednak pomimo tego, że AAM w większym stopniu wykorzystuje informację płynącą z obrazu, to wspomniane wcześniej właściwości obrazów TK i MR powodują, że przy segmentacji organów w tych reprezentacjach lepiej sprawdza się model ASM [7].

Do wygenerowania modelu ASM niezbędny jest zbiór  $N$  danych treningowych, spełniających następujące wymagania:

- w każdej z  $N$  chmur punktów musi znajdować się  $M$  odpowiadających sobie punktów,
- każdy z  $M$  punktów musi ściśle przylegać do krawędzi znajdującego się na  $N$ -tym obrazie obiektu, którego statystyczny model jest tworzony,
- dodatkowym wymogiem stosowanej w tej pracy implementacji [8] jest wygenerowanie powierzchni (siatek) rozpiętych na  $N$  punktach każdej chmury, tworzących reprezentację wierzchołki-wielokąty (ang. *vertices-faces*).

Spełnienie powyższych wymagań jest podstawową trudnością, wiążącą się z korzystaniem z modeli ASM/AAM. W poprzednich pracach autorów [7,9] problem ten był rozwiązywany metodą propagacji punktów, zaprezentowaną w publikacjach [10,11]. Wadą tej metody jest duża złożoność obliczeniowa, wymagająca odpowiednich zasobów i rosnąca wraz z ilością dopasowywanych obrazów.

W celu wyeliminowania powyższej wady zaproponowano wykorzystanie metodologii bazującej na iteracyjnej metodzie najbliższych punktów (ang. *Iterative Closest Point* ICP) [12], której przydatność w generowaniu danych uczących dla algorytmu ASM była analizowana w poprzedniej pracy autorów [13].

Schemat ideowy proponowanego podejścia przedstawia rysunek 1. W pierwszym kroku jest generowana chmura punktów na obrazie średnim lub jednym ze zbioru dostępnych danych TK. W ramach niniejszej pracy do generacji chmury wykorzystano algorytm maszerujących sześcianów (ang. *Marching Cubes*).

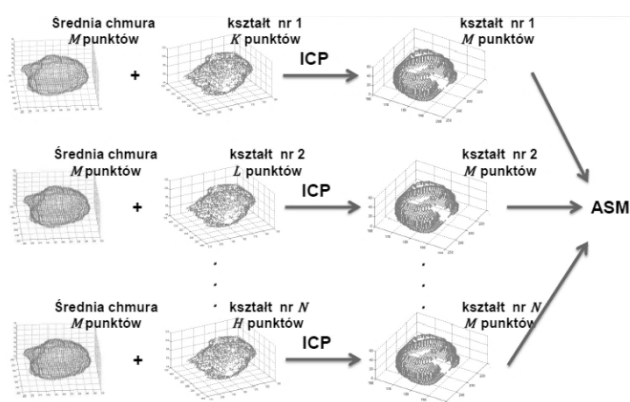
Po wyznaczeniu współrzędnych punktów, leżących na powierzchni struktury zobrazowanej w danych reprezentujących uśredniony model, samo dopasowanie do

obrysów w danych uczących opiera się o wykorzystanie trójstopniowej procedury:

- generacja chmur punktów w danych uczących,
- sztywne dopasowanie z wykorzystaniem metody ICP [12],
- lokalna korekcja położenia punktów z wykorzystaniem metody k-najbliższych sąsiadów (ang. *k-nearest neighbors*) [15].

W celu przeniesienia chmury (siatki) z obrazu uśrednionego na dane, wykorzystywane do budowy modelu w ASM, wyznaczono sztywne dopasowanie, umożliwiające obliczenie wektora translacji oraz współczynnika skalowania. Ze względu na charakter danych (ułożenie pacjentów) nie było konieczności estymacji macierzy rotacji.

Po wyznaczeniu parametrów transformacji przeprowadzana jest korekta lokalnych różnic w rozkładzie przestrzennym z wykorzystaniem algorytmu k-najbliższych sąsiadów [15]. Procedura ta umożliwia propagację punktów z danych uśrednionych na dane uczące z zachowaniem wymaganej zgodności punktów w metodzie ASM.



Rys. 1. Schemat ideowy generowania zbiorów punktów uczących dla algorytmu Active Shape Model. Opis w tekście.

## Implementacja

Na podstawie obrysów, wykonanych przez lekarzy specjalistów, generowanych jest  $N$  chmur, odzwierciedlających prostaty na poszczególnych  $N$  woluminach uczących. Otrzymuje się w ten sposób  $N$  chmur o różnej liczbie nieodpowiadających sobie punktów. Następnie, do tak wygenerowanych chmur zostaje dopasowana jedna, licząca  $M$  punktów, arbitralnie wybrana chmura, zgodnie ze schematem przedstawionym na rysunku 1.

Model ASM konstruowano w sposób następujący. Otrzymane  $M$ -punktowe chmury odwzorowują prostaty na obrazach TK, które w omawianym wypadku cechowały się różnymi wartościami odległości pomiędzy pikselami (ang. *pixel spacing*) oraz różnymi grubościami przekrojów (ang. *slice thickness*). Uwzględnienie tych parametrów jest konieczne, aby nie wprowadzać do modelu fałszywej informacji uczącej o wariacji kształtu obiektu. W poprzednich pracach [7,9] wymóg ten był spełniany drogą interpolacji całych obrazów na regularną siatkę węzłów  $1 \times 1 \times 1$  mm. W proponowanym algorytmie różnice między pikselami są uwzględniane na etapie tworzenia modelu ASM, poprzez przemnożenie każdej z  $N$  chmur punktów przez odpowiednie wartości odległości między pikselami i wartości grubości przekrojów. Z tak zmodyfikowanych chmur, oznaczanych jako  $\mathbf{p}_i$ :

$$(1) \quad \mathbf{p}_{i=1..N} = [\hat{x}_1, \hat{y}_1, \hat{z}_1, \dots, \hat{x}_M, \hat{y}_M, \hat{z}_M]$$

wyznaczany jest średni kształt:

$$(2) \quad \bar{\mathbf{P}} = \frac{1}{N} \sum_{i=1}^N \mathbf{p}_i,$$

a następnie macierz kowariancji:

$$(3) \quad S_b = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{p}_i - \bar{\mathbf{P}})(\mathbf{p}_i - \bar{\mathbf{P}})^T.$$

Metodą analizy głównych składowych (ang. *Principal Component Analysis*, PCA) z macierzy tej są wyznaczane wektory własne:

$$(4) \quad S_b \Phi_{st} = \lambda_i \Phi_{st},$$

$$(5) \quad \Phi_s = [\Phi_{s1}, \Phi_{s2}, \dots, \Phi_{s2M}],$$

za pomocą których można znaleźć taki wektor  $\mathbf{b}_s$ , że dla dowolnego  $\pi$  spełnione jest równanie:

$$(6) \quad \pi = \bar{\mathbf{P}} + \Phi_s \mathbf{b}_s, \quad \mathbf{b}_s = [b_{s1}, b_{s2}, \dots, b_{s2M}]^T$$

Wektory  $\Phi_s$  i  $\mathbf{b}_s$  reprezentują, odpowiednio, główne kierunki średniego kształtu oraz wariację wzdłuż tych kierunków. Ponieważ wektory własne o wyższych indeksach charakteryzują się mniejszymi odchyleniami (mniejszą wariacją), do konstrukcji modelu jest wykorzystywanych tylko  $t$  pierwszych, najistotniejszych wektorów własnych. Pozwala to na zmniejszenie wymiarowości modelu, którego finalną postać opisuje równanie:

$$(7) \quad \pi \approx \bar{\mathbf{P}} + \Phi_{st} \mathbf{b}_{st}$$

Ponieważ większość średnich kształtów mieści się w przedziale  $\pm 3\sigma$ , dlatego znając wektory  $\Phi_{st}$  oraz  $\mathbf{b}_{st}$ , można za ich pomocą wygenerować nowy, syntetyczny kształt  $\pi$ , nie pochodzący ze zbioru testowego. W ten sposób tworzona jest część modelu, wiążąca informacje o kształcie obiektu.

Prostopadle do powierzchni rozpiętej na  $M$  punktach modelu, przez każdy z tych punktów, prowadzony jest wektor (*profil*) próbkujący lokalny rozkład wartości wokseli. Na tym etapie pojawia się konieczność uwzględnienia anizotropii danych, na których operuje algorytm. Ponieważ obraz zapisany jest we współrzędnych będących liczbami naturalnymi, a wektory próbkujące (*profile*) przechodzą pod różnymi kątami przez powiązane z nimi punkty modelu, do precyzyjnego zapisu położenia poszczególnych punktów *profilu* potrzebne są liczby zmiennoprzecinkowe. Z kolei do precyzyjnego określania wartości w tych punktach, stosuje się interpolację. Uwzględniając w siatce węzłów interpolacji grubość przekrojów oraz odległości pomiędzy pikselami obrazu, eliminuje się problem anizotropii danych. Nie zachodzi przy tym konieczność stosowania kosztownej obliczeniowo interpolacji całych obrazów testowych na regularną siatkę  $1 \times 1 \times 1$  mm.

Łącząc informację o znormalizowanym rozkładzie wartości wzdłuż *profilu* z częścią modelu opisującą kształt, otrzymuje się kompletny model ASM.

## Segmentacja

Pierwszą operacją wyodrębniania struktury anatomicznej z danych obrazowych jest wstępne, zgrubne dopasowanie do niej modelu, realizowane poprzez umieszczenie go w pobliżu poszukiwanej struktury, drogą globalnej transformacji  $\mathbf{T}_{\text{global}}$ . Wówczas model we współrzędnych danego obrazu, na którym operuje, opisuje zależność:

$$(8) \quad \Pi = \mathbf{T}_{\text{global}}(\bar{\mathbf{P}} + \Phi_{st} \mathbf{b}_{st})$$

Pierwszym krokiem algorytmu ASM jest lokalna optymalizacja modelu, znajdującego się w pozycji startowej. Następnie są powtarzane iteracyjnie następujące kroki:

1. Prostopadle do powierzchni rozpiętej na punktach modelu, przez każdy z  $M$  punktów, jest prowadzony *profil* próbkujący lokalny rozkład wartości wokseli. W tym

kroku algorytmu pojawia się problem anizotropii danych, który jest eliminowany analogicznie jak na etapie tworzenia modelu.

2. Punkty *profilu* o największym gradencie są kandydatami na nowe pozycje punktów modelu. Następnie, zmieniając parametry transformacji  $T_{global}$ , uaktualniane jest położenie (poza) całego modelu, tak aby otrzymać najlepsze dopasowanie do segmentowanej struktury.
3. Na końcu są obliczane nowe wartości wektora  $b_{st}$ , aby drogą lokalnych zmian uzyskać najlepsze dopasowanie modelu w nowej pozie.

Realizacja trzech wyżej wymienionych kroków sprowadza się do minimalizacji wyrażenia:

$$(9) \quad f(\mathbf{b}, \Pi_c, s, \theta) \approx \|\Pi - T_{global}(\bar{P} + \Phi_{st} \mathbf{b}_{st})\|^2,$$

gdzie  $\Pi_c, s, \theta$  oznaczają skalę, rotację oraz aktualny kształt chmury punktów modelu.

Minimalizacja funkcji (9) jest powtarzana dopóki błąd nie zmniejszy się do założonej wartości, bądź algorytm nie wykona zadanej liczby iteracji. Końcowy wynik dopasowywania modelu do danych jest uznawany za rezultat procesu segmentacji.

### Wyniki dopasowania oraz walidacja

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

Baza danych obrazowych jaką dysponowali autorzy składała się z 27 rzeczywistych woluminów TK o rozdzielczości 512 na 512 pikseli i łącznej liczbie przekrojów wahającej się od 63 do 116. Grubość przekrojów w każdym z woluminów była równa 5mm, natomiast rozdzielczość przestrzenna w płaszczyźnie poprzecznej wahała się w zakresie od 0.9678 do 1.225 mm. Każdy z woluminów pochodził od innego pacjenta i był uzupełniony o obrysy struktur obszaru miednicy (pęcherza, prostaty, głów kości udowych, odbytnicy), wykonane przez lekarzy radiologów. Do utworzenia modelu ASM użyto 12 woluminów wybranych z bazy, natomiast 15 pozostałych służyło za obrazy testowe do walidacji algorytmu.

Jako poprawny kształt odniesienia wykorzystano maski prostaty, wygenerowane na podstawie obrysów wykonanych przez lekarzy. Przyjętą miarą dokładności segmentacji była wartość współczynnika Dice'a:

$$(10) \quad s = \frac{2|A \cap B|}{|A| + |B|},$$

gdzie: A - oznacza maskę binarną, wygenerowaną jako wynik końcowy segmentacji (dopasowaną), B - oznacza maskę binarną prawdziwej struktury,


Rysunki 2 i 3 przedstawiają jakościowe wyniki dopasowania powierzchni prostaty średniego modelu do przykładowych danych testowych. Zestawienie uzyskanych wyników w zakresie dokładności segmentacji, wyrażonej współczynnikiem Dice'a, zawiera tabela nr 1.

Z przeprowadzonych testów wynika, że na dokładność algorytmu mają wpływ trzy czynniki.

Pierwszym z nich jest poprawność generowania modelu ASM, przez którą rozumie się zachowanie odpowiedności punktów z  $M$  zbiorów uczących oraz przyleganie tych punktów do krawędzi struktur, których kształty mają odzwierciedlać. Za spełnienie tych wymogów odpowiada algorytm ICP i od dokładności jego wyników zależy jakość modelu ASM.

Drugim czynnikiem jest ilość informacji płynąca z samego obrazu, pozwalająca odróżnić struktury poszukiwane od sąsiadujących. Na informację tę składa się jakość danych obrazowych oraz dystynktywność samej struktury. Na wszystkich obrazach dostępnej bazy woluminów TK, zarówno tych wchodzących w skład zbioru uczącego jak i tych używanych do testów, prostata słabo wyróżnia się rozkładem wartości. Z tego powodu główną rolę w tworzonych modelach odgrywała informacja o kształcie, płynąca z wiedzy *a priori*. Największy błąd występował w przypadku struktur testowych, których kształt najbardziej odbiegał od zapisanego w modelu ASM kształtu średniego lub przekraczał jego ustaloną dopuszczalną zmienność.


Trzeci czynnik stanowi jakość danych (rozumiana jako liczba przekrojów obrazu, na których pojawia się poszukiwana struktura), stosunek sygnału do szumu oraz wszelkie występujące w obrazie artefakty. Niska jakość negatywnie wpływa zarówno na sam model jak i na późniejszą segmentację z jego użyciem.



Rys. 2. Przykładowe wyniki segmentacji otrzymane za pomocą algorytmu ASM. Jasne fragmenty rysunku przedstawiają miejsca niezgodności dopasowania modelu ASM do obrysu wykonanego przez lekarza. Wszystkie osie są wyskalowane w wokselach.

Tabela 1. Zestawienie uzyskanych wyników segmentacji

Nr woluminu testowego	Wartość współczynnika Dice'a $\delta$
1	0.7458
2	0.7966
3	0.8421
4	0.7806
5	0.8230
6	0.7881
7	0.8094
8	0.8223
9	0.8838
10	0.8083
11	0.8071
12	0.8606
13	0.8014
14	0.7301
15	0.7223
wartość średnia $\delta$	0.8014
odchylenie standardowe $\sigma$	0.0448



Rys. 3. Wyniki segmentacji na przykładzie pojedynczego przekroju dwóch różnych woluminów testowych. Białe kontury – obrysy wykonane przez lekarza, czarne kontury – wynik segmentacji.

### Podsumowanie

W artykule zaprezentowano zmodyfikowany sposób generowania danych treningowych dla algorytmu automatycznej segmentacji ASM, wykorzystujący metodę ICP, jak również usprawnienie samego algorytmu.

Z przeprowadzonych testów wynika, że dokładność algorytmu zależy od jakości danych na jakich operuje, dystynktywności samego segmentowanego obiektu oraz stopnia poprawności modelu ASM w zakresie ujęcia zmienności kształtu i cech segmentowanego obiektu.

Planowanym kierunkiem rozwoju przedstawionego algorytmu jest budowa modelu połączonych kilku struktur, mieszczących się w obszarze miednicy. W zamierzeniu ma to poprawić jakość segmentacji poprzez zwiększenie w modelu udziału informacji pochodzących od struktur bardziej dystynktywnych, takich jak główki kości udowych.

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

*W implementacji całościowego rozwiązania wykorzystano kody źródłowe umieszczone w [8,15].*

*W pracy wykorzystano dane pozyskane w ramach projektu finansowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego / Narodowe Centrum Nauki, projekt numer NN518 497739.*

*Praca została wykonana z wykorzystaniem Infrastruktury PL-Grid.*

*Autorzy chcieliby podziękować dr Piotrowi Kędzierawskiemu ze Świętokrzyskiego Centrum Onkologii za wykonanie obrysów struktur anatomicznych w danych medycznych*

### LITERATURA

- [1] Horwich, VA., Parker, C., Kataja, V.: Prostate cancer: ESMO Clinical Recommendations for diagnosis, treatment and follow-up, *Annals of Oncology* 20 (Supplement4): iv76-iv78, (2009)
- [2] Skalski A., et al., "Computed Tomography - based radiotherapy planning on the example of prostate cancer: Application of Level-Set segmentation method guided by atlas-type

- knowledge," *ACM Digital Library*, ISBN 978-1-4503-0913-4/11/10, (2011)
- [3] Cootes T.F., et al., A trainable method of parametric shape description, *Image Vision Comput.* 10(5), pp. 289-294, 1992
- [4] Cootes T.F., Taylor C.J., Statistical models of appearance for computer vision, *Technical Report*, University of Manchester, 2004.
- [5] Gao X., et al., A review of Active Appearance Models, *IEEE Trans. on Systems, Man, and Cybernetics - Part C: Applications and reviews.* 40 (2), pp. 145-158, 2010
- [6] Heimann T., Meinzer H.P., Statistical shape models for 3D medical image segmentation: A review, *Medical Image Analysis*, 13, pp. 543-563, 2009
- [7] Skalski A., Lagwa J., Zielinski T., Kędzierawski P., Kuszewski T., Automatic prostate segmentation in MR images based on 3D active contours with shape constraints, *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, 26-28 Sept. (2013), 246-249
- [8] Kroon D.J.: Active Shape Model and Active Appearance Model <http://www.mathworks.com/matlabcentral/fileexchange/26706-active-shape-model-asm-and-active-appearance-model-aam/>, dostęp 22.02.2015
- [9] Kos A., Skalski A., Zieliński T, Using ASM in CT data segmentation for prostate radiotherapy. *Lecture Notes in Computer Science, Springer Berlin Heidelberg, LNCS 7594*, (2012), 610-617
- [10] Frangi, A.F., et al.: Automatic ASM Construction via Atlas-Based Landmarking and Volumetric Elastic Registration. In: M.F. Insana and R.M. Leahy (Eds.): IPMI 2001, LNCS 2082, 78-91 (2001)
- [11] Frangi, A.F., Rueckert, D., Schnabel, J.A., Niessen, W.J.: Automatic construction of multiple-object three-dimensional statistical shape models: application to cardiac modeling. *IEEE Trans. Med. Imaging*, 21(9), 1151-1166 (2002)
- [12] Besl P.J., McKay N.D., A method for registration of 3-D shapes, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 14(2), (1992), 239-256
- [13] Skalski A., Socha, M. Dopasowanie chmur punktów do powierzchni dla potrzeb przetwarzania i analizy obrazów medycznych oraz systemów wizyjnych. *Przegląd Elektrotechniczny*, 90(5) (2014), 160-163
- [14] Friedman J.H., Bentely J., Finkel R. A., An Algorithm for Finding Best Matches in Logarithmic Expected Time, *ACM Transactions on Mathematical Software* 3, (1977), 209.
- [15] <http://www.mathworks.com/matlabcentral/fileexchange/41396-nonrigidicp/>, dostęp 26.02.2015

**Autorzy:** mgr inż. Artur Kos, AGH Akademia Górniczo-Hutnicza, Katedra Telekomunikacji, Al. Mickiewicza 30, 30-059, Kraków, E-mail: [kosar@agh.edu.pl](mailto: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](mailto: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](mailto:tzielin@agh.edu.pl);