

Marcin WIŚNIEWSKI, Tomasz ZIELIŃSKIAKADEMIA GÓRNICZO-HUTNICZA W KRAKOWIE,
Al. Mickiewicza 30, 30-059 Kraków**Analiza i modelowanie sygnałów osłuchu płuc****Mgr inż. Marcin WIŚNIEWSKI**

Absolwent kierunku Elektrotechnika Wydziału EAIiE Akademii Górniczo-Hutniczej. Tytuł magistra inżyniera otrzymał w 2009 roku. Obecnie doktorant w Katedrze Telekomunikacji AGH. Zajmuje się cyfrowym przetwarzaniem sygnałów biomedycznych.



e-mail: wisniewski@kt.agh.edu.pl

Prof. dr hab. inż. Tomasz ZIELIŃSKI

Absolwent kierunku Elektronika Wydziału EAIiE Akademii Górniczo-Hutniczej. Pracował w Katedrze Metrologii AGH od 1982 do 2006 roku, a od 2006 roku do chwili obecnej jest zatrudniony w Katedrze Telekomunikacji AGH. Zajmuje się algorytmami cyfrowego przetwarzania sygnałów w zastosowaniach pomiarowych, telekomunikacyjnych i biomedycznych, w szczególności metodami analizy czasowo-częstotliwościowej sygnałów.



e-mail: tzielin@agh.edu.pl

Streszczenie

Artykuł dotyczy problematyki modelowania sygnałów pozyskanych podczas osłuchu płuc. Oprócz modelu normalnego oddechu zdrowego pacjenta, przedstawiono opracowany model świstów astmatycznych, jednego z najpopularniejszych objawów zaburzenia oddychania. Biorąc pod uwagę fakt, że świsty osadzone są na tle normalnego oddechu, w artykule przedstawiono metodykę wyliczania poprawnego stosunku sygnałów tonalnych świstu do sygnału normalnego oddechu. Przeprowadzono również analizę przedziałów częstotliwości tonów występujących w świstach rzeczywistych.

Słowa kluczowe: Osłuch płuc, modelowanie, oddech, świsty.

Analysis and modelling of lung sounds**Abstract**

The paper addresses a problem of modelling lung sounds. Apart from typical human breath of a healthy person, the model of asthma wheeze, one of the most often breathing disorders, is presented. Since wheezes are embedded in normal human breath, the methodology of signal-to noise (wheeze-to-breath) ratio calculation is discussed in the paper. The frequency range of wheezes present in real recordings is investigated in this work, too. Section 2 specifies signals that are obtained during the chest auscultation. In Section 3 feature identification and signal modelling of normal lung sounds are made. In this section the distribution of signal samples and the mean signal spectrum are shown in the figures. Section 4 describes identification of real signal features and modelling of wheezes. This section presents histograms of SNR (*Signal to Noise Ratio* or *Wheeze-to-Breath Ratio*), number of tones in wheezes and tone frequencies for real signals and generated tonalities. The model verification results obtained with use of tonality detection algorithms are given in Section 6. The short conclusions and a list of references are at the end of the paper.

Keywords: chest auscultation, modeling, lung sounds, wheezes.

1. Wstęp

Modelowanie sygnałów jest bardzo ważnym elementem w procesie cyfryzacji diagnostyki medycznej [1]. Pozwala ono na zrozumienie działania mechanizmów generacji sygnałów oraz dokładniejszą ich analizę. Modelowanie sygnałów częściowo rozwiązuje również problem ograniczonej ilości danych, które są bardzo trudne lub wręcz niemożliwe do pozyskania. Modelowanie sygnałów akustycznych pozyskanych z osłuchu płuc nie jest tematem nowym. Już na przełomie lat 80-tych i 90-tych ubiegłego wieku pojawiały się opisy tego zagadnienia [2,3]. W artykule przedstawiono metodologię modelowania sygnałów osłuchów płuc. Przedstawiono przykładowe widma oraz rozkład próbek sygnału oddechowego. Oprócz modelu normalnego oddechu zdrowego pacjenta, przedstawiono również model jednego z najpopularniejszych objawów zaburzenia oddychania jakim są świsty. Biorąc pod uwagę fakt, że świsty osadzone są na tle normalnego oddechu, w artykule przedstawiono metodykę wyliczania poprawnego stosunku sygnałów tonalnych świstu do sygnału tła

normalnego oddechu (SNR). Przeprowadzono również analizę przedziałów częstotliwości tonów występujących w świstach rzeczywistych oraz ich analizę tonalności. W rozdziale 2 opisane zostały sygnały pozyskane z osłuchu klatki piersiowej. Przedstawione zostały sygnały osłuchu zdrowego pacjenta oraz świstów – anomalii występujących u astmatyków. Rozdział 3 i 4 przedstawia metodologię zbierania informacji o sygnałach normalnego oddechu i świstów oraz modelowanie tych sygnałów. W rozdziale 5 utworzone modele poddane zostały weryfikacji za pomocą istniejących metod [4, 5], służących do rozpoznawania świstów astmatycznych. Artykuł zamyka rozdział 6, w którym zawarto wnioski z przeprowadzonego modelowania.

2. Sygnały osłuchu płuc

Sygnały zarejestrowane podczas osłuchu klatki piersiowej zdrowego pacjenta nazwane są sygnałami normalnego oddechu lub sygnałami normalnymi. Pastercamp i inni opisał sygnały tego rodzaju w [6] jako szum kolorowy którego widmo osiąga szczyt poniżej częstotliwości 100 Hz i opada gwałtownie w przedziale (100 – 200) Hz. Sygnały normalnego oddechu mieszane są z sygnałami, których źródłem są mięśnie, oraz z sygnałami kardiologicznymi. Sygnałów tych nie da się rozseparować, dlatego traktowane są jako jeden dźwięk. Widmo częstotliwościowe sygnału nie zawiera żadnych widocznych pików, czyli sygnał nie ma charakteru tonalnego. Amplituda sygnałów zależy zarówno od pacjenta, jak i od miejsca umieszczenia mikrofonu na klatce piersiowej. Należy również zaznaczyć, że sygnały pozyskane za pomocą mikrofonów umieszczonych w okolicach krtani różnią się kształtem widma, lecz sygnały te nie są omawiane w tej pracy.


W odróżnieniu od sygnałów normalnych, świsty wykazują tonalną charakterystykę. Częstotliwości tonowe zawierają się w przedziale od 100 Hz do 1 kHz, a czas ich trwania przekracza 80 ms. Sygnał tonalny może zawierać jedną lub kilka częstotliwości, które mogą ulegać niewielkiej modulacji. Sygnał świstu jest sumą składowej tonalnej i normalnego oddechu [6, 7].

W pracy analizowano nagrania osłuchów płuc, wykonanych za pomocą rejestratora 8 kHz/16-bit oraz trzech mikrofonów Panasonic WM-61, przytwierdzonych do końcówek stetoskopu. W celu powiększenia bazy sygnałów, użyto również sygnałów z Internetu [8,9]. W celu ujednoczenia, zmieniono częstotliwość próbkowania wszystkich sygnałów na 8000 Hz. Nagrane sygnały zostały pocięte na fragmenty reprezentujące dwie grupy sygnałów (zwykły oddech lub świst) o długości 1024 próbek. Każda z nich liczyła 140 realizacji.

3. Sygnał szumu czystego oddechu**3.1. Identyfikacja cech**

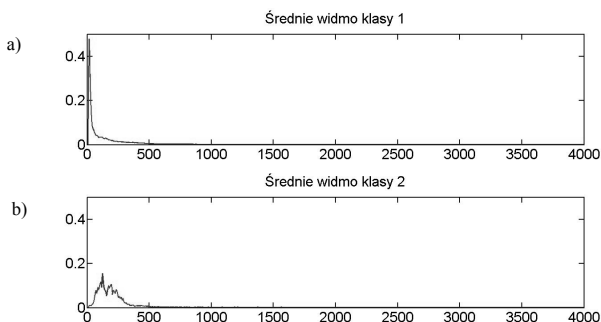
Jak już zostało wspomniane, sygnał normalnego oddechu jest sygnałem szumowym. W celu sprawdzenia jego rozkładu użyto

140 fragmentów reprezentujących normalne oddechy. Sygnały zostały znormalizowane poprzez odjęcie wartości średniej i podzielenie przez maksymalną wartość bezwzględną ($\max(|x|)$). Rysunek 1 przedstawia histogram z wszystkich próbek reprezentujących normalny oddech. Jak widać rozkład histogramu jest w dużym przybliżeniu gaussowski (RMSE = 122,3; R-square = 0,98).



Rys. 1. Histogram próbek normalnego oddechu
Fig. 1. Real lung sounds histogram

Bardziej szczegółowe obserwacje sygnałów normalnego oddechu w dziedzinie częstotliwości pozwoliły zauważyć występowanie 2 rodzajów widm, różniących się w obszarze niskich częstotliwości. Wycięte fragmenty sygnałów zostały pogrupowane w zależności od rodzaju początku widma. Do grupowania posłużył algorytm klasteryzacji hierarchicznej zaimplementowany w Matlabie. Na rysunku 2 jest przedstawione średnie widmo każdej z dwóch klas.




Rys. 2. Średnie widma dwóch klas sygnału normalnego oddechu
Fig. 2. Two typical mean spectra of normal lung sounds

Należy zwrócić uwagę, że sygnał zwykłego oddechu w przeważającej części (95%) należy do klasy 1 i ma widmo przedstawione na rysunku 2a. Pomimo tak dużej nieproporcjonalności, sygnały mające widmo klasy 2 (5%) należy także uwzględnić podczas procesu modelowania.

3.2. Modelowanie normalnego oddechu

Zebrane wyżej informacje posłużyły do zamodelowania sygnałów normalnego oddechu. Wielokrotnie były generowane 1024 próbki, należące do kolejnej realizacji sygnału. Uzyskiwano je w wyniku filtracji szumu białego o rozkładzie normalnym. Do filtracji szumu wykorzystywano krzywą średniego widma wszystkich sygnałów normalnego oddechu. Aby uwzględnić różnorodność widm (patrz rys. 2), krzywa średniego widma była każdorazowo (dla każdego wygenerowanego reprezentanta) modyfikowana przed filtracją w zakresie niskich częstotliwości. Częstotliwościową granicę modyfikacji ustalano losowo z przedziału od 50 Hz do 150 Hz. Innymi słowy, każdy wygenerowany sygnał o długości 1024 filtrowany był za pomocą innej krzywej powstałej na bazie średniego widma (rys. 3).



Rys. 3. Przykład 10 krzywych filtrujących utworzonych na bazie średniego widma
Fig. 3. Example of 10 filtering curves made on a basis of the mean spectrum

Tak otrzymane sygnały były poddawane normalizacji w taki sam sposób jak sygnały rzeczywiste.

4. Sygnał szmeru astmatycznego

4.1. Identyfikacja cech

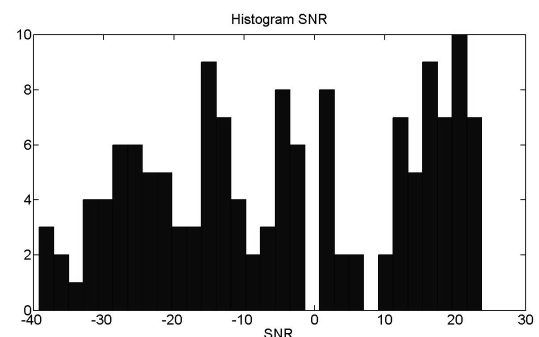
W odróżnieniu do czystego oddechu, świsty astmatyczne są sumą dwóch rodzajów sygnałów: składowej wielotonowej oraz szumu tła oddechowego. Ważną informacją jest stosunek energii tych dwóch sygnałów. Ponieważ świsty mają charakter tonalny a normalny oddech ma charakter szumowy, stosunek energii tych sygnałów określono za pomocą współczynnika SNR (*Signal to Noise Ratio* lub *Wheeze-to-Breath Ratio*). Energię obu składowych wyliczano w dziedzinie częstotliwości, korzystając z twierdzenia Parsevala (1):

$$\sum_n x(n)^2 = \sum_k X(k)^2, \quad X = FFT(x) \quad (1)$$

W celu wyznaczenia współczynnika SNR z widm sygnałów świstów zostały wycięte prążki reprezentujące tonalności. W oryginalnym widmie wycięte fragmenty zastąpiono wartością średnią z próbek widma, występujących przed i po prążku świstu. Następnie policzono energię wszystkich tonów oraz tła oddechowego, oraz wyliczono SNR (2)

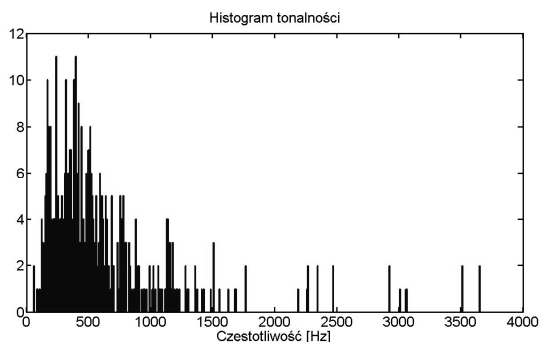
$$SNR = 10 \log_{10} \left(\frac{\sum_k X_{wheeze}(k)^2}{\sum_k X_{noise}(k)^2} \right) \quad (2)$$

gdzie $X_{wheeze}(k)$ oznacza wycięty prążek k -tego tonu, a $X_{noise}(k)$ – wartości widma Fouriera tła oddechu. Na rysunku 4 przedstawiono histogram przyjmowanych wartości przez tak wyznaczony współczynnik SNR. Biorąc pod uwagę małą licznosc sygnałów reprezentujących świsty, do dalszych badań przyjęto SNR z przedziału (-40 – 20) dB o rozkładzie równomiernym.



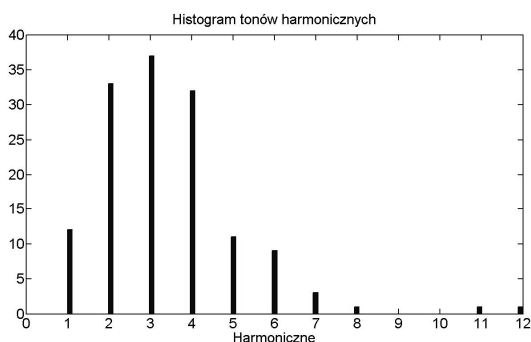
Rys. 4. Histogram SNR dla nagrań świstów
Fig. 4. SNR histogram for wheeze recordings

Kolejnym etapem analizy tonalnych szmerów astmatycznych było określenie przedziału częstotliwości, w którym one występują. W tym celu wyznaczono histogram częstotliwości ich prążków widmowych, uprzednio wyciętych. Wyniki tej operacji przedstawia rysunek 5.




Rys. 5. Histogram częstotliwości tonów w nagraniach świstów
Fig. 5. Histogram of tone frequencies for wheeze recordings

Wycięte prążki tonów posłużyły również do zbadania liczby składowych tonalnych zwykle występujących w świstach. Rysunek 6 przedstawia histogram liczby tonów, wykrytych w nagraniach świstów. Jak widać na rysunku, świsty mające tylko jedną tonalność są w zdecydowanej mniejszości.



Rys. 6. Histogram liczby tonów występujących w nagraniach świstów
Fig. 6. Histogram of number of tones in wheeze recordings

Następnie, podobnie jak w przypadku normalnego oddechu, przeanalizowano tło szumowe świstów pod względem kształtu widma częstotliwościowego. Klasyfikacja tła widmowego świstów wykazała, że w 99,5% przypadków tło to ma podobny kształt, przedstawiony na rysunku 7. Można więc uznać, że zmienia się ono w bardzo ograniczonym stopniu.



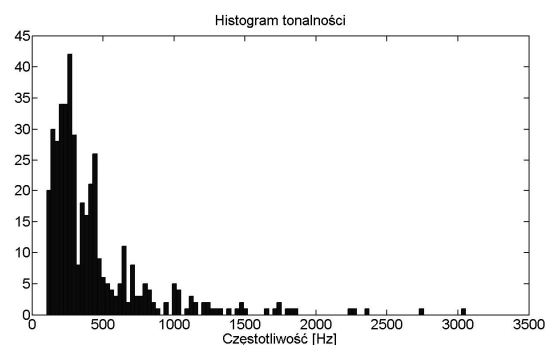
Rys. 7. Średnie widmo tła szumowego świstów
Fig. 7. Mean spectrum of the noisy background of wheezes

4.2. Modelowanie świstów

Jako tło szumowe (oddechowe) dla syntetycznych świstów posłużyły nam sygnały generowane w taki sam sposób jak dla nor-

malnego oddechu. Takie postępowanie pozwala uniknąć sztucznego podwyższania skuteczności poprzez różny kształt widma, a algorytm oceniany jest tylko na podstawie wykrywania tonalności.

Na podstawie analizy tonalności sygnałów rzeczywistych, wygenerowano sygnały tonalne o losowej: liczbie tonów, amplitudach, częstotliwościach i fazach dla każdego reprezentanta sygnału świstu. W modelu przyjęto liczbę tonów z przedziału (1 – 5). Każdy wygenerowany ton miał amplitudę z przedziału (0,5 – 1) oraz był przesunięty w fazie o losowo wygenerowany kąt. Częstotliwość podstawowa generowana była z przedziału (100 – 400) Hz, natomiast kolejne częstotliwości tworzone były jako krotność częstotliwości podstawowej. Wartość krotności częstotliwości zawierała się w przedziale (1,3 – 2). Rysunek 8 przedstawia histogram generowanych tonalności. Dodatkowo dla każdego reprezentanta świstu wprowadzono liniową modulację częstotliwości z przedziału (0 – 15) Hz. Oznacza to, że częstotliwość sygnału na końcu próbki, może różnić się od tej z początku o maksymalnie 15 Hz. Tak utworzone tonalności dodane były do wygenerowanych sygnałów normalnych z odpowiednim SNR z przedziału od -40 do 20 dB.



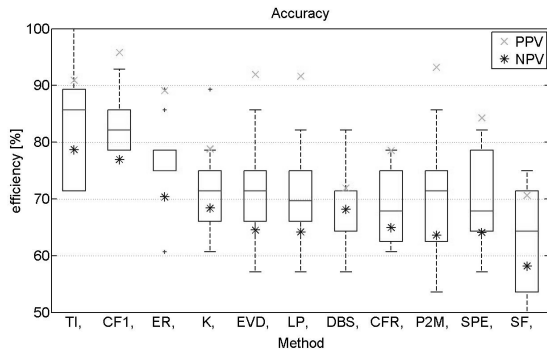
Rys. 8. Histogram częstotliwości wygenerowanych tonów
Fig. 8. Histogram of tone frequencies for generated wheezes

5. Weryfikacja i zastosowanie modelu

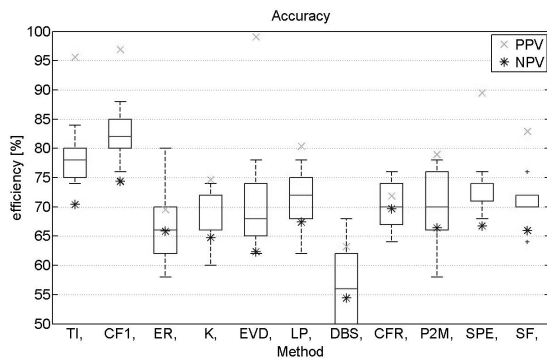
Do weryfikacji modelu sygnałów czystego oddechu oraz modelu świstów astmatycznych posłużyły deskryptory wykorzystywane do detekcji tonalności, opisane i wykorzystywane w [4, 5, 10, 11]: TI – Tonal Index, CF1 – Correlation feature, ER – Energy Ratio, K – Kurtosis, EVD – Eigen Vector Decomposition feature, LP – Linear Prediction feature, DBS – Diagonal Bispectrum feature, CFAR – Constant False Alarm Rate feature, P2M – Peak to Mean ratio, SPE – Spectral Peaks Entropy, SF – Spectral Flatness). Jako klasyfikator wykorzystano metodę SVM (Support Vector Machine) z wielomianową funkcją jądra. W pierwszej kolejności przeprowadzono eksperyment na sygnałach rzeczywistych. Z uwagi na ograniczoną liczbę reprezentantów sygnałów należących do poszczególnych grup, rozpoznawanie przeprowadzono kilkakrotnie używając metody k-fold. Zebrane sygnały podzielono na 10 grup po 14 reprezentantów w grupie. Rozpoznawanie odbywało się na jednym, wylosowanym zbiorze sygnałów, a sygnały z pozostałych grup służyły do nauczania algorytmu. Aby nie pominąć żadnego ze zbiorów, wykonano 20 powtórzeń. Na rysunku 9 zamieszczono wyniki rozpoznawania za pomocą wykresów ramka-wąsy, które przedstawiają medianę oraz 25 i 75 percentyl poszczególnych wyników. Skuteczność rozpoznawania zdefiniowano jako:

$$AC = \frac{TN + TP}{TN + TP + FN + FP} \cdot 100\% \quad (3)$$

gdzie TP – poprawny pozytyw, TN – poprawny negatyw, FP – fałszywy pozytyw oraz FN – fałszywy negatyw. Dodatkowo znakiem „x” oznaczono wartość predykcijną dodatnią, a znakiem „*” – wartość predykcijną ujemną.



Rys. 9. Średnie wyniki rozpoznawania sygnałów rzeczywistych (po 20 próbach)
Fig. 9. Mean results of wheezes recognition using real data (after 20 repetitions)



Rys. 10. Wyniki rozpoznawania zamodelowanych sygnałów (po 20 próbach)
Fig. 10. Mean results of wheeze recognition using modelled signals (after 20 repetitions)

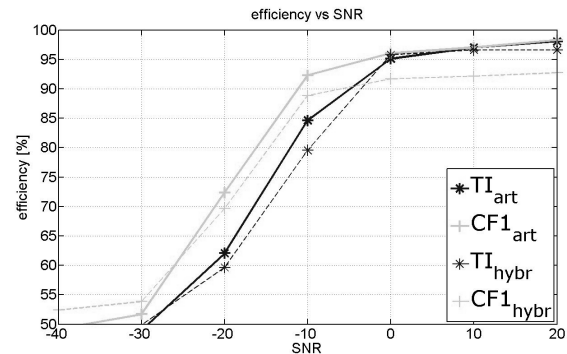
Następnie przeprowadzono rozpoznawanie na zamodelowanych sygnałach. Do rozpoznawania użyto 300 sygnałów, które również podzielono na 10 grup. Rozpoznawanie przeprowadzono 20 razy. Wyniki rozpoznawania dla zamodelowanych sygnałów przedstawia rysunek 10.

Jak widać, wyniki badań przeprowadzonych na stworzonych modelach sygnałów oddechowych w większości przypadków pokrywają się z wynikami badań, wykonanych na sygnałach rzeczywistych. Istotne różnice widać tylko dla dwóch wykorzystanych miar tonalności, a mianowicie dla cechy ER (*Energy Ratio*) oraz DBS (*Diagonal Bispectrum*). Co ważne, uzyskane wyniki dla cech najskuteczniejszych w rozpoznawaniu, TI (*Tonality Index*) oraz CF1 (*Correlation*), są bardzo zbliżone, co pozwala wykorzystać opracowane modele do bardziej rozległego testowania właściwości użytkowych tych cech, w sytuacji ograniczonej liczby nagrań osłuchów płuc. Przykładowo, na rysunku 11 przedstawiono wyniki badania skuteczności rozpoznawania świstów klasyfikatorem SVM dla cech TI i CF1 w zależności od wartości współczynnika SNR dla sygnałów całkowicie sztucznych – linia ciągła, oraz hybrydowych (sztucznie wygenerowanych wielotonów, dodanych do rzeczywistych sygnałów normalnych) – linia przerywana. Dla sygnałów sztucznych system uczonej jednokrotnie zamodelowanymi sygnałami wzorcowymi szumu oddechowego oraz zamodelowanymi sygnałami świstów, mającymi SNR z przedziału od -40 do 20 dB. Rozpoznawano zaś sygnały wielokrotnie dla różnych wartości współczynnika SNR świstów. Próba dla sygnałów hybrydowych wykonano podobnie, z tą różnicą, że sygnały generowane normalnego oddechu zamieniono na sygnały rzeczywiste normalnego oddechu.

6. Wnioski końcowe

W pracy opisano wyniki analizy rzeczywistych nagrań osłuchów płuc. Na tej podstawie opracowano dwa modele sygnałów: czystego oddechu oraz świstu astmatycznego. Stwierdzono zadowalającą zgodność skuteczności rozpoznawania rzeczywistych

świstów astmatycznych i świstów zamodelowanych dla większości testowanych metod detekcji tonalności, w szczególności dla metod TI i CF1. Opracowane modele wykorzystano do zbadania jak skuteczność tych dwóch ostatnich, najlepszych deskryptorów tonalności zależy od wartości SNR samego świstu.



Rys. 11. Porównanie rozpoznawania dla zamodelowanych i hybrydowych sygnałów dla różnych SNR
Fig. 11. Comparison of recognition using modelled and hybrid data for different SNR

Badania, których wyniki przedstawiono w tym artykule, były sfinansowane przez Ministerstwo Nauki i Szkolnictwa Wyższego z Europejskiego Funduszu Rozwoju Regionalnego w ramach Programu Operacyjnego Innowacyjna Gospodarka projekt nr POIG.01.01.01-00-045/09-00 „Inżynieria Internetu Przyszłości”.

7. Literatura

- [1] Coatrieux, J.L.: Integrative science: biosignal processing and modeling. IEEE Engineering in Medicine and Biology Magazine, Volume : 23, Issue:3 pp. 9 - 12, May-June 2004.
- [2] Iier V.K., Ramamoorthy P.A., Ploysongsang Y.: Autoregressive modeling of lung sounds: characterization of source and transmission. IEEE Transactions on Biomedical Engineering, Volume: 36, Issue: 11 pp. 1133 – 1137, Nov. 1989.
- [3] Hadjileontiadis L.J., Panas S.M.: Autoregressive modeling of lung sounds using higher-order statistics: estimation of source and transmission, Proceedings of the IEEE Signal Processing Workshop on Higher-Order Statistics, pp 4 – 8, 21-23 Jul 1997.
- [4] Wisniewski M., Zielinski T.: Application of Tonal Index to pulmonary wheezes detection in asthma monitoring, European Signal Process. Conf., Barcelona, pp. 1544-1548, 2011.
- [5] Wisniewski M., Zielinski T.: Tonality detection methods for wheezes recognition system, 19th International Conf. on Systems, Signals and Image Processing IWSSIP, Vienna 2012, accepted, in print.
- [6] Pasterkamp H., Kraman S.S., Wodicka G.R.: Respiratory Sounds. Advances Beyond the Stethoscope, Am. J. Respir. Crit. Care Med., Volume 156, Number 3, pp. 974-987, September 1997.
- [7] Sovijarvi A.R.A., Dalmasso F., Vanderschoot J., Malberg L.P., Righini G., Stoneman S.A.T.: Definition of Terms for Applications of Respiratory Sounds, Eur. Respir. Rev., vol.10, no.77, pp. 597-610, December 2000.
- [8] http://solutions.3m.com/wps/portal/3M/en_US/Littmann/stethoscope/education/lung_sounds/
- [9] http://faculty.etsu.edu/arnall/www/public_html/heartlung/breathsounds/contents.html
- [10] Wang Q., Wan C.R.: A novel CFAR tonal detector using phase compensation, IEEE J.Oceanic Engineering, vol. 30, no. 4, pp. 900-911, 2005.
- [11] Chang G.C., Cheng Y.P.: Investigation of noise effect on lung sound recognition, International Conference on Machine Learning and Cybernetics, Kunming, , Vol: 3 pp: 1298 - 1301, 12-15 July 2008.