

Identyfikacja dźwięków serca za pomocą algorytmu LPC oraz sztucznej sieci neuronowej

Streszczenie. W artykule przedstawiono algorytm klasyfikacji sygnału fonokardiograficznego, który umożliwia skuteczną identyfikację 12 różnych stanów. Poprzez połączenie ze sobą algorytmu kodowania liniowego (LPC) wraz ze sztuczną siecią neuronową uzyskano skuteczność klasyfikacji sięgającą 82% oraz pełną skuteczność w rozróżnieniu pomiędzy stanami: braku lub występowania schorzenia. Najlepsze rezultaty uzyskano dla jednokierunkowych, dwuwarstwowych sieci, odpowiednio z 24, 20 oraz 12 neuronami w warstwach ukrytych, których zadaniem było: wstępne wykrycie nieprawidłowości, identyfikacja zdrowego tonu oraz identyfikacja patologii. Do uczenia sieci wykorzystano adaptacyjny algorytm wstecznej propagacji -traininga. Opracowany system w przyszłości może zostać zaimplementowany w urządzeniach mobilnych takich jak smartfony czy tablety.

Abstract. In this paper a new classification algorithm of phonocardiography signal is presented. It enables an effective identification of 12 different heart sounds. Through the combination of Linear Predictive Coding (LPC) algorithm and artificial neural network, an accuracy of 82% in identification of signals and 100% of precision in distinguishing between pathological and healthy sound were obtained. The best results were obtained with three neural networks with 24, 20 and 12 neurons in the hidden layer, which were responsible for preliminary identification of pathology, identification of healthy tones and identification of the pathology. The networks were taught with training backpropagation algorithm. In the future, this system could be implemented on smartphones or tablets. (**Heart sound identification system based on LPC algorithm and artificial neural network**).

Słowa kluczowe: fonokardiografia, przetwarzanie sygnałów, sztuczne sieci neuronowe, sztuczna inteligencja, inteligentny stetoskop
Keywords: phonocardiography, signal processing, artificial neural networks, artificial Intelligence, smart stethoscope

doi:10.12915/pe.2014.03.35

Wstęp

W ostatniej dekadzie w krajach Unii Europejskiej, współczynnik umieralności na choroby serca spadł o 30%, co wynika głównie ze wzrostu profilaktyki w krajach zachodnich [1]. Niemniej jednak, to wciąż choroby układu krwionośnego na równi z rakiem stanowią najczęstszą przyczynę zgonów w krajach UE [2]. Należy również zwrócić uwagę, że ze względu na szybkie tempo życia i związany z nim brak czasu, część osób wciąż zaniedbuje regularne badania lekarskie. Opracowanie odpowiednich metod autodiagnostyki pozwoliłoby na przeprowadzanie wstępnego badania diagnostycznego w domu, bez udziału lekarza i w przypadku wystąpienia nieprawidłowości, bezzwłoczne skierowanie pacjenta na specjalistyczne badania diagnostyczne.

Jedną z pierwszych metod stosowanych w diagnostyce lekarskiej, głównie z uwagi na łatwość dostępu, nieinwazyjność oraz prostotę wykonania badania jest fonokardiografia – PCG. Potrzebę opracowania metod autodiagnostyki sygnału fonokardiograficznego, podkreśla również fakt, że czasami nawet doświadczeni lekarze mają problem z identyfikacją niektórych patologicznych dźwięków serca i w swojej diagnozie wspomagają się zmysłem dotyku, starając się wyczuć ruchy klatki piersiowej [3]. Wynika to ze znacznej przewagi niskich częstotliwości, które znajdują się poniżej progu słyszalności.

Przegląd Prac Związanych

Wszystkie powyższe aspekty świadczą o potrzebie szukania nowych oraz doskonalenia istniejących metod diagnostyki oraz leczenia chorób układu krwionośnego. Fakt ten znalazł odzwierciedlenie w najnowszych pracach badawczych [3÷10], w których zostały podjęte próby zaadoptowania zaawansowanych metod przetwarzania sygnałów do celów identyfikacji patologicznych stanów serca.

Jedną z pierwszych prób opracowania algorytmu „inteligentnego” stetoskopu podjęli Boutana, Benidir oraz Barkat, którzy połączyli analizę czasowo częstotliwościową z entropią Rényi [4]. W rezultacie autorom tym udało się wyznaczyć różnicę pomiędzy czterema patologicznymi stanami serca [4]. Odmiana analizy częstotliwościowej – analiza falkowa – została wykorzystana przez chińskich

naukowców z politechniki w Guangzhou do wyznaczenia charakterystycznych cech sygnału [5]. Bazując na wyznaczonych parametrach skonstruowali oni algorytm, który zapewniał 95% skuteczności w identyfikacji między stanem zdrowym, a patologicznym [5]. Babaei oraz Geranmayeh, również wykorzystali analizę falkową do wyznaczenia głównych cech statystycznych dźwięków serca i w połączeniu ze sztuczną siecią neuronową, skonstruowali klasyfikator, który zapewniał 94,42% skuteczności w klasyfikowaniu poszczególnych stanów [6]. Algorytm został przetestowany na zdrowym dźwięku serca oraz dla trzech różnych stanów patologicznych [6].

System umożliwiający przeprowadzanie diagnozy w domu został opracowany przez Jiang oraz Choi [7]. Niemniej jednak, podobnie jak w przypadku algorytmu opracowanego przez Chińskich naukowców, był on w stanie rozróżniać tylko dwa stany – patologiczny oraz zdrowy. Jedne z najlepszych rezultatów, ze skutecznością sięgającą 96% podczas identyfikacji stanu zdrowego oraz 93,1% skuteczności podczas identyfikacji stanów patologicznych osiągnęli Avci wraz z Turkoglu łącząc analizę głównych składowych (*Principle Component Analysis*, PCA) ze sztuczną siecią neuronową [8]. W późniejszym okresie Avci rozwinął swoją pracę konstruując *genetic – support vector machines* [9], który zapewniał 95% skuteczność podczas identyfikacji czterech stanów (3 choroby oraz stan serca zdrowego) [9]. Najnowsze badania, poprzez analizę czterech charakterystycznych cech sygnału (nazwanych: aktywnością, złożonością, mobilnością oraz pikami spektrum) pozwoliły osiągnąć 98% skuteczności w identyfikacji czterech patologicznych stanów serca [10].

Problem Badawczy

Obecny rozwój techniki umożliwia budowę nowoczesnych i dokładnych fonokardiografów elektronicznych gwarantujących wysoką jakość zarejestrowanego sygnału. Natomiast wciąż nie został opracowany odpowiedni algorytm identyfikacji [3÷10] poszczególnych stanów patologicznych. Główną przeszkodą w dalszym rozwoju systemów autodiagnostyki chorób serca jest duża różnorodność stanów patologicznych (rys 1) oraz niestacjonarność sygnału [11, 12]. Oczywiście jest również fakt, że jednym z głównych

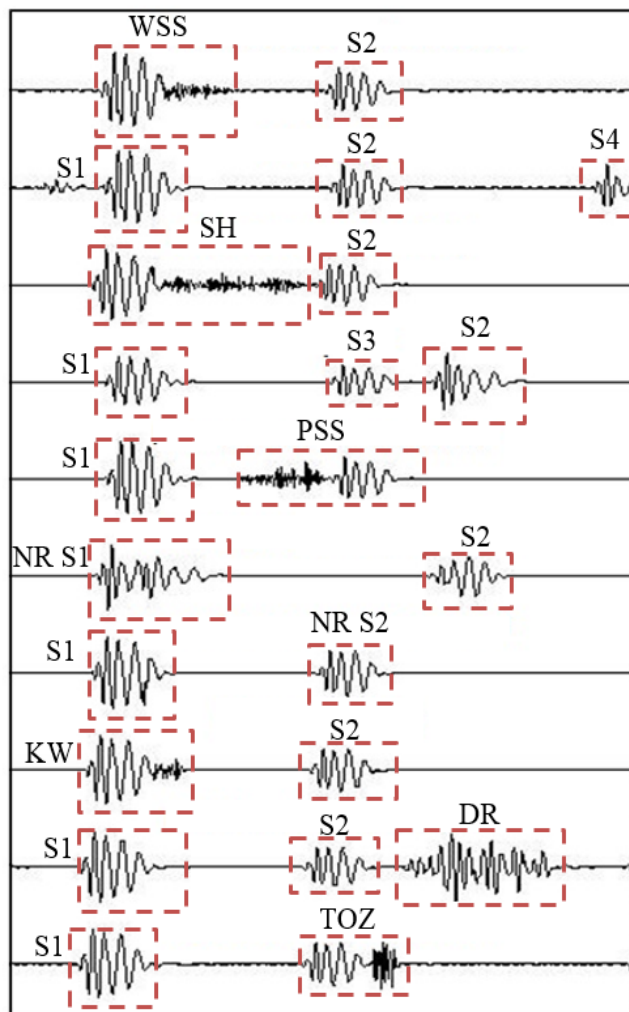
wymogów stawianych urządzeniom takim jak „inteligentny” stetoskop jest pełna skuteczność identyfikacji. Każdy procent niepewności takich urządzeń może skutkować śmiercią tysięcy osób. Dodatkowo, dotychczas stosowane algorytmy wyznaczania cech charakterystycznych sygnału (m.in. analiza falkowa) charakteryzują się dużą złożonością obliczeniową, co może stanowić przeszkodę w ich implementacji na dedykowane urządzenia mikroprocesorowe. Koniecznym jest również zwiększenie różnorodności rozpoznawanych stanów, ponieważ najlepsze opracowane algorytmy umożliwiają rozpoznawanie tylko czterech stanów chorobowych [9, 10].

Dostosowanie przez autorów algorytmu LPC [12] do celów identyfikacji poszczególnych stanów patologicznych umożliwiło zmniejszenie złożoności obliczeniowej fazy wstępnego przetwarzania sygnału. Dodatkowo algorytm ten charakteryzuje się łatwością implementacji na urządzeniach mikroprocesorowych. Dlatego autorzy określają jako główny cel artykułu, opracowanie efektywnego algorytmu klasyfikacji poszczególnych stanów serca, przyjmując jako bazę zmodyfikowany algorytm LPC opisany w [12]. Zakłada się, że jednym z rezultatów wykorzystania tego algorytmu będzie zwiększenie ilości rozpoznawanych stanów chorobowych serca.

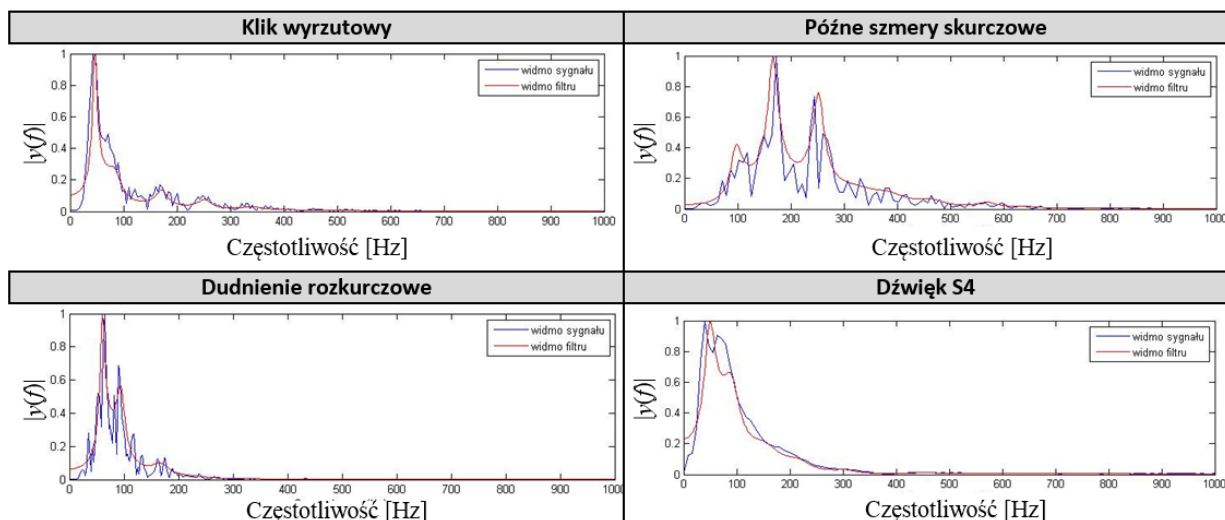
Wyznaczanie cech sygnału

Na rysunku 1 zaprezentowano przebiegi fonokardiograficzne zdrowych i patologicznych dźwięków serca. Głównymi składowymi zdrowych dźwięków serca są tony: S1 – wynikający z drgań wytworzonych podczas zamykania zastawki dwudzielnej i trójdzielnej serca oraz ton S2 – będący efektem zamknięcia zastawki płucnej oraz zastawki aortalnej. Dodatkowo, w niektórych przypadkach można wyróżnić trzeci (S3) oraz czwarty (S4) ton serca. U osób młodych występowanie tonu S3 nie jest uważane za stan patologiczny. Ton serca S4 tylko częściowo pojawia się u osób zdrowych, a jego obecność wynika z przed skurczowych drgań komór w czasie rozkurczu [3].

Pochodzenie patologicznych dźwięków serca można podzielić na dwie grupy. Pierwszą grupę stanowią dźwięki skurczowe, które są bezpośrednio związane z turbulentnym przepływem krwi, np. będące następstwem zwężenia zastawki aortalnej. Drugą grupę stanowią dźwięki rozkurczowe związane z powrotnym przepływem krwi, a które spowodowane są przede wszystkim niedomykaniem się zastawek. Wszystkie szmery charakteryzują się szerokim spektrum częstotliwości, niewielką amplitudą oraz brakiem wyraźnego początku i końca.



Rys.1. Przykładowe przebiegi fonokardiograficzne z wyselekcjonowanymi dźwiękami serca (S1 – pierwszy ton serca; S2 – drugi ton serca; S3 – trzeci ton serca; S4 – czwarty ton serca; WSS – wczesne szmery skurczowe; SH – szmer holosystoliczny; PSS – późne szmery skurczowe; NR S1 – normalne rozszczepienie pierwszego tonu serca; NR S2 – normalne rozszczepienie drugiego tonu serca; KW – klik wyrzutowy; DR – dudnienie rozkurczowe; TOZ – trzask otwarcia zastawki). Opracowanie własne, na podstawie nagrań zamieszczonych na stronie głównej producenta stetoskopu elektronicznego Littmann 3M [13]



Rys.2. Widmo sygnału oraz widmo modelowanego filtra dla wybranych dźwięków serca

Pierwszym etapem działania algorytmu jest segmentacja zarejestrowanych przebiegów fonokardiograficznych, której rezultat został zaprezentowany w postaci czerwonej ramki na rysunku 1. Opracowany algorytm działa na podstawie założeń o długości poszczególnych składowych sygnału. Najdłuższa składowa S1 trwa do 160 ms, a najkrótsza składowa S4 trwa do 30 ms. Założono także, że najkrótszy odstęp pomiędzy poszczególnymi składowymi sygnału PCG wynosi 1 ms. Próba ulepszenia tego algorytmu może stanowić przedmiot dalszych badań.

Kolejnym etapem algorytmu klasyfikacji sygnału PCG jest wyznaczenie odpowiednich parametrów poszczególnych ramek sygnału w taki sposób by umożliwić ich późniejszą identyfikację. Poprzez analogię sygnału PCG z sygnałem mowy ludzkiej zdecydowano się wykorzystać algorytm LPC, który w najnowszej pracy autorów [12] zaadoptowano do celów modelowania dźwięków fonokardiograficznych.

Koncepcja identyfikacji mowy ludzkiej polega na dopasowaniu quasi-stacjonarnych fragmentów jego widma (zazwyczaj są to fragmenty liczące od 20 do 40 ms) do widma modelowanego filtra FIR za pomocą algorytmu LPC (*Linear Predictive Coding*). Najczęściej podczas modelowania stosuje się 10 rząd mianownika transmitancji, który pozwala na pełną identyfikację mowy. Ze względu na fakt, że dźwięki serca charakteryzują się większą dynamiką oraz niestacjonarnością, aby lepiej odwzorować widmo sygnału koniecznym stało się odpowiednie zwiększenie rzędu filtra. W literaturze [3] podawane jest, że najbardziej złożone widmo składowej S1 może posiadać nawet siedem maksimów. Niemniej jednak, niektóre patologiczne tony serca mogą charakteryzować się jeszcze większą złożonością. Na rysunku 2 można zaobserwować, że widmo późnych szmerów skurczowych, na którym można zaobserwować aż 10 maksimów. Przyjmując dodatkowo pewien zapas na wypadek innych patologii serca, do zamodelowania sygnału PCG należy przyjąć minimum dwanaście biegunów transmitancji, które leżą w środku okręgu jednostkowego blisko pulsacji rezonansowych. Dodatkowo wymaga się by wielomian mianownika posiadał tylko współczynniki rzeczywiste, zatem konieczne jest sprzężenie biegunów parami, co wymusza aż 24-ty rząd

mianownika transmitancji. Ostatecznie transmitancja modelowanego filtra przyjmuje postać opisaną wzorem

$$H(z) = \frac{G}{A(z)} = \frac{G}{1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_{24} z^{-24}} = \frac{G}{(1 - p_1^* z^{-1})(1 - p_1^* z^{-1}) + \dots + (1 - p_{12}^* z^{-12})(1 - p_{12}^* z^{-12})}$$

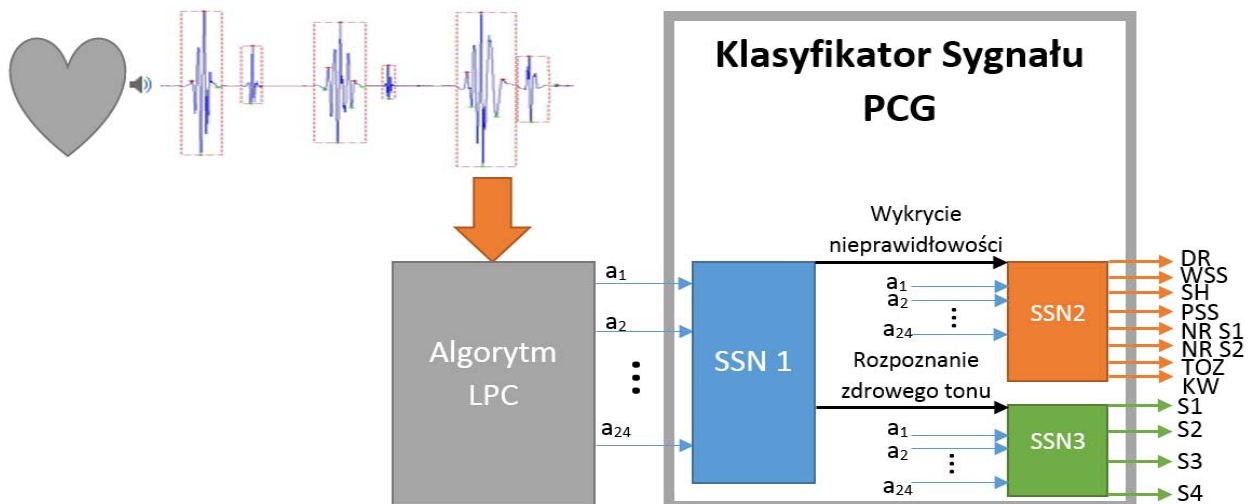
gdzie: p_k^* oznacza wielkość sprzężoną do p_k .

Na rysunku 2 zostały zestawione widma wybranych dźwięków serca z widmami modelowanego filtra. Można zaobserwować słusność wprowadzonych zmian, gdyż różnice pomiędzy widmami sygnału, a widmami modelu są znikome. Dodatkowo widma poszczególnych dźwięków są na tyle charakterystyczne, że możliwa staje się ich dalsza klasyfikacja.

Klasyfikacja sygnału PCG

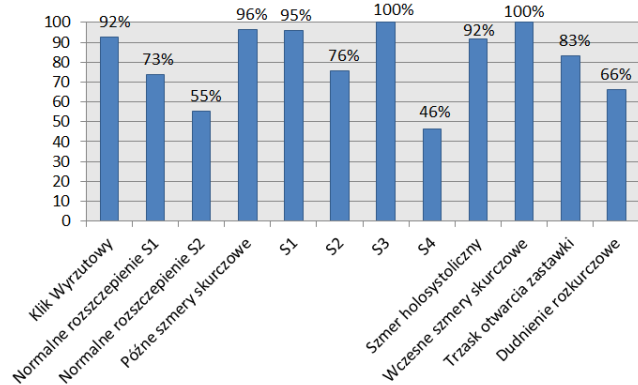
Na podstawie zmodyfikowanego algorytmu LPC, do wyznaczenia odpowiednich cech sygnału fonokardiograficznego został opracowany algorytm jego klasyfikacji. Dla każdej ramki sygnału, współczynniki modelu transmitancji dźwięków serca $a_1 \div a_{24}$ zostały wykorzystane jako parametry wejściowe do klasyfikatora, natomiast na wyjściu została podana bezpośrednia informacja odnośnie tonu, który jest reprezentowany przez dany dźwięk. Baza dźwięków składała się z 12 różnych przebiegów (rysunek 1), z których każdy zawierał sześć powtórzeń. Została ona podzielona na dwie równe części wykorzystane do uczenia oraz weryfikacji i walidacji.

Algorytm klasyfikacji sygnału fonokardiograficznego został podzielony na dwie części. Pierwsza część oznaczona blokiem SSN 1 na rysunku 3 odpowiedzialna jest za wstępne wykrycie nieprawidłowości. Natomiast druga część, do której zaliczają się sieci SSN 2 oraz SSN 3 odpowiadają za precyzję diagnozy, definiując odpowiednio stan chorobowy lub ton serca. Celem takiej operacji – rozdzielania klasyfikatora na trzy różne sieci neuronowe – jest uzyskanie jak największej skuteczności wstępnego wykrycia nieprawidłowości. Podczas badań symulacyjnych uzyskano 100% skuteczność sieci SSN1 w rozróżnieniu pomiędzy stanami patologicznymi, a stanami zdrowymi.



Rys 3. Ideowy Schemat algorytmu identyfikacji patologicznych dźwięków serca za pomocą algorytmu LPC i sztucznej sieci neuronowej ozn.: SSN1 – sztuczna sieć neuronowa, odpowiedzialna za wstępną detekcję nieprawidłowości; SSN 2 – sztuczna sieć neuronowa odpowiedzialna za precyzję diagnozy; SSN 3 – sztuczna sieć neuronowa odpowiedzialna za precyzję tonu serca; S1 – pierwszy ton serca; S2 - drugi ton serca; S3 – trzeci ton serca; S4 – czwarty ton serca; WSS – wczesne szmery skurczowe; SH- szmer holosystoliczny; PSS – późne szmery skurczowe; NR S1 – normalne rozszczepienie pierwszego tonu serca; NR S2 – normalne rozszczepienie drugiego tonu serca; KW – klik wyrzutowy; DR – dudnienie rozkurczowe; TOZ – trzask otwarcia zastawki; $a_1 \div a_{24}$ współczynniki modelu LPC (Linear Predictive Coding).

Najlepsze rezultaty klasyfikacji uzyskano dla dwuwarstwowych sieci składających się w warstwach ukrytych z 24 neuronów dla sieci SSN1, 20 dla SSN2 oraz 12 dla SSN3. Do uczenia sieci wykorzystano adaptacyjny algorytm wstecznej propagacji – „*traingda*”. Najlepsze uzyskane rezultaty klasyfikacji przedstawiono na rysunku 4. Średnia skuteczność klasyfikacji wyniosła: dla sieci SSN1 – 100%, SSN2 – 82,2% oraz dla SSN3 – 79,5%, natomiast całkowita średnia skuteczność klasyfikatora wyniosła 82%.



Rys.4. Rezultaty klasyfikacji poszczególnych dźwięków PCG. Średnia skuteczność klasyfikacji wynosi 82%.

Podsumowanie i wnioski

Przedstawiony w artykule algorytm klasyfikacji tonów serca umożliwia skuteczną identyfikację 12 różnych dźwięków. Poprzez połączenie ze sobą algorytmu kodowania liniowego (LPC) wraz ze sztuczną siecią neuronową uzyskano całkowitą skuteczność klasyfikacji sięgającą 82%. Warty uwagi jest również fakt, iż uzyskano 100% skuteczność w rozróżnieniu pomiędzy stanem patologicznym, a stanem zdrowym.

W przyszłości, rozbudowanie proponowanego systemu o dodatkowy blok, odpowiedzialny za powiązanie danego dźwięku serca z konkretną jednostką chorobową, może stanowić podstawę skutecznego systemu autodiagnostyki chorób serca bazującego na analizie przebiegów fonokardiograficznych. Dodatkowo z uwagi na wykorzystanie algorytmów kodowania mowy (które są obecnie implementowane w urządzeniach mobilnych) oraz sztucznych sieci neuronowych (które w etapie normalnego działania – po zakończeniu procesu uczenia się – charakteryzują się niewielką złożonością obliczeniową) opracowany system może zostać zaimplementowany w urządzeniach mobilnych takich jak smartfony czy tablety.

W przyszłości, aby zwiększyć skuteczność identyfikacji dźwięków serca, należy zwiększyć bazę danych oraz rozważyć wykorzystanie pozostałych algorytmów kodowania mowy (cepstrum, mel-cepstrum). Zasadnym jest również próba zweryfikowania innych klasyfikatorów bazujących na sztucznej inteligencji, takich jak np. algorytmy rojowe [14, 15]. Dodatkowo poprzez konstrukcję dodatkowych modułów oraz urządzeń pomiarowych system może zostać także rozbudowany o blok diagnostyki układu oddechowego [16] lub układu pokarmowego [17]. Analogiczny system może zostać również opracowany do autoanalizy przebiegów elektrokardiograficznych (EKG) [18]. Ze względu na swoją uniwersalność, analogiczny system może zostać też wykorzystany do monitorowania stanu technicznego struktur mechanicznych [19] lub jako autodiagnostyka systemu do pozycjonowania [20].

LITERATURA

[1] European Commission Eurostat, Causes of death statistics (available: <http://epp.eurostat.ec.europa.eu/>)

[2] World Health Organization WHO, (available: <http://www.who.int/healthinfo/statistics/mortality/en/index.html>)

[3] Ahlström C., "Processing of the Phonocardiographic Signal- Methods for the intelligent Stethoscope", Sweden 2006

[4] Boutana D., Benidir M., Barkat B., "Segmentation and identification of some pathological phonocardiogram signals using time-frequency analysis," *Signal Processing*, IET, vol. 5, no. 6, pp. 527-537, 2011.

[5] Wu J.-B., Zhou S., Wu Z., Wu X.-M., "Research on the method of characteristic extraction and classification of phonocardiogram," in *Systems and Informatics (ICSAI)*, 2012 International Conference on, 2012, pp. 1732-1735

[6] Babaei S., Geranmayeh A., Heart sound reproduction based on neural network classification of cardiac valve disorders using wavelet transforms of PCG signals, *Computers in Biology and Medicine*, Volume 39, Issue 1, January 2009, Pages 8-15, ISSN 0010-4825,

[7] Jiang Z. Choi S., "A cardiac sound characteristic waveform method for in-home heart disorder monitoring with electric stethoscope," *Expert Systems with Applications*, vol. 31, no. 2, pp. 286 - 298, 2006

[8] Avci E. Turkoglu I., "An intelligent diagnosis system based on principle component analysis and anfis for the heart valve diseases," *Expert Systems with Applications*, vol. 36, no. 2, Part 2, pp. 2873 - 2878, 2009

[9] Avci E., "A new intelligent diagnosis system for the heart valve diseases by using genetic-svm classifier," *Expert Systems with Applications*, vol.36, no.7, pp.10618-10626, 2009

[10] Abdel-Motaleb I., Akula R., "Artificial intelligence algorithm for heart disease diagnosis using phonocardiogram signals," in *Electro/Information Technology (EIT)*, 2012 IEEE International Conference on, 2012, pp. 1-6.

[11] Niedziejko P., Dobrowolski A., Krysowaty I.: Współczesne metody analizy dźwięku serca. *Przegląd Elektrotechniczny*, (2011), nr 9a.

[12] Redlarski G., Gradolewski D., „Wykorzystanie algorytmu kompresji sygnału mowy MP-LPC do modelowania przebiegu fonokardiograficznego”, *Przegląd Elektrotechniczny*, vol 89, nr 2013/4a.

[13] Strona producenta mikrofonu elektronicznego: <http://solutions.3mpoland.pl/>, (dostęp: czerwiec 2012)

[14] Piechocki J., Ambroziak D., Palkowski A., Redlarski G., Use of Modified Cuckoo Search algorithm in the design process of integrated power systems for modern and energy self-sufficient farms, *Applied Energy*, Available online 22 August 2013, ISSN 0306-2619,

[15] Redlarski G. Gradolewski D. Pałkowski A., A System for Heart Disease Diagnosis Based on Phonocardiography, *PLoS ONE* (w recenzji)

[16] Redlarski G., Jaworski J., A new approach to modeling of selected human respiratory system diseases, directed to computer simulations, *Computers in Biology and Medicine*, Volume 43, Issue 10, 2013, Pages 1606-1613,

[17] Redlarski G., Tojza P.M.: Aplikacja komputerowa wspomagająca proces diagnostyki chorób górnego odcinka przewodu pokarmowego na podstawie analizy przebiegu pH-metrii. *Pomiary Automatyka Kontrola*, vol. 59, nr 3/2013, 193-195

[18] Gradolewski D., Redlarski G. "The Use of Wavelet Analysis to Denoising of Electrocardiography Signal." *XV International PhD Workshop OWD 2013*, 19-22 October 2013

[19] Mieloszyk M., Krawczuk M., Skarberk L., Ostachowicz W., An application of neural network for Structural Health Monitoring of an adaptive wing with an array of FBG sensors 2011 *J. Phys.: Conf. Ser.* 305 012066, 2011

[20] Dziak D., Jachimczyk B., Kulesza W., An Analysis of Uncertainty and Robustness of Waterjet Machine Positioning Vision System, *Elektronika Ir Elektrotechnika*, ISSN 1392-1215 Vol. 19, No. 9, 2013

Autorzy: mgr inż. Dawid Gradolewski, Politechnika Gdańska, Wydział Elektrotechniki i Automatyki, Katedra Mechatroniki i Inżynierii Wysokich Napięć, ul. G. Narutowicza 11/12, 80-233 Gdańsk, E-mail: gradolewski@ely.pg.gda.pl
dr hab. inż. Grzegorz Redlarski, prof. PG, Politechnika Gdańska, Wydział Elektrotechniki i Automatyki, Katedra Mechatroniki i Inżynierii Wysokich Napięć, ul. G. Narutowicza 11/12, 80-233 Gdańsk, E-mail: g.redlarski@ely.pg.gda.pl