

Adaptacyjny algorytm filtracji sygnału fonokardiograficznego wykorzystujący sztuczną sieć neuronową

Streszczenie. Podstawowym problemem podczas projektowania systemu autodiagnostyki chorób serca, bazującego na analizie sygnału fonokardiograficznego (PCG), jest konieczność zapewnienia, niezależnie od warunków zewnętrznych, sygnału o wysokiej jakości. W artykule, bazując na zdolności Sztucznej Sieci Neuronowej (SSN) do predykcji sygnałów periodycznych oraz quasi-periodycznych, został opracowany adaptacyjny algorytm filtracji dźwięków serca. Wykazano, że poprzez zastosowanie jednokierunkowej, dwuwarstwowej sieci neuronowej ze 100 neuronami w warstwie wejściowej oraz odpowiednio z 25 i 10 neuronami w warstwach ukrytych oraz poprzez zastosowanie algorytmu Silva-Almeida podczas uczenia sieci metodą wstecznej propagacji wraz z sigmoidalną funkcją pobudzenia tangensa hiperbolicznego, możliwa jest efektywna filtracja sygnału PCG. Opracowany algorytm został przetestowany zarówno dla dźwięków serca zarejestrowanych u osoby zdrowej (S1-S4) jak dla dźwięków serca osób posiadających zmiany patologiczne (normalne rozszczępienie tonu S1, klik wyrzutowy oraz dudnienie rozkurczowe).

Abstract. The quality of the phonocardiography signal plays a key role in the development of an effective auto-diagnostic system. In this paper, an adaptive denoising algorithm is shown, which was developed based on the neural networks ability of periodic and quasi-periodic signals prediction – such as phonocardiography signal. It is presented that a multilayer neural network of 100 neurons in the input layer, 25 in first and 10 in second layer, trained using the backpropagation algorithm can remove the noise efficiently. During the simulation Silva-Almeida algorithm and Tan-Sigmoid transfer function were used. The denoising algorithm is tested on normal (S1 – S4) and pathological (normal split S1, ejection click, diastolic rumble) heart tones. (**Adaptive Neural Network Filter for denoising the phonocardiography signal**).

Słowa kluczowe: Filtry Adaptacyjne, Sztuczna Inteligencja, Sztuczne Sieci Neuronowe, Fonokardiografia.


Keywords: Adaptive Filters, Artificial Intelligence, Neural Networks, Phonocardiography (PCG).

doi:10.12915/pe.2014.11.58

Wstęp

Według statystyk Światowej Organizacji Zdrowia [1], choroby układu krwionośnego stanowią na świecie główną przyczynę zgonów. Stąd też odpowiednio wczesne wykrycie nieprawidłowości układu sercowo-naczyniowego może uchronić życie wielu osób. W związku z tym opracowanie efektywnego algorytmu autodiagnostyki chorób serca, umożliwiającego monitorowanie stanu zdrowia pacjenta w warunkach domowych stało się jednym z głównych celów badawczych zainteresowanych środowisk naukowych. Jedną z metod badawczych, która ze względu na nieinwazyjność oraz prostotę wykonania cieszy się szczególnym zainteresowaniem, jest fonokardiografia (PCG). Niemniej jednak głównie z uwagi na znaczną podatność tego sygnału na zaszumienie, do tej pory nie opracowano skutecznego algorytmu autoanalizy.

Zasadniczo szумы wpływające na pomiar sygnału PCG można rozróżnić jako pochodzenia zewnętrznego lub wewnętrznego (rys. 1). Szумы pochodzenia zewnętrznego zawierają szerokie spektrum dźwięków z otoczenia np. takich jak mowa lub dźwięki spowodowane ruchem, podczas gdy na szумы pochodzenia wewnętrznego składają się przeważnie dźwięki trawienne oraz dźwięki powstałe w procesie oddychania. Spektrum tych dźwięków nakłada się na spektrum dźwięków serca, co znacznie podwyższa poziom złożoności problemu filtracji zarejestrowanego sygnału PCG.



Rys 1. Mapa spektrum sygnału PCG oraz sygnałów zakłócających (na podstawie [2])

Przegląd prac związanych z filtracją sygnału PCG

Dotychczasowa [3], szczegółowa analiza czasowo-częstotliwościowa umożliwiła opracowanie odpowiednich algorytmów identyfikacji [4] oraz klasyfikacji [5] sygnałów PCG. Niemniej jednak w opracowaniach [4, 5] pomiar sygnałów wykonywany był w akustycznie sterylnych warunkach, niespotykanych w życiu codziennym. Stąd, by umożliwić budowę inteligentnego systemu autodiagnostyki (tzw. „inteligentnego stetoskopu”), który byłby w stanie pracować w warunkach domowych, koniecznym stało się opracowanie skutecznego algorytmu filtracji.

Do tej pory powstały nieliczne prace bezpośrednio dedykowane zagadnieniu filtracji sygnału PCG. W jednej z pierwszych, Messer [6] zaadoptował do tego celu algorytm filtracji falkowej. Algorytm ten został dostosowany do pracy w „hałaśliwym otoczeniu” [7] oraz doczekał się wielu implementacji m.in. podczas filtracji sygnału EKG [8].

W ostatnim okresie podjęto również prace nad opracowaniem algorytmu adaptacyjnego bazującego na analizie falkowej [9]. Niemniej jednak, w rzeczywistości wielopoziomowa dekompozycja falkowa, w znaczny sposób zwiększa złożoność obliczeniową oraz wymusza pracę na zarejestrowanym wcześniej sygnale, co nader utrudnia budowę systemu pracującego w czasie rzeczywistym.

Inne podejście zastosował Khan, który opracował „współpracujący zespół mikrofonów” [10]. W wyniku usunięcia z sygnału pomiarowego dźwięku powodowanego oddychaniem, w znaczący sposób zwiększył jakość sygnału PCG. Zia, Griffel oraz Semmlow [11], w analogiczny sposób, poprzez umiejscowienie mikrofonu na brzuchu pacjenta, starali się wyeliminować dźwięki trawienne nakładające się na wynikowy sygnał PCG. Jednakże, umiejscowienie dodatkowych sensorów [10, 11] wiązało się z dyskomfortem pacjenta i uniemożliwiało budowę systemu pracującego w warunkach domowych.

Kolejne próby opracowania odpowiedniego algorytmu filtracji sygnału fonokardiograficznego także nie przyniosły spodziewanego rezultatu. Nawet system bazujący na dwukanałowej rejestracji danych, opracowany przez zespół badawczy kierowany przez Várady'a – jak przyznali sami autorzy – w dalszym ciągu wymaga dalszej klinicznej weryfikacji [12].

Problem badawczy


W rzeczywistości problem związany z filtracją sygnału fonokardiograficznego może zostać ograniczony do tzw. problemu „ślepej separacji sygnałów” (ang. *blind source separation*). Najczęściej stosowanym wówczas podejściem jest wykorzystanie sztucznej sieci neuronowej [13]. Podejście takie zostało wielokrotnie zaadaptowane do celów filtracji licznych biosygnatów, m.in.: sygnału elektrograficznego [14], RTG klatki piersiowej [15], czy EEG mózgu [16].

Uwzględniając powyższe fakty, można nakreślić główny cel badawczy prezentowanego materiału, którego istotą jest dostosowanie algorytmu „ślepej separacji sygnałów”, bazującego na sztucznej sieci neuronowej [13-18], do celów filtracji sygnału fonokardiograficznego.

Metody


Ogólny schemat działania proponowanego algorytmu został zaprezentowany na rysunku 2. Rdzeniem systemu jest dobrze znany algorytm „ślepej separacji sygnałów” bazujący na sztucznej sieci neuronowej [10-15]. Niemniej jednak system ten nie został dotychczas odpowiednio zaadaptowany do celów filtracji sygnału PCG.

Zarejestrowane dźwięki serca zawierające szumy – $x(n)$, porównywane są z odpowiedzią sieci neuronowej – $y(n)$. Wyznaczony w ten sposób $Błąd(n)$ wykorzystywany jest w procesie uczenia sieci neuronowej metodą wstecznej propagacji. Jako wejście do sieci wykorzystywany jest wektor i -elementów poprzednich próbek zarejestrowanego sygnału PCG. Zadaniem sztucznej sieci neuronowej jest obserwacja i próbek sygnału $x(n)$ oraz ich estymacja [17].



Rys 3. Czysty sygnał oraz sygnał zaszumiony, wykorzystywany podczas wyznaczania optymalnych parametrów sieci neuronowej

W celu wyznaczenia odpowiedniej struktury sieci neuronowej do „czystego przebiegu” prawidłowego dźwięku serca – uzyskanego z bazy danych mikrofonu 3M [19], dodano różne wartości mocy nieskorelowanego szumu białego. Na rysunku 3 przedstawiono „czysty sygnał” serca zawierający tony S1, S2 i S3 oraz „sygnał zaszumiony” o zmierzonym współczynniku SNR (*signal-to-noise ratio*), wynoszącym 10 dB.



Rys 2. Propozycja funkcjonowania opracowanego algorytmu

W celu obiektywnego wyznaczenia optymalnych parametrów algorytmu filtracji wykorzystano współczynnik SNR określony wzorem (1). Współczynnik ten został zdefiniowany, jako zależność pomiędzy mocą czystego sygnału PCG – P_y oraz mocą sygnału po filtracji P_{noise} . Tak zdefiniowany współczynnik daje bowiem informację na temat efektywności proponowanego algorytmu.

$$(1) \quad SNR = 10 \log_{10} \frac{P_y}{P_{noise}}$$

Współczynnik SNR przed filtracją porównywany jest z jego wartością po filtracji, dlatego też wyższa jego wartość determinuje ten algorytm, który efektywniej odfiltrowuje zakłócenia nakładające się na sygnał fonokardiograficzny. Analogiczny sposób weryfikacji został wykorzystany w pracach [6-8].

Dodatkowo, aby dostarczyć informacji odnośnie zmian kształtu sygnału fonokardiograficznego wykorzystano współczynnik dopasowania zdefiniowany wzorem



$$(2) \quad fit = 100 \cdot \left(1 - \frac{\sum_{i=1}^n [f(i) - y(i)]^2}{\sum_{i=1}^n \left[y(i) - \frac{1}{n} \sum_{i=1}^n y(i) \right]^2} \right)$$

Zasadniczo, jest to współczynnik determinacji [20], znormalizowany w zakresie 0-100%. Jego wartość obliczana jest na bazie informacji o sygnale oryginalnym $f(i)$ i odfiltrowanym $x(n)$. Zdefiniowana we wzorze wartość fit zmienia więc swój zakres od 0% (w przypadku pełnej rozbieżności pomiędzy porównywanymi sygnałami) do 100% (gdy porównywane sygnały w pełni nakładają się na siebie).

Symulacje



Pierwszym istotnym działaniem podczas projektowania proponowanego systemu jest wyznaczenie odpowiedniego rozmiaru warstwy wejściowej sieci neuronowej. Na rysunku 4 został zaprezentowany przebieg zmian współczynnika SNR oraz współczynnika dopasowania dla różnych wartości mocy szumu dodawanego do czystego sygnału PCG. Symulacje zostały przeprowadzone odpowiednio dla 25, 50, 100 oraz 200 neuronów w warstwie wejściowej.

Najwyższa wartość SNR wyznaczona jest dla sieci neuronowej ze 100 neuronami w warstwie wejściowej. Sieci neuronowe z mniejszą liczbą neuronów nie pozwalają na osiągnięcie zadowalających rezultatów. Z kolei warstwa wejściowa składająca się z 200 neuronów charakteryzuje się znaczną niestabinością występującą podczas filtracji, co można zaobserwować poprzez analizę przebiegu współczynnika dopasowania (można zauważyć, że posiada ona zarówno najmniejszą jak i największą wyznaczoną wartość – odpowiednio dla sygnału o mocy szumu równej 6 dB oraz 8 dB).



Rys 4. Przebieg SNR oraz współczynnika dopasowania *fit* dla różnych wartości szumu dodawanego do czystego sygnału PCG wyznaczonych dla różnych wielkości warstwy wejściowej

Kolejnym etapem jest dobór optymalnej wielkości warstwy ukrytej. W tym celu na rysunku 5 zostały przedstawione wyniki symulacji dla sześciu proponowanych sieci neuronowych; czterech z podwójną warstwą ukrytą: SSN1 (15 oraz 10 neuronów), SSN2 (25 oraz 10 neuronów), SSN3 (50 oraz 10 neuronów), SSN4 (50 oraz 20 neuronów); oraz dwóch z pojedynczą warstwą ukrytą: SSN5 (30 neuronów), SSN 6 (60 neuronów).





Rys 5. Przebieg SNR oraz współczynnika dopasowania *fit* dla różnych wartości szumu dodawanego do czystego sygnału PCG wyznaczonych dla różnych wielkości warstwy ukrytej

Sieci neuronowe z pojedynczą warstwą ukrytą (SSN5 oraz SSN6) nie pozwalają na efektywną filtrację sygnału fonokardiograficznego. Można to zaobserwować głównie w przypadku, gdy na sygnał bazowy nakłada się szum o znaczącej mocy. W skrajnych przypadkach sieci te tracą nawet do 90% informacji zawartych w sygnale bazowym. Spośród sieci dwuwarstwowych, sieci SSN1 oraz SSN2 znacznie lepiej odfiltrowują szum biały z sygnału bazowego niż sieci SSN3 oraz SSN4. Z uwagi na fakt, iż znacznie wyższa wartość współczynnika dopasowania wyznaczona jest dla sieci SSN2 może być ona uważana za umożliwiającą uzyskanie najlepszych rezultatów filtracji. Dlatego też sieć neuronowa ze 100 neuronami w warstwie wejściowej, 25 neuronami w pierwszej oraz 10 neuronami w drugiej warstwie ukrytej może być uznana, za sieć najlepiej filtrującą sygnał PCG (podczas symulacji, w celu uzyskania szybszej zbieżności, zastosowano algorytm *Silva-Almeida*).

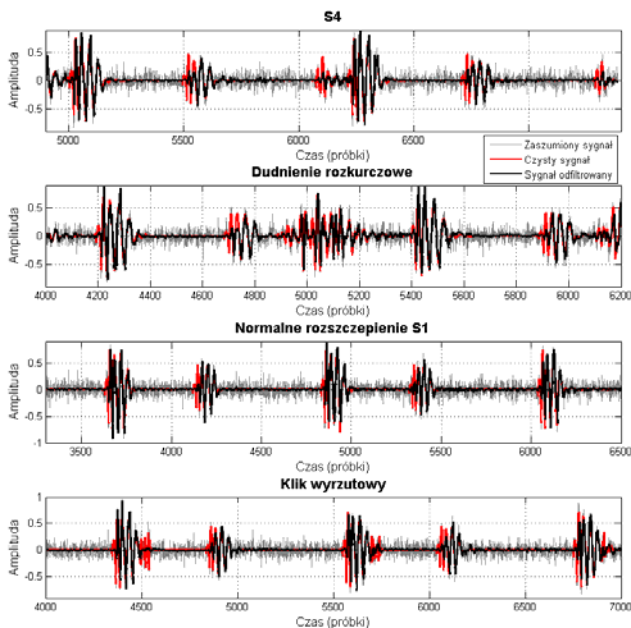
Podsumowanie i wnioski

Na rysunku 6 zostało przedstawione; w części A – porównanie sygnału zaszumionego z sygnałem po filtracji; oraz w części B – porównanie sygnału oryginalnego z sygnałem po filtracji. Można zaobserwować, że opracowany algorytm w początkowej fazie wymaga dodatkowego czasu (około 3000 próbek – 1,5 sekundy), który jest niezbędny do zaadaptowania się sieci do wymagań otoczenia. Można również zaobserwować, że nadal pewna ilość wysokoczęstotliwościowych szumów pozostaje w sygnale. Niemniej jednak szumy te mogą zostać odfiltrowane w dalszej fazie przetwarzania sygnału, np. poprzez filtr dolnoprzepustowy.



Rys 6. Wynik filtracji: A – porównanie sygnału zaszumionego wraz z sygnałem po filtracji; oraz B – porównanie sygnału oryginalnego z sygnałem po filtracji

Dodatkowo, na rysunku 7, zaprezentowano efekt działania algorytmu w przypadku wybranych dźwięków (dudnienie rozkurczowe, normalne rozszczepienie tonu S1 oraz klik wyrzutowy) będących bezpośrednim następstwem zmian patologicznych występujących u pacjenta. Pomimo faktu, iż podczas filtracji pewna ilość informacji zawartych w sygnale została utracona (współczynnik dopasowania równy 81%) pewne charakterystyczne cechy pozwalają nadal na dalszą szczegółową identyfikację sygnału.



Rys 7. Wynik filtracji patologicznych dźwięków serca: dudnienie rozkurczowe, normalne rozszczenie tonu S1 oraz klik wyrzutowy

Podsumowując dotychczasowe rozważania można stwierdzić, że główny cel artykułu, który stanowiła próba opracowania efektywnego algorytmu filtracji dźwięków serca został zakończony sukcesem. Skuteczność algorytmu została zweryfikowana w przypadku dźwięków serca, które mogą wskazywać na potencjalnie występowanie zmian patologicznych u pacjenta, co w dotychczasowych pracach badawczych było z reguły pomijane. Opracowany algorytm umożliwia efektywną filtrację sygnału o znacznym poziomie szumów i charakteryzuje się niewielką złożonością obliczeniową, co – zdaniem autorów – może w przyszłości pozwolić na jego wykorzystanie w fazie wstępnego przetwarzania sygnałów np. w systemie tzw. „inteligentnego stetoskopu”. Proponowane rozwiązanie może również zostać dostosowane do innych zagadnień [21], m.in. filtracji szumów występujących podczas pomiaru paramentów układu oddechowego [22].

LITERATURA

- [1] World Health Organization WHO, (available: <http://www.who.int/healthinfo/statistics/mortality/en/index.html>)
- [2] Varady P., Wavelet-based adaptive denoising of phonocardiographic records, *Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE*, vol.2, no., pp. 1846-1849 vol.2, 2001.
- [3] Niedziejko P., Dobrowolski A., Krysowaty I., Współczesne metody analizy dźwięku serca. *Przegląd Elektrotechniczny*, 87 (2011) nr. 9, 1-7.
- [4] Redlarski G., Gradolewski D., Wykorzystanie algorytmu kompresji sygnału mowy MP-LPC do modelowania przebiegu fonokardiograficznego, *Przegląd Elektrotechniczny*, 89 (2013), nr. 4 A, 40-45
- [5] Gradolewski D., Redlarski G., Identyfikacja dźwięków serca za pomocą algorytmu LPC oraz sztucznej sieci neuronowej, *Przegląd Elektrotechniczny*, 90 (2014) nr. 3 161-164, doi:10.12915/pe.2014.03.35
- [6] Messer S.R., Agzarian J., Abbott D., Optimal wavelet denoising for phonocardiograms, *Microelectronics Journal*, Vol. 32, No. 12. (December 2001), pp. 931-941.
- [7] Gradolewski D., Redlarski G., Wavelet-based denoising method for real phonocardiography signal recorded by mobile

- devices in noisy environment, *Computers in Biology and Medicine* (2014), DOI: 10.1016/j.combiomed.2014.06.011
- [8] Gradolewski D., Redlarski G. "The Use of Wavelet Analysis to Denoising of Electrocardiography Signal." *XV International PhD Workshop OWD 2013*, 19–22 October 2013
- [9] Varady P., Wavelet-based adaptive denoising of phonocardiographic records, *Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE*, vol.2, no., pp. 1846-1849 vol.2, 2001
- [10] Khan A.K., Onoue T., Hashiodani K., Fukumizu Y., Yamauchi H., Signal and noise separation in medical diagnostic system based on independent component analysis, *Circuits and Systems (APCCAS), 2010 IEEE Asia Pacific Conference*, vol., pp.812-815, 6-9 Dec 2010
- [11] Zia, M.K., Griffel, B., Semmlow, J.L., Robust detection of background noise in phonocardiograms, *Biomedical Engineering (MECBME), 2011 1st Middle East Conference on*, vol., no., pp.130-133, 21-24 Feb. 2011
- [12] Várady P., Wildt L., Benyó Z., Hein A., An advanced method in fetal phonocardiography, *Computer Methods and Programs in Biomedicine*, Volume 71, (2003), Pages 283-296,
- [13] Cichocki A., Karhunen J., Kasprzak W., Vigário R.: Neural networks for blind separation with unknown number of sources, *Neurocomputing*, Volume 24, Issues 1–3, February 1999, Pages 55-93, ISSN 0925-2312,
- [14] Jung TP, Makeig S, Humphries C, Lee TW, McKeown MJ, Iragui V, Sejnowski TJ: Removing electroencephalographic artifacts by blind source separation. *Psychophysiology* 37: 163–178
- [15] Rasheed, T.; Ahmed, B.; Khan, M. A U; Bettayeb, M.; Sungyoung Lee; Tae-Seong Kim,,: Rib suppression in frontal chest radiographs: A blind source separation approach, *Signal Processing and Its Applications*, 2007. ISSPA 2007. 9th International Symposium on, vol., no., pp.14, 12-15 Feb. 2007
- [16] Dan Xiao; Jianfeng Hu,; Identification of Motor Imagery EEG Signal, *Biomedical Engineering and Computer Science (ICBECS), 2010 International Conference on*, vol., no., pp.1.4, 23-25, 2010
- [17] Amari, S.-I.; Cichocki, A.: Adaptive blind signal processing-neural network approaches, *Proceedings of the IEEE*, vol.86, no.10, pp.2026,2048, Oct 1998
- [18] Woo, W.L.; Sali, S.: A new demixer scheme for blind source separation using general neural network model, *Signal Processing and its Applications, Sixth International Symposium on. 2001*, vol.2, no., pp.379,381 vol.2, 2001
- [19] Strona producenta mikrofonu elektronicznego: <http://solutions.3mpoland.pl>, (dostęp: Maj 2014)
- [20] B.S. Everitt, A. Skrondal, Cambridge Dictionary of Statistics, 2010.
- [21] 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*, 51 (2013) 159-170,
- [22] 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,

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
mgr inż. Piotr Tojza, Politechnika Gdańska, Wydział Elektrotechniki i Automatyki, Katedra Mechatroniki i Inżynierii Wysokich Napięć, ul. G. Narutowicza 11/12, 80-233 Gdańsk, E-mail: ptojza@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