

Wyznaczanie objętości wyrzutowej pneumatycznej pompy wspomaganie serca siecią neuronową i transformatą falkową

Leszek GRAD, Wojciech SULEJ, Krzysztof MURAWSKI

Instytut Teleinformatyki i Automatyki, WCY, WAT
ul. Gen. W. Urbanowicza 2, 00-908 Warszawa 46
leszek.grad{wojciech.sulej}{krzysztof.murawski}@wat.edu.pl

STRESZCZENIE: W artykule przedstawiono wyniki uzyskane w trakcie badań będących kontynuacją prac nad wykorzystaniem sztucznych sieci neuronowych do określania relacji między widokiem membrany wiotkiej i objętością wyrzutową komory krwi mechanicznej, pozaustrojowej pompy wspomaganie serca. Celem pracy było zbadanie możliwości zwiększenia dokładności obliczeń podczas wyznaczania objętości wyrzutowej przez sztuczną sieć neuronową. Badania koncentrowały się na technice ekstrakcji cech z obrazu. W ich trakcie użyto transformatę falkową. Otrzymane wyniki porównano z wynikami uzyskanymi uprzednio przez inne metody. Badania przeprowadzono na modelu pompy wspomaganie serca, który był używany także w poprzednich doświadczeniach.

SŁOWA KLUCZOWE: transformata falkowa, sztuczna sieć neuronowa, objętość wyrzutowa, pomiar optyczny


1. Wprowadzenie

Publikacja jest efektem kontynuacji badań, których założenie i cel przedstawiono w pracy [1]. W artykule [1] zaproponowano zastosowanie sztucznej sieci neuronowej (*ANN*) do określania wielkości chwilowej objętości wyrzutowej krwi (*SV*) modelu pneumatycznej pozaustrojowej pompy wspomaganie serca, rysunek 1a. W pracy [1] zawarto również wyniki obliczeń objętości wyrzutowej pompy, które stanowią punkt odniesienia do oceny jakości rezultatów prezentowanych obecnie. Objętość wyrzutową komory wyznaczono na podstawie analizy obrazów membrany wiotkiej, którą zaopatrzone w markery, rysunek 1b. Obraz analizowano z użyciem *ANN*. Zastosowanie sieci

a)



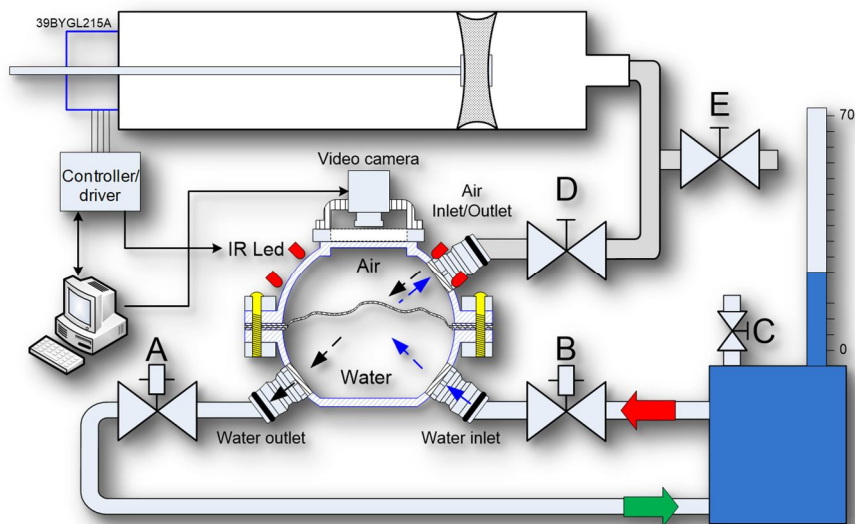
b)



Rys. 1. Autorski model protezy serca (a), zdjęcie membrany wykonane w paśmie NIR (b)

neuronowej do realizacji obliczeń dla znacznej liczby danych wejściowych jest czasochłonne, nawet dla współczesnych komputerów. Z tego względu obraz membrany wiotkiej o rozdzielczości 640×640 pikseli, tworzący wektor obserwacji o długości 409 600 elementów, został zredukowany. Redukcję przeprowadzono wykonując ekstrakcję cech obrazu. Do tego celu w pracy [1] zastosowano dwie metody redukcji przestrzeni cech: zmniejszenie rozdzielczości obrazu oraz wyznaczenie współczynników transformaty *DCT* obrazu i zastosowanie obcięcia z przyjętym arbitralnie progiem. W niniejszej pracy ekstrakcję cech obrazu przeprowadzono stosując dyskretną transformatę falkową (*DWT*). Założenia i wstępne wyniki badań prezentowanych w pracy zostały omówione na XII Konferencji Integrated Optics Sensors, Sensing Structures, and Methods [2].

Wyznaczone cechy obrazu podano na wejście sieci neuronowej, której strukturę omówiono w artykule [1]. Dzięki temu możliwe było zestawienie i porównanie wyników badań z wynikami zawartymi w pracy [1]. Porównanie wyników było możliwe również dlatego, że rejestrację obrazów wykonano w tym samym układzie pomiarowym (rysunek 2), i z wykorzystaniem tego samego egzemplarza modelu pompy (*VAD*). Konstrukcję modelu pompy wzorowano na protezie serca wykorzystywanej w badaniach [3], [4], [5]. Model pokazany na rysunku 1a posiada komorę pneumatyczną i komorę krwistą oddzieloną membraną wiotką (rysunek 1b). Trudność określania chwilowej objętości wyrzutowej *VAD* związana jest z identyfikacją kształtu membrany.



Rys. 2. Układ pomiarowy [1]

Szczegółowy opis użytej membrany i układu pomiarowego (rysunek 2), zawarto w pracach [6], [7], [8], [9] i [10].

2. Sztuczna sieć neuronowa

Pomiar objętości wyrzutowej komory zrealizowano stosując sztuczną sieć neuronową. W badaniu użyto trójwarstwową sieć neuronową typu feed-forward three layer MLP [11], [12], [13], której strukturę przedstawiono w pracy [1].

W pierwszej warstwie sieci wykorzystano 20 neuronów. Warstwę drugą (ukrytą) stanowiło 40 neuronów, a warstwę trzecią jeden neuron wyjściowy. Dla wszystkich neuronów przyjęto tę samą funkcję aktywacji. W badaniach użyto funkcję *logsig transfer function*¹. Przygotowanie ANN do wyznaczania objętości poprzedzono zgromadzeniem obrazów membrany wiotkiej. Obrazy rejestrowano przy różnym stopniu wypełnienia komory oraz przy znanych wartościach SV. Wartość objętości wyrzutowej dla każdego z obrazów odczytano z menzurki pomiarowej z dokładnością $\pm 0,5$ ml. Obrazy, zgodnie z zaleceniami zawartymi w artykułach [11], [12] i [13], podzielono na dwa zbiory w proporcji 2:1. Tym samym utworzono odpowiednio zbiór danych uczących i zbiór testowy.

Dla wszystkich obrazów wykonano ekstrakcję cech stosując dyskretną transformatę falkową. Trening sztucznej sieci neuronowej przeprowadzono na danych uczących i dla algorytmu Backpropagation [11], [12], [13].

Nauczoną sieć testowano podając na jej wejścia dane ze zbioru testowego, które nie były wykorzystywane w trakcie procesu uczenia – wyznaczania wag neuronów.

Eksperyment z użyciem ANN prowadzono nie mniej niż trzykrotnie, a wyniki uśredniono w celu minimalizacji wpływu błędów przypadkowych.

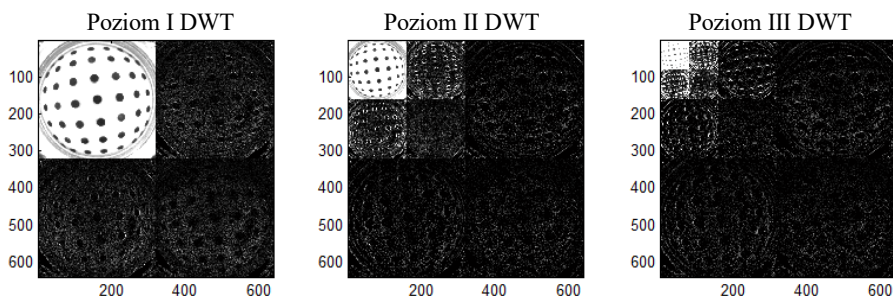
3. Ekstrakcja cech obrazu z użyciem DWT

Ekstrakcję cech obrazu membrany wiotkiej przeprowadzono stosując dyskretną transformatę falkową DWT [14] i [15]. Liczbę cech wykorzystywanych podczas uczenia i testowania sieci neuronowej dobierano zmieniając stopień dekompozycji obrazu.

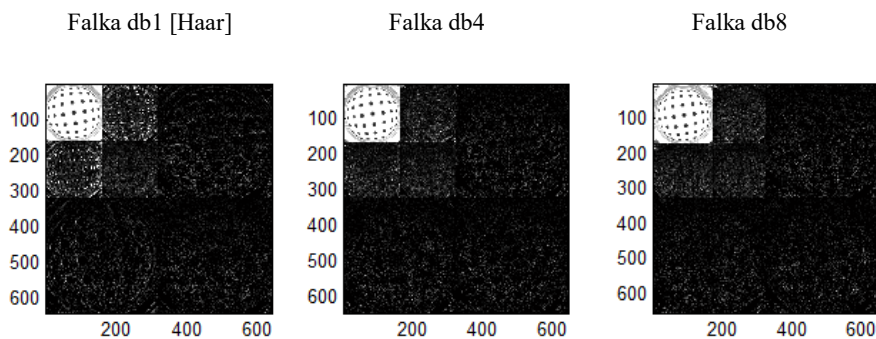
¹ Logistyczna funkcja aktywacji: $\varphi(e) = \frac{1}{1 + \exp(-\beta e)}$, e – pobudzenie neuronu,

β -parametr określający szybkość przejścia pomiędzy fazami nasycenia.

Przykład cech wyznaczonych w procesie przetwarzania obrazu membrany wiotkiej dla trzech poziomów dekompozycji z użyciem falki Haara (db1) pokazano na rysunku 3. W trakcie eksperymentów badano również możliwość zastosowania falki Daubechies wyższych rzędów (db1, db4, db8, db20). Wybrane z nich przedstawiono na rysunku 4.



Rys. 3. Ekstrakcja cech obrazu, trzy poziomy dekompozycji falkowej obrazu membrany

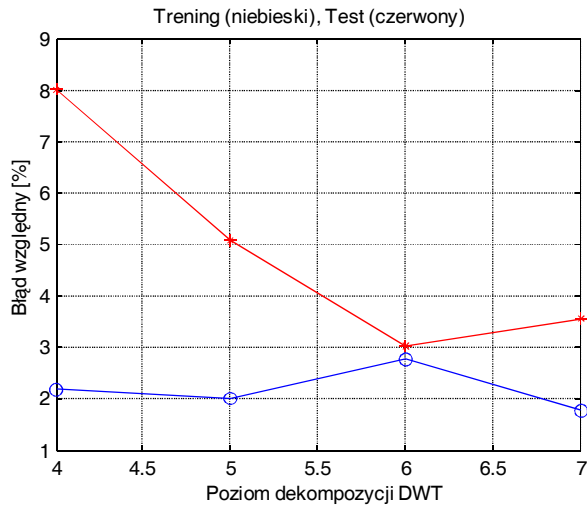


Rys. 4. Dwa poziomy dekompozycji falkowej obrazu wyznaczone dla różnych falek Daubechies (db1, db4, db8)

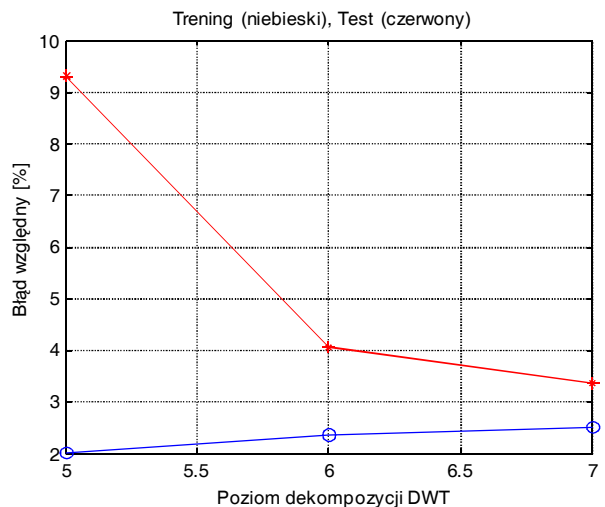
Redukcję rozmiaru danych wejściowych podawanych na sztuczną sieć neuronową wykonano przyjmując za wektor cech, współczynniki falkowe n -tego poziomu dekompozycji. W eksperymencie brano pod uwagę wszystkie współczynniki danego poziomu dekompozycji (lowpass approximation cA , horizontal detail cH , vertical detail cV i diagonal detail cD) lub jedynie lowpass approximation cA [14], [15].

4. Pomiar objętości wyrzutowej

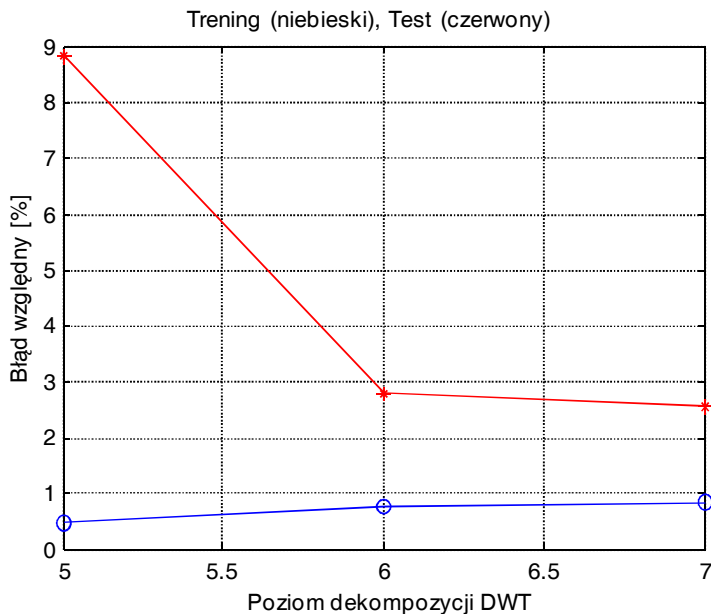
Badaniu poddano dwa sposoby parametryzacji obrazu membrany z wykorzystaniem dyskretnej transformaty falkowej. Sposób pierwszy polegał na tworzeniu wektora cech tylko ze współczynników cA uzyskanych dla sprawdzanego poziomu dekompozycji. Eksperymenty przeprowadzono dla różnych typów falek. Najlepsze rezultaty otrzymano dla falki Haara (db1) rysunek 5a.



Rys. 5a. Wyniki pomiaru SV na podstawie cA , $MSE=0,0001$



Rys. 5b. Wyniki pomiaru SV na podstawie cA , cH , cV , cD , $MSE=0,0001$



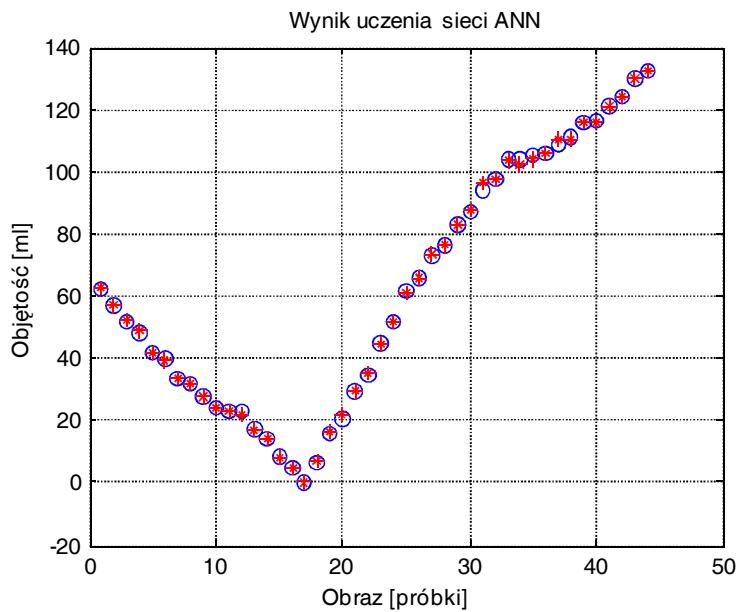
Rys. 5c. Wyniki pomiaru SV dla $MSE=0,00001$

Rysunek 5a przedstawia rezultat względnego pomiaru SV w funkcji poziomu dekompozycji od 4 do 7. Poziomom tym odpowiadały liczby współczynników składowej cA wynoszące odpowiednio: 1600, 400, 100 i 25. Wykres dolny, na rysunku 5a, pokazuje błąd uzyskany dla danych pochodzących ze zbioru uczącego. Wykres górny, na rysunku 5a, obrazuje błąd otrzymany dla danych testowych. Najmniejszy błąd względny wynoszący około 3% osiągnięto dla szóstego poziomu dekompozycji. Rezultat ten otrzymano dla sieci neuronowej wytrenowanej z $MSE=0,0001$ (ang. *Mean Squared Error*).

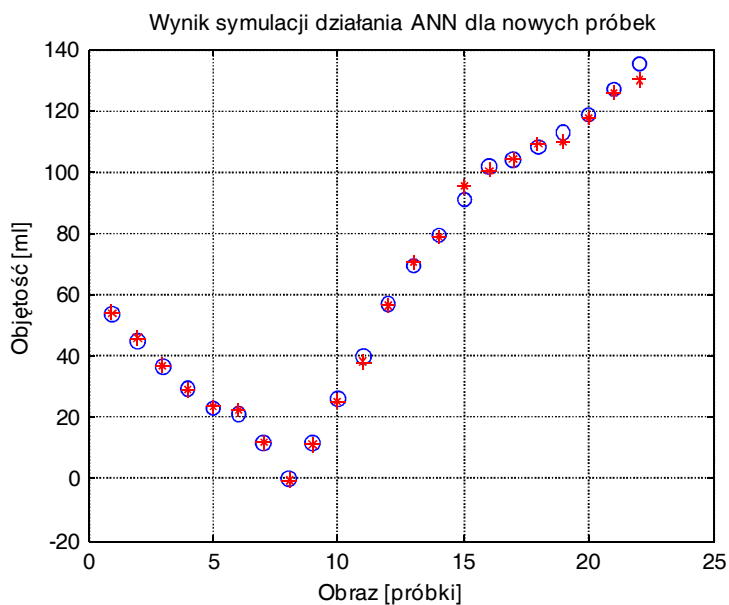
Dalsze uczenie sieci doprowadziło co prawda do zmniejszenia się błędu względnego do około 2%, ale sieć w tym przypadku uczyła się znacznie dłużej, nie osiągając przy tym założonego poziomu błędu $MSE = 0,00001$. Drugi sposób parametryzacji polegał na uwzględnieniu w wektorze cech wszystkich współczynników dekompozycji falkowej (cA , cH , cV , cD). W omawianym przypadku prace prowadzono dla poziomów dekompozycji od 5 do 7. Poziomy te charakteryzowały się odpowiednio liczbą współczynników: 1600, 400 i 100. Rezultaty uwzględniania współczynników cA , cH , cV i cD podczas wyznaczania SV przez ANN , dla której MSE wynosił 0,0001 przedstawia rysunek 5b i rysunek 5c. Otrzymane wyniki są nieco gorsze w porównaniu z parametryzacją opartą wyłącznie na składowej cA . W badaniu uzyskano błąd względny na poziomie powyżej 3%. Jednak w tym przypadku uczenie ANN do poziomu $MSE=0,00001$ było możliwe. Uzyskany błąd względny kształtował się wówczas

na poziomie 2,5% dla siódmego poziomu dekompozycji. Wyniki uczenia sztucznej sieci neuronowej pokazano na rysunku 6a.

a)



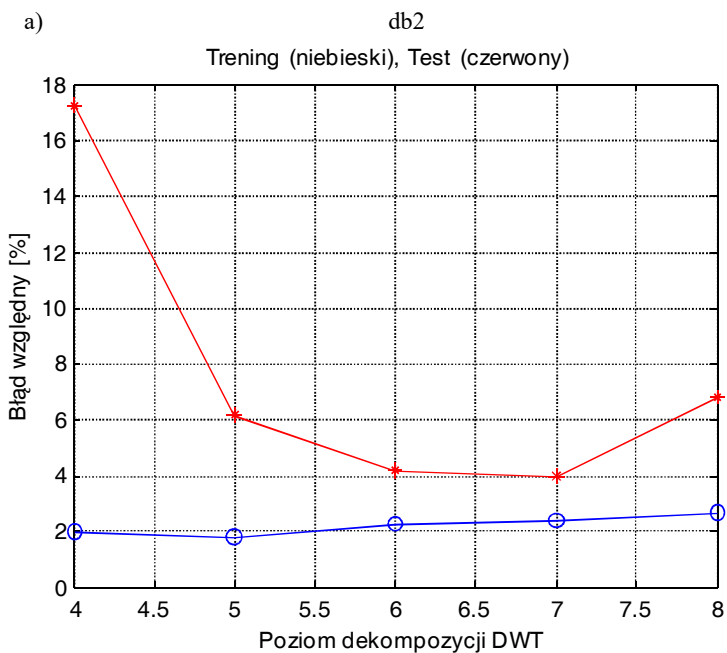
b)



Rys. 6. Wyniki treningu (a) oraz testu (b) dla parametryzacji i uczenia z rysunku 5c

Rezultat wyznaczania SV przez ANN po podaniu na wejście danych testowych prezentuje rysunek 6b. Na wykresach kółka oznaczają wartości pomiarów, gwiazdki symbolizują wartości wyznaczone przez ANN . Jak wcześniej wspomniano wykonano również eksperyment polegający na doborze najlepszej falki. Badaniu poddano kilka wybranych falek Daubechies. Najlepsze rezultaty wyznaczania SV uzyskano dla falki db1 (Haara).

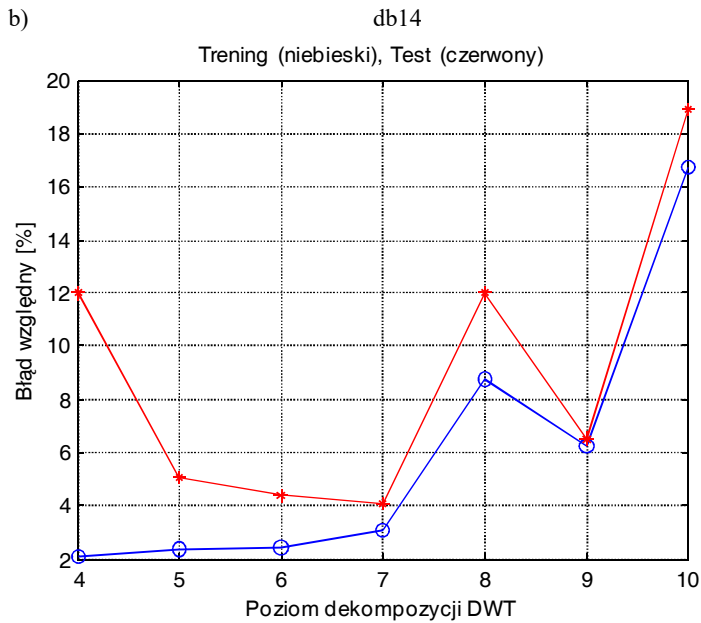
Rysunek 7 przedstawia wyniki uzyskane dla falek wyższych rzędów. Wyniki badań otrzymane dla tych samych założeń dla falki db1 przedstawia rysunek 5a.




Rys. 7a. Wyniki pomiaru SV dla falki Daubechies db2 przez ANN z $MSE = 0,0001$

5. Podsumowanie i wnioski

Użycie parametryzacji opartej na DWT do wyznaczania objętości wyrzutowej modelu pneumatycznej pozaustrojowej pompy wspomaganie serca metodą ANN przyniosło pozytywne rezultaty. W pracy zaproponowano i przebadano dwa sposoby redukcji rozmiaru danych wejściowych oparte na DWT.



Rys. 7b. Wyniki pomiaru SV dla falki Daubechies db14 przez ANN z $MSE = 0,0001$



Rys. 7c. Wyniki pomiaru SV dla falki Daubechies db20 przez ANN z $MSE = 0,0001$

W badaniu pierwszym uwzględniono tylko składową cA danego poziomu dekompozycji. Wariant drugi polegał na uwzględnieniu wszystkich składowych. Błąd względny wyznaczania SV uzyskano na poziomie ok. 2,5%. W drugim przypadku, po uwzględnieniu wszystkich składowych (cA , cH , cV , cD), sieć neuronowa w krótszym czasie przechodziła proces uczenia.

Odnosząc otrzymane wyniki pomiaru objętości wyrzutowej do uzyskanych wcześniej wyników dla parametryzacji opartej na obciążeniu współczynników transformaty DCT [1] należy uznać, że wyniki są porównywalne. W efekcie, podejścia prezentowane obecnie oraz w pracy [1] mogą być stosowane zamiennie. Na korzyść transformaty DCT przemawia fakt uzyskiwania krótszych wektorów cech, przy których otrzymywano najlepsze wyniki.

Literatura

- [1] GRAD L., MURAWSKI K., PUSTELNY T., *Measuring the stroke volume of the pneumatic heart prosthesis using an artificial neural network*. Proc. SPIE 10034, 11th Conference on Integrated Optics: Sensors, Sensing Structures, and Methods, 2016, pp. 7.1-7.4 (DOI: 10.1117/12.2243952).
- [2] GRAD L., MURAWSKI K., SULEJ W., *Research to improve the accuracy of determining the stroke volume of an artificial ventricle using the wavelet transform*. Proc. SPIE 10455, 12th Conference on Integrated Optics: Sensors, Sensing Structures, and Methods, 2017, pp. 9.1-9.4 (DOI: 10.1117/12.2280804).
- [3] GIBINSKI P., KONIECZNY G., MACIAK E., OPILSKI Z., PUSTELNY T., *Acoustic device for measuring instantaneous blood volume in cardiac support chamber i.e. pneumatic heart assist driving chamber, has sensor supporting heart in openings, and audio amplifier connected with volume unit of blood-cell support*. Patent Number(s): PL394074-A1, 2011.
- [4] KONIECZNY G., PUSTELNY T., *Preliminary research of an optical sensor for measurements of the blood chamber volume in the POLVAD prosthesis*. Acta Phys. Pol. A 122, 2012, pp. 962-965.
- [5] KONIECZNY G., PUSTELNY T., MARCZYŃSKI P., *Optical sensor for measurements of the blood chamber volume in the POLVAD prosthesis - static measurements*. Acta Phys. Pol. A, 124, 2013, pp. 479-482.
- [6] MURAWSKI K., PUSTELNY T., GRAD L., MURAWSKA M., *Estimation of the blood volume in pneumatically controlled ventricular assist device by vision sensor and image processing technique*. Proc. 21st International Conference on Methods and Models in Automation and Robotics (MMAR), 2016, pp. 100-105 (DOI: 10.1109/MMAR.2016.7575115).

- [7] MURAWSKI K., ARCIUCH A., PUSTELNY T., *A new innovative depth from defocus method: identification of the impact of the marker size on the distance measurement result*. Proc. SPIE 10034, 11th Conference on Integrated Optics: Sensors, Sensing Structures, and Methods, 2016, pp. 9.1-9.4 (DOI: 10.1117/12.2244130).
- [8] SULEJ W., GRAD L., MURAWSKI K., *The technique of accuracy measurement of membrane shape mapping of an artificial ventricle*. Proc. SPIE 10455, 12th Conference on Integrated Optics: Sensors, Sensing Structures, and Methods, 2017, pp. B.1-B.4 (DOI: 10.1117/12.2280806).
- [9] SULEJ W., MURAWSKI K., PUSTELNY T., *Improvement of accuracy of the membrane shape mapping of the artificial ventricle by eliminating optical distortion*. Proc. 22nd International Conference on Methods and Models in Automation and Robotics (MMAR), 2017, pp. 820-825 (DOI: 10.1109/MMAR.2017.8046934).
- [10] SULEJ W., MURAWSKI K., *The membrane shape mapping of the artificial ventricle in the actual dimensions*. 2017 Federated Conference on Computer Science and Information Systems (FedCSIS), Prague, 2017, pp. 675-680 (DOI: 10.15439/2017 F269).
- [11] OSSOWSKI S., *Sieci neuronowe do przetwarzania informacji*. OWPW, Warszawa, 2013.
- [12] ŻURADA J., BARSKI M., JĘDRUCH W., *Sztuczne sieci neuronowe: Podstawy teorii i zastosowania*. PWN, Warszawa, 1996.
- [13] RUMELHART, D. E., HINTON, G. E., WILLIAMS, R. J., *Learning representations by back-propagating errors*. Nature 323 (6088), 1986, pp. 533-536.
- [14] KWIATKOWSKI W., *Wstęp do cyfrowego przetwarzania sygnałów*. BEL Studio, Warszawa, 2012.
- [15] DAUBECHIES I., *Ten Lectures on Wavelets*. SIAM, Philadelphia, 1992.

Stroke volume determination of Ventricular Assist Device by neural network and wavelet transform coefficients

ABSTRACT: The paper presents results obtained during research, which are the continuation of work on the use of artificial neural networks to determine the relationship between the view of membrane and the stroke volume of the blood chamber of the mechanical pneumatic prosthetic heart. The purpose of the research was to increase the accuracy of determination the stroke volume of the blood chamber. Therefore, the study was focused on the technique of the features extraction from the image. Received results were compared to the results obtained previously using other methods. Tests were conducted on the same model of mechanical prosthetic heart, which have been used in previous experiments.

KEYWORDS: wavelet transform, artificial neural network, stroke volume, optical measurement

Praca wpłynęła do redakcji: 21.11.2017 r.

Niniejsza strona służy jedynie zachowaniu odstępu.