

WPLYW PARAMETRÓW SYGNAŁU PULSU ROGÓWKI OKA NA DOKŁADNOŚĆ WYKRYWANIA PULSU DYKROTYCZNEGO

IMPACT OF PARAMETERS OF CORNEAL PULSE SIGNAL ON ACCURACY OF DETECTION OF A DICROTIC PULSE

Tomasz Melcer^{1*}, Monika E. Danielewska¹, D. Robert Iskander¹

¹ Politechnika Wroclawska, Wydział Podstawowych Problemów Techniki,
Katedra Inżynierii Biomedycznej, 50-370 Wrocław, Wybrzeże Wyspiańskiego 27

* e-mail: tomasz.melcer@pwr.edu.pl

STRESZCZENIE

Występowanie dykrotycznego kształtu sygnału pulsu rogówki oka jest powiązane z procesem starzenia się i występowaniem jaskry. Dotychczas procedura wykrywania dykrotyzmu wymagała równoległego synchronicznego pomiaru pulsu rogówki oka, sygnału EKG i sygnału pulsu krwi, jednak nowe badania mogą pozwolić na detekcję dykrotyzmu tylko za pomocą pomiaru sygnału pulsu rogówki. Dokładność wykrywania dykrotyzmu zależy od parametrów sygnału wejściowego: długości i częstotliwości próbkowania. Z powodu odruchu mrugania u niektórych pacjentów trudno jest uzyskać odpowiednio długi sygnał nieobejmujący odruchu mrugania. Przeprowadzono eksperymenty numeryczne w celu określenia minimalnych wymagań rejestracji sygnału wejściowego w celu uzyskania odpowiedniej jakości klasyfikacji. Rezultaty wskazują na możliwość uzyskania dostatecznej jakości klasyfikacji sygnałów krótszych od 10 sekund pod warunkiem zapewnienia odpowiedniej częstotliwości próbkowania.

Słowa kluczowe: oczny puls dykrotyczny, analiza falkowa, tekstury, uczenie maszynowe

ABSTRACT

The presence of the ocular dicrotic pulse is associated with aging and the glaucoma incidence. Previous procedures for detecting ocular dicrotism required synchronous measurement of ECG and blood pulse signals. However, recent studies have offered an opportunity to detect ocular dicrotism from the corneal pulse signal alone. The accuracy of the detection procedure mainly depends on the input signal length and its sampling frequency. The acquisition of the corneal pulse signal is performed in suppress blinking conditions. Hence, it is often difficult to acquire a sufficiently long signal for the analysis. Numerical experiments were conducted to determine the minimum requirements of the input signal in order to obtain adequate classification rate. The results indicate the possibility of obtaining sufficient classification rates for signals shorter than 10 seconds provided an adequate sampling is maintained.

Keywords: ocular dicrotic pulse, wavelet analysis, texture, machine learning

1. Wstęp

Dykrotyzm oka jest nowo zaobserwowanym zjawiskiem związanym z występowaniem dwóch wyraźnych maksimów w kształcie sygnału pulsu rogówki przypadających na jeden cykl serca [1, 2]. Zarejestrowanie ocznego pulsu dykrotycznego (ODP, ang. *Ocular Dicrotic Pulse*) było możliwe dzięki zastosowaniu bezdotykowej, ciągłej i nieinwazyjnej metody pomiaru sygnałów pulsu oka [3, 4]. Sygnał ODP zarejestrowano u znacznej części osób zdrowych powyżej 50 roku życia (około 70%), natomiast nie zarejestrowano tego sygnału u przebadanych osób młodych (poniżej 35 roku życia). Najnowsze badania przeprowadzone w grupie pacjentów chorujących na jaskrę ujawniły częstsze występowanie dykrotyzmu oka u osób z jaskrą pierwotną otwartego i zamkniętego kąta, w porównaniu do kontrolnej grupy zdrowych osób. Ponadto, wykazano, że występowanie sygnału ODP wzrasta z wiekiem, a najwyższy wzrost odnotowano u osób z jaskrą. Tym samym potwierdzono, że dykrotyzm oka jest nie tylko naturalnym objawem starzenia się oka, ale może być również czynnikiem związanym z rozwojem jaskry.

Wykrycie dykrotyzmu oka w sygnale pulsu rogówki (CP, ang. *Corneal Pulse*) nie jest zadaniem trywialnym ze względu na jego niestacjonarny charakter. W surowym sygnale CP można wyróżnić takie składowe, jak sygnały o niskich częstotliwościach związane z procesem oddychania (około 0,2–0,3 Hz), składową odpowiadającą rytmowi serca (około 1 Hz) oraz jej kolejne składowe harmoniczne, także ograniczone w czasie zaburzenia sygnału związane m.in. z mruganiem oraz ruchami głowy. Częstotliwości wymienionych składowych mogą zmieniać się w czasie, np. pod wpływem wysiłku fizycznego lub emocji. Kilka technik stosowano w celu eliminacji niepożądanych częstotliwości z sygnału CP [5].

Jak dotąd, do detekcji sygnału ODP wykorzystywano algorytm dynamicznego dopasowania czasowego (DTW, ang. *Dynamic Time Warping*) [6], który wymagał synchronicznej z sygnałem CP rejestracji sygnałów aktywności sercowo-naczyniowej (sygnał pulsu krwi, EKG). Konieczność ta wynikała z kształtu sygnału CP, który jest sygnałem bardziej niestacjonarnym niż sygnały pracy serca oraz pozbawionym tak charakterystycznych i quasi-periodycznych cech, jak np. odstępy załamek $R-R'$ w sygnale EKG [7]. Ponadto, w przypadkach, w których przy użyciu algorytmu DTW nieprawidłowo uśredniono cechy sygnału CP, niezbędna była manualna korekcja. Stąd, zautomatyzowanie procesu detekcji sygnału ODP ma szczególne znaczenie, zwłaszcza w badaniach podłużnych uwzględniających znaczną liczbę pacjentów i danych pomiarowych sygnałów CP.

Celem niniejszej pracy jest zbadanie wpływu parametrów mierzonego sygnału, takich jak częstotliwość i długość, na jakość procedury detekcji dykrotyzmu oka wykorzystującej tylko sygnał CP. Dotychczas w badaniach rejestrowano sygnały o długości 10 s i częstotliwości 400 Hz. Nie każdy badany jest w stanie powstrzymać odruch mrugania na tak długi czas. Krótszy pomiar może być łatwiejszy do poprawnego przeprowadzenia, jednak może też niekorzystnie wpłynąć na poziom detekcji. Mniejszą ilość zebranych danych na temat pulsu oka można kompensować zwiększeniem częstotliwości próbkowania, która także wpływa na poziom detekcji sygnału ODP

2. Metodyka

Badana metoda wykrywania dykrotyzmu wyłącznie z sygnału pulsu rogówki oka opiera się na szeregu operacji na cyfrowym zapisie sygnału pulsu rogówki oka, zebranych za pomocą bezdotykowego pomiaru z użyciem ultradźwiękowego czujnika odległości. Pierwszym krokiem jest wyznaczenie ciągłej transformaty falkowej sygnału wejściowego [8]. Wynik transformaty jest następnie traktowany jako tekstura, której cechy statystyczne są wyznaczane za pomocą metody macierzy współwystępowania poziomów intensywności (GLCM, ang. *Gray-level Co-occurrence Matrix*) [9]. W ostatnim kroku, statystyki wyznaczone dla sygnałów pochodzących od wielu pacjentów, są wykorzystywane w celu zbudowania modelu klasyfikacji sygnałów na dykrotyczne i niedykrotyczne. Dokładność algorytmu klasyfikacji, zbudowanego w ostatnim kroku metody, jest testowana za pomocą metody bootstrap 632+ [10].

2.1. Pomiar pulsu rogówki oka

W poniższej pracy użyto danych zebranych w trakcie badań dotyczących diagnostyki jaskry (zgoda komisji bioetycznej Uniwersytetu Medycznego we Wrocławiu, KB 481/2009). Dane personalne osób badanych zostały usunięte przed analizą statystyczną. W zbiorze danych znajdują się sygnały pulsu rogówki oka 261 badanych: 191 pacjentów Kliniki Jaskry (Uniwersytet Medyczny we Wrocławiu) i 70 osób zdrowych, stanowiących grupę kontrolną. Sygnały zostały podzielone do celów budowania modeli klasyfikacji na dykrotyczne i niedykrotyczne z użyciem synchronicznie zbieranych sygnałów EKG i pulsu krwi [2].

2.2. Analiza czasowo-częstotliwościowa

Sygnał pulsu rogówki oka jest sygnałem niestacjonarnym [11]. Co prawda, odwzorowany jest w nim cykl pracy serca, mający charakter okresowy, jednakże sygnał jest zaburzony czynnikami wynikającymi z metody pomiaru czujnikiem odległości. Zaburzenia wynikają między innymi z ruchów głowy (minimalizowanych poprzez ustabilizowanie w uchwycie, ale nieusuwanym), mrugnięć, błędów pomiarowych, itd. Sam cykl pracy serca też nie jest ściśle okresowy, bo długość cyklu zmienia się z powodu oddychania, wysiłku fizycznego czy stanów emocjonalnych.

To wszystko utrudnia analizę sygnału metodami częstotliwościowymi, np. metodą transformaty Fouriera. Analiza częstotliwościowa jest odpowiednia dla sygnałów stacjonarnych, bo te sygnały mają stabilne, łatwe do wyizolowania składowe o stałych częstotliwościach. W sygnałach niestacjonarnych występują zaburzenia miejscowe (w przypadku sygnału pulsu rogówki oka przykładem jest mrugnięcie), a ważne z punktu widzenia analizy składowe zmieniają swoje częstotliwości (np. zmiany długości cyklu pracy serca). Gdy stosujemy analizę czasowo-częstotliwościową, otrzymujemy informacje nie tylko o tym, jakie częstotliwości występowały w sygnale, ale też kiedy się pojawiały. To pozwala nam śledzić, jak częstotliwości składowych sygnału zmieniają się w kolejnych momentach.

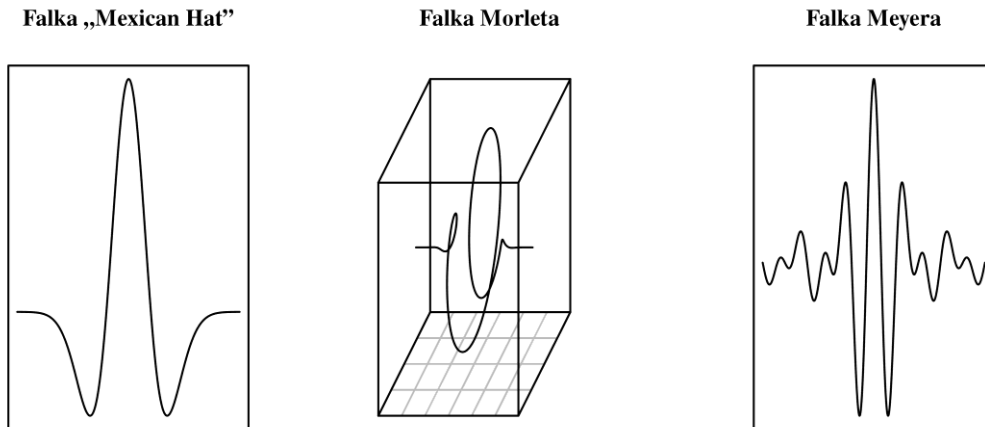
2.3. Ciągła transformata falkowa

Ciągła transformata falkowa jest przykładem metody czasowo-częstotliwościowej, często stosowanej dla sygnałów wykazujących podobieństwa do sygnałów okresowych, jednak w istocie będących niestacjonarnymi sygnałami [8]. Metoda ta ma wiele zastosowań w naukach biologicznych, w tym np. w analizie przepływu krwi [12, 13].

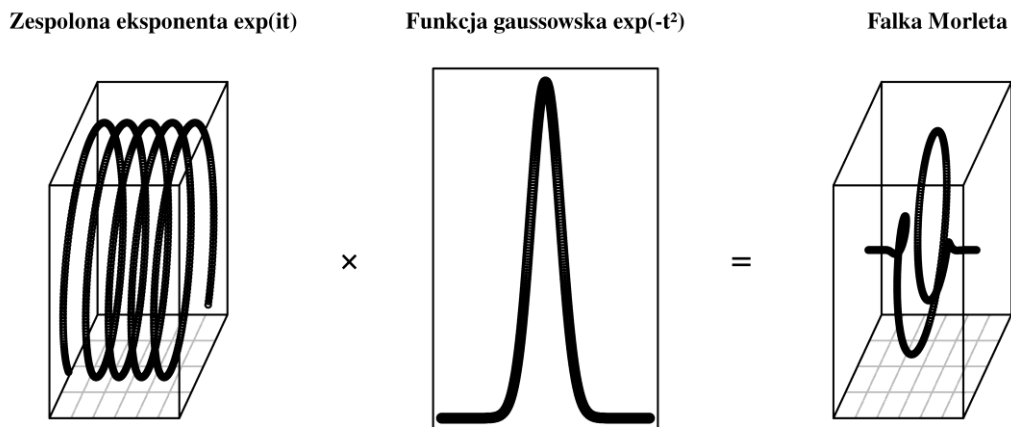
Transformata falkowa bazuje na funkcji zwanej falką-matką, która może być wybrana w zależności od cech sygnału, które są badane. Falka-matka może być dowolnym rzeczywistym lub zespolonym sygnałem, o ile ma ograniczony nośnik (tj. przyjmuje niezerowe wartości tylko w określonym ograniczonym przedziale) i jego całka jest równa zero. W szczególności, nie musi być funkcją ciągłą, choć w naszych rozważaniach ograniczymy się do ciągłych falek. Rysunek 1 przedstawia przykłady sygnałów spełniających te założenia, często używanych w praktyce: falka „Mexican hat” (zwana też falką Rickera), falka Morleta (zwana też falką Gabora) i falka Meyera [14], [15, 16].

Do wykrywania podwójnego sygnału pulsu rogówki oka wybraliśmy falkę Morleta. Rysunek 2 przedstawia konstrukcję tej falki: zespolona funkcja eksponencjalna e^{it} modulowana funkcją gaussowską e^{-t^2} .

Po wybraniu falki-matki tworzy się rodzinę sygnałów dyskretnych zwanych falkami, parametryzowaną parametrem skali s poprzez przesunięcie w czasie, przeskalowanie, unormowanie i próbkowanie funkcji falki-matki tak, aby norma L^1 wynikowego sygnału była równa 1, sygnał był niezerowy na przedziale długości s próbek i wycentrowany w czasie $t = 0$.



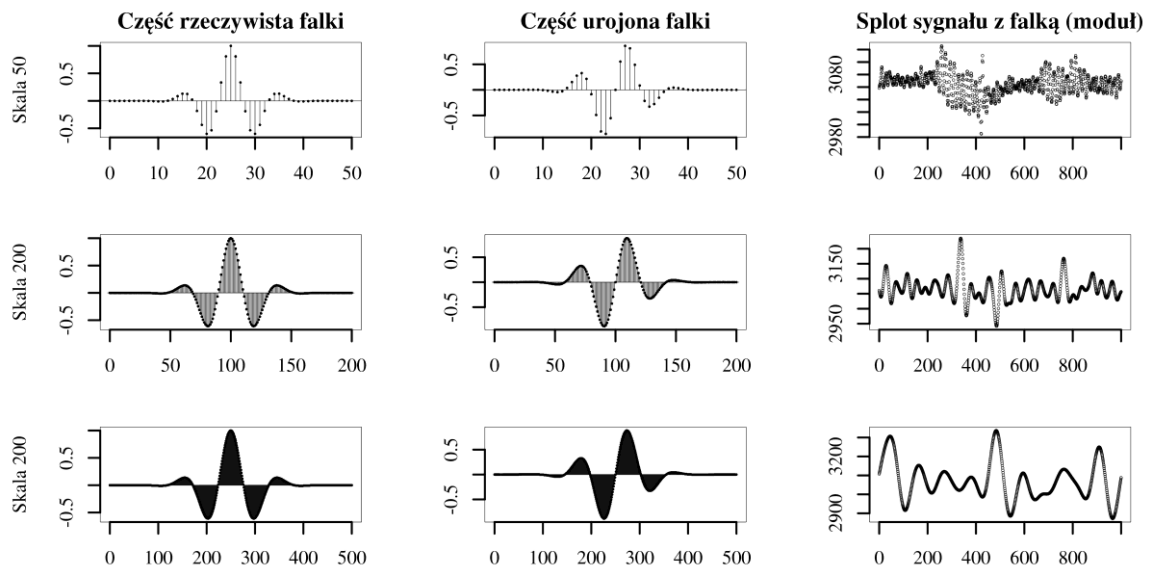
Rys. 1. Przykłady sygnałów spełniających warunki dla funkcji falek-matek



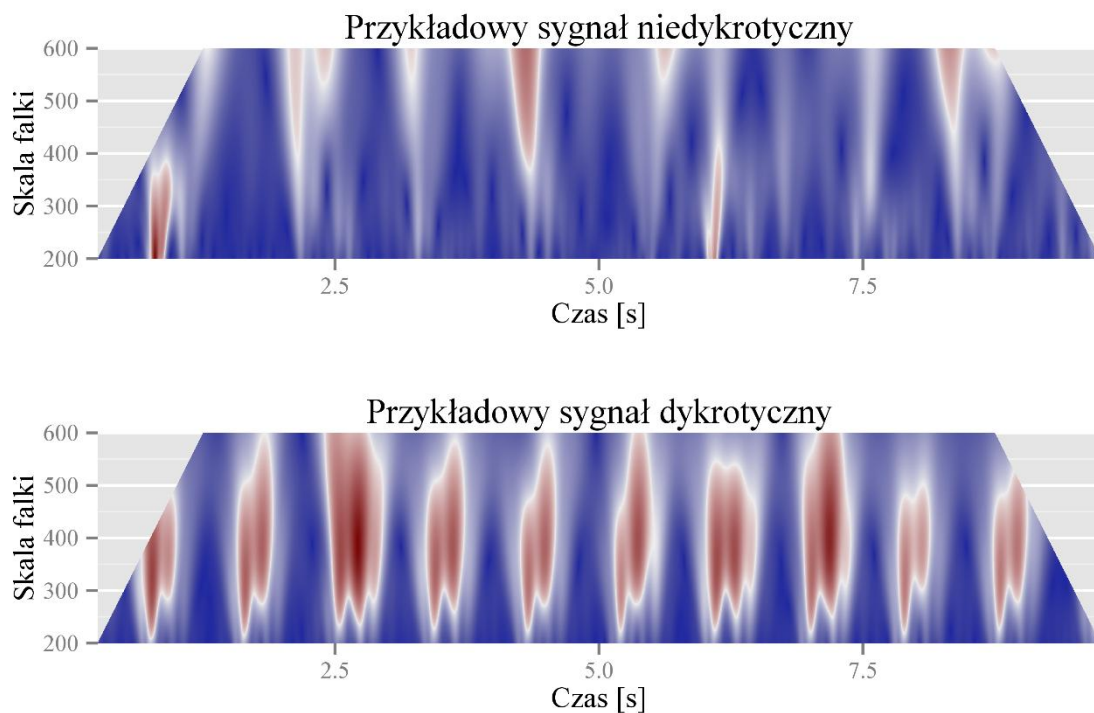
Rys. 2. Konstrukcja falki Morleta

Operacja wyznaczenia ciągłej transformaty falkowej polega na wyznaczeniu splotów sygnału wejściowego z sygnałami kolejnych falek o różnych skalach. Wartości skal użytych do wyznaczania splotów zazwyczaj się wybiera na zasadzie równoodległych punktów w zadanym przedziale, według skali liniowej lub logarytmicznej. Wybór przedziału jest podobny do zastosowania filtra pasmowego – każda skala odpowiada (do pewnego stopnia, zależnie od wybranej falki-matki) pewnej częstotliwości, więc jeśli decydujemy się na wąski przedział skal, częstotliwości odpowiadające skalom spoza wybranego przedziału nie będą reprezentowane w wyniku. Na rysunku 3 przedstawiono przykłady splotów falek o różnych skalach z fragmentem rzeczywistego sygnału pulsu rogówki oka. Można zwrócić uwagę na fakt, że im większa skala falki, tym sygnał splotu jest bardziej regularny.

Wynik transformaty można przedstawić w postaci mapy ciepła, której kolejne wiersze odpowiadają splotom wyznaczonym dla kolejnych skal. W przypadku falki zespolonej wizualizacji można poddać zarówno część rzeczywistą i urojoną, jak i moduł i argument obliczonej transformaty. Rysunek 4 prezentuje mapy ciepła modułu ciągłej transformaty falkowej dla dwóch sygnałów pulsowania rogówki oka: sygnału niedykrotycznego i dykrotycznego. Widoczne na mapie ciepła przygotowanej na podstawie sygnału dykrotycznego *semi*-regularne regiony o wysokiej intensywności w skalach 300–500 są podstawową cechą charakterystyczną wyniku transformaty falkowej dla sygnałów dykrotycznych [5].



Rys. 3. Przykłady splotów falek o różnych skalach z sygnałem pulsu rogówki oka



Rys. 4. Przykłady wizualizacji ciągłej transformaty falkowej dla falki Morleta i sygnałów pulsu rogówki oka: niedykrotycznego i dykrotycznego

Tak wyznaczona transformata ma szereg właściwości matematycznych, upraszczających analizę sygnału pulsu rogówki oka:

- Ponieważ splot można wyznaczyć za pomocą algorytmu szybkiej transformaty Fouriera, złożoność obliczeniowa wyznaczania transformaty to $O(w n \log n)$, gdzie w to ilość wartości skal wybranych do obliczenia transformaty, a n to długość sygnału.
- Transformata stałego sygnału jest równa zero. To konsekwencja założenia, że całka falki-matki jest równa zero.
- Transformata jest systemem liniowym niezmienniczym w czasie. Ta właściwość wynika wprost z definicji transformaty jako zbioru splotów. Jednym z ważniejszych wniosków

wynikających z tej własności jest fakt, że transformata ignoruje stałą składową.

- Addytywny szum w oryginalnym sygnale jest reprezentowany w wyniku transformaty jako addytywny szum o standardowym odchyleniu przemnożonym przez normę L^2 sygnału falki. Jednak norma L^1 falki jest równa 1, więc norma L^2 falki jest mniejsza niż 1 i transformata efektywnie osłabia wpływ szumu.

2.4. Macierz współwystępowania poziomów intensywności

W naszej pracy przyjęliśmy, że mapa ciepła, wyznaczona jako rezultat ciągłej transformaty falkowej, jest traktowana jako tekstura, której parametry statystyczne identyfikuje się poprzez zbudowanie macierzy współwystępowania poziomów intensywności [9]. Teksturę kwantyzuje się do małej liczby poziomów. W badanym algorytmie użyto 8 poziomów intensywności. Następnie tworzy się kwadratową macierz, gdzie na (i, j) -tej pozycji umieszcza się liczbę par pikseli tekstury, które sąsiadują ze sobą w pewnej horyzontalnej odległości, piksel po lewej ma poziom i , a piksel po prawej ma poziom j . Badany algorytm wybierał odległość tak, aby – zależnie od wybranej częstotliwości – odpowiadał w przybliżeniu 1/16 sekundy. Wyznaczane cechy statystyczne to entropia, homogeniczność, kontrast i współczynnik korelacji.

2.5. Klasyfikacja

Do klasyfikacji użyto algorytmu lasów losowych, implementacji z pakietu *randomForest* [17, 18]. Użyty algorytm został przetestowany za pomocą metody bootstrap 632+, wyznaczającej statystykę dokładności klasyfikacji i jej standardowe odchylenie [10]. Wykorzystano implementację tej metody z pakietu *caret* [19]. Należy tu zaznaczyć, że w zbiorze danych 72% przypadków stanowią sygnały dykrotyczne. To oznacza, że dokładność na poziomie 72% jest tu traktowana jako efekt losowy. Algorytm klasyfikacji musi wykazać się dokładnością różniącą się w statystycznie istotny sposób od tego poziomu, aby został uznany za efektywny.

2.6. Pomiar wpływu parametrów sygnału na jakość klasyfikacji

Badanie wpływu parametrów sygnału na jakość klasyfikacji odbyło się poprzez wielokrotne powtórzenie powyższej procedury po dokonaniu wstępnego przetworzenia sygnału poprzez decymację (ang. *downsampling*) i skrócenie sygnału do testowanej długości.

Decymacja polega na usuwaniu z sygnału wejściowego próbek tak, aby pozostała tylko co n -ta próbka; n nazywa się współczynnikiem decymacji. Ponieważ oryginalne sygnały mają częstotliwość 400 Hz i długość 4000 próbek, na przykład pozostawiając tylko co czwartą próbkę (współczynnik decymacji $n = 4$), otrzymamy sygnał o długości 1000 próbek, symulujący pomiar z częstotliwością 100 Hz. Ta procedura była zastosowana dla $n = 1, \dots, 100$.

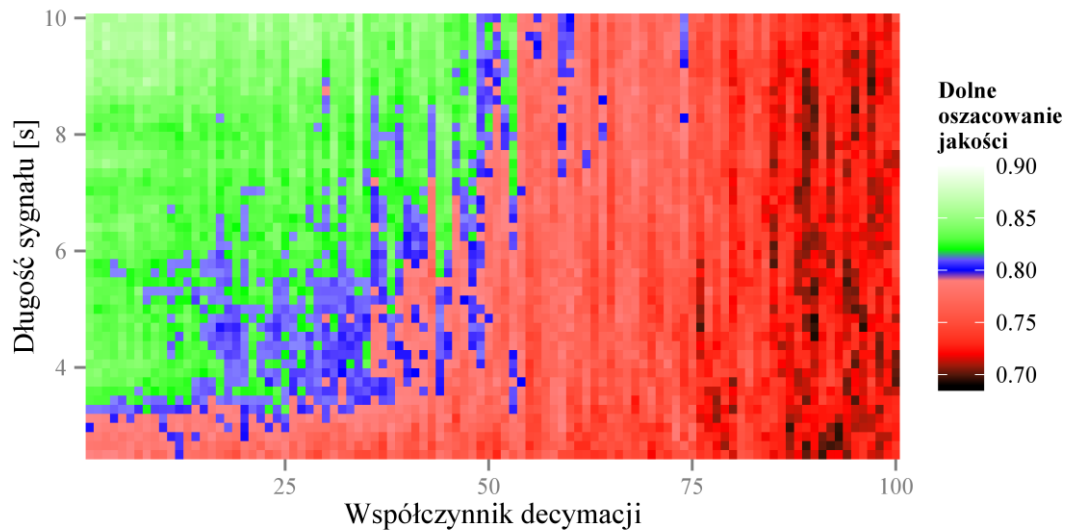
Oryginalne sygnały miały długość 10 sekund. W celu oceny wpływu długości sygnału na jakość klasyfikacji oryginalny sygnał był skracany do długości między 2,5 s i 10 s.

Dla każdego współczynnika decymacji i dla każdej długości sygnału przygotowano zbiór danych do oszacowania błędu klasyfikacji badanej metody. Wyniki przedstawiono w postaci mapy ciepła prezentującej poziom dwóch odchyłeń standardowych poniżej wyznaczonej dokładności. Ten poziom traktujemy jako akceptowalne dolne ograniczenie oszacowania dokładności klasyfikacji. Wynik powyżej poziomu 80% traktujemy jako dobry. Wyznaczone standardowe odchylenie oszacowania dokładności klasyfikacji także zostało przedstawione w postaci mapy ciepła.

3. Wyniki

Na rysunku 5 przedstawiono zależność dokładności klasyfikacji od długości sygnału i współczynnika decymacji. Obserwujemy silną zależność między długością sygnału i współczynnikiem decymacji niezbędnymi do otrzymania dobrych efektów klasyfikacji. Dla współczynnika decymacji $n < 10$ (odpowiadającym sygnałom o częstotliwościach próbkowania powyżej 40 Hz) wystarcza sygnał o długości 3 sekund do uzyskania klasyfikacji na dobrym poziomie. Powyżej współczynnika decymacji $n = 50$ (odpowiadającego sygnałowi o częstotliwości próbkowania 8 Hz i niższym)

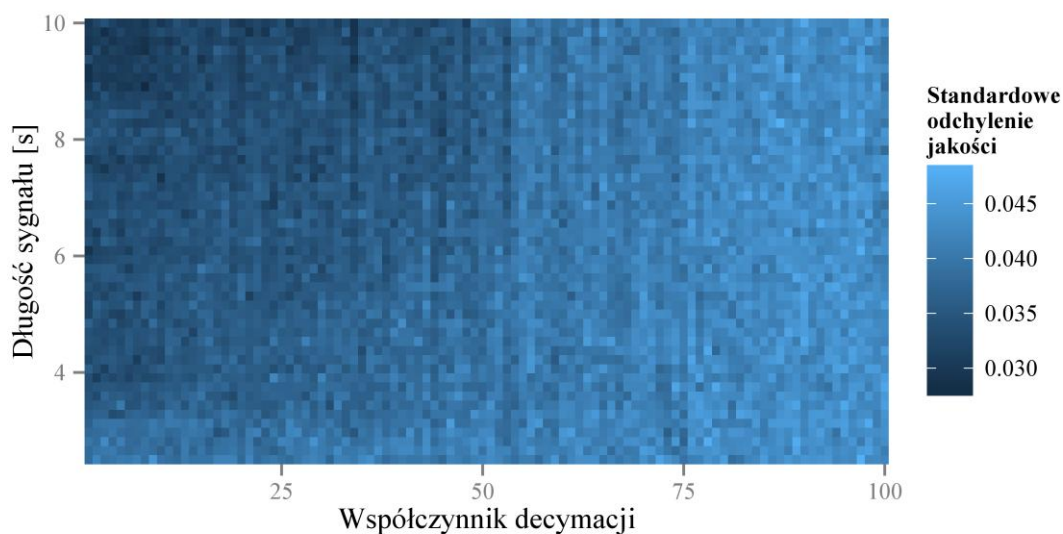
klasyfikacja nie różni się istotnie od poziomu uznanego za szum losowy niezależnie od długości sygnału. Pomiędzy tymi dwoma programami można zauważyć, że krótszy sygnał można skompensować wyższą częstotliwością próbkowania w celu zachowania odpowiedniego poziomu klasyfikacji.



Rys 5. Zależność jakości detekcji dykrotycznego pulsu od długości i współczynnika decymacji oryginalnego sygnału

Występujące na obrazie charakterystyczne pionowe linie wskazują na zaokrąglenia wynikające z trudności odwzorowania przedziału 1/16 sekundy przy obliczaniu macierzy współwystępowania poziomów intensywności.

Rysunek 6 przedstawia zależność błędu oszacowania jakości klasyfikacji od długości sygnału i współczynnika decymacji. Zauważono, że wyznaczone standardowe odchylenie dokładności klasyfikacji waha się w granicach 2,8–5%. Zebrane dane wskazują na systematyczne poprawianie się jakości oszacowania dokładności klasyfikacji dla wyższych częstotliwości i dłuższych sygnałów. Jednocześnie można zwrócić uwagę na fakt, że różnice błędu oszacowania w obszarze dobrych efektów klasyfikacji nie są duże. Może to oznaczać, że dalsze wydłużanie sygnału lub zwiększenie częstotliwości nie spowoduje znaczącej poprawy błędu oszacowania.



Rys 6. Zależność standardowego odchylenia jakości detekcji dykrotycznego pulsu od długości i współczynnika decymacji oryginalnego sygnału

4. Podsumowanie

Podstawowy problem wynikający z metody pomiaru wynika z odruchu mrugania. Praktyka pokazuje, że pomiar trwający 10 s to najdłuższy pomiar, który może być przeprowadzony efektywnie u większości pacjentów. Niektórzy badani mają jednak trudności z wstrzymaniem się od mrugania nawet na tak krótki okres czasu. Przeprowadzone symulacje wskazują na to, że przy zastosowaniu obecnie posiadanej aparatury można stosować krótsze pomiary bez znacznej straty na jakości klasyfikacji.

Jednocześnie można zauważyć, że czujniki ultradźwiękowe pracujące z częstotliwością próbkowania na poziomie 40 Hz mogą być wystarczające do wykonania pomiarów. Nie zaobserwowano dużych różnic w poziomie klasyfikacji pomiędzy sygnałem spróbkowanym z częstotliwością 40 Hz i 400 Hz. To pozwala sądzić, że potencjalne przyszłe wdrożenie procedury badania dykrotyzmu pulsu oka do zastosowań klinicznych będzie wymagać mniej specjalistycznej aparatury, a co za tym idzie też tańszej.

LITERATURA

- [1] M.E. Danielewska, D.R. Iskander, P. Krzyżanowska-Berkowska: *Age-related changes in corneal pulsation: Ocular dicrotism*, Optometry & Vision Science, vol. 91(1), 2014, s. 54–59.
- [2] M.E. Danielewska, P. Krzyżanowska-Berkowska, D.R. Iskander: *Glaucomatous and age-related changes in corneal pulsation shape. The ocular dicrotism*, PloS One, vol. 9(7), 2014, e102814.
- [3] M.A. Kowalska, H.T. Kasprzak, D.R. Iskander, M.E. Danielewska, D. Mas: *Ultrasonic in vivo measurement of ocular surface expansion*, IEEE Transactions on Biomedical Engineering, vol. 58(3), 2011, s. 674–680.
- [4] T.J. Licznarski, J. Jaroński, D. Kosz: *Ultrasonic system for accurate distance measurement in the air*, Ultrasonics, vol. 51(8), 2011, s. 960–965.
- [5] T. Melcer, M.E. Danielewska, D.R. Iskander: *Wavelet representation of the corneal pulse for detecting ocular dicrotism*, PloS One (w produkcji).
- [6] H. Sakoe, S. Chiba: *Dynamic programming algorithm optimization for spoken word recognition*, IEEE Transactions on Acoustics, Speech and Signal Processing, vol. 26(1), 1978, s. 43–49.
- [7] A. Angelone, N.A. Coulter: *Respiratory sinus arrhythmia: a frequency dependent phenomenon*, Journal of Applied Physiology, vol. 19(3), 1964, s. 479–482.
- [8] C. Gargour, M. Gabrea, V. Ramachandran, J.M. Lina: *A short introduction to wavelets and their applications*, IEEE circuits and systems magazine, vol. 9(2), 2009, s. 57–68.
- [9] R.M. Haralick, K. Shanmugam, I.H. Dinstein: *Textural features for image classification*, IEEE Transactions on Systems, Man and Cybernetics, vol. 6, 1973, s. 610–621.
- [10] B. Efron, R. Tibshirani: *Improvements on cross-validation: the 632+ bootstrap method*, Journal of the American Statistical Association, vol. 92(438), 1997, s. 548–560.
- [11] H. Kasprzak, D.R. Iskander: *Spectral characteristics of longitudinal corneal apex velocities and their relation to the cardiopulmonary system*, Eye, vol. 21(9), 2007, s. 1212–1219.
- [12] M. Unser, A. Aldroubi: *A review of wavelets in biomedical applications*, Proceedings of the IEEE, vol. 84.4, 1996, s. 626–638.
- [13] M. Bracic, A. Stefanovska: *Wavelet-based analysis of human blood-flow dynamics*, Bulletin of Mathematical Biology, vol. 60(5), 1998, s. 919–935.
- [14] H. Ryan: *Ricker, Ormsby, Klauder, Butterworth-A choice of wavelets*, Hi-Res Geoconsulting, 1994, s. 24–25.
- [15] D. Gabor: *Theory of communication. Part I: The analysis of information*, Journal of the Institution of Electrical Engineers - Part III: Radio and Communication Engineering, vol. 93(26), 1946, s. 429–441
- [16] I. Daubechies: *Ten lectures on wavelets*, Society for industrial and applied mathematics, Philadelphia, 1992.
- [17] L. Breiman: *Random forests*, Machine learning, vol. 45(1), 2001, s. 5–32.
- [18] A. Liaw, M. Wiener: *Classification and Regression by randomForest*, R news, vol. 2, 2002, s. 18–22.
- [19] M. Kuhn: *Building predictive models in R using the caret package*, Journal of Statistical Software, vol. 28, 2008, s. 1–26.

otrzymano/submitted: 15.12.2014
zaakceptowano/accepted: 15.03.2015