

Michał BOLTRUKIEWICZ

POLITECHNIKA POZNAŃSKA, INSTYTUT ELEKTROTECHNIKI I ELEKTRONIKI PRZEMYSŁOWEJ,
ul. Piotrowo 3a, 60-965 Poznań

Detekcja błędów segmentacji sygnału fotopletyzmo­graficznego

Dr inż. Michał BOLTRUKIEWICZ

Ukończył studia na kierunku Automatyka i Robotyka (1994). Stopień doktora nauk technicznych uzyskał w 2003 roku. Od 1995 roku jest pracownikiem Politechniki Poznańskiej, obecnie na stanowisku adiunkta w Zakładzie Metrologii i Optoelektroniki. W pracy naukowej zajmuje się pomiarami i przetwarzaniem sygnałów biologicznych oraz konstrukcją elektronicznych przetworników sygnałów.



e-mail: boltruk@et.put.poznan.pl

Streszczenie

Tematyka pracy związana jest z analizą zmienności rytmu serca, a dotyczy w szczególności detekcji błędów powstających podczas segmentacji - procedury wyznaczającej zbiór okresów przebiegu. W artykule omówiono i zilustrowano podstawowe przyczyny błędów segmentacji. Zaproponowano dwa algorytmy detekcyjne wykorzystujące statystyczne przedziały tolerancji, które następnie przetestowano i oceniono przy użyciu posiadane­go zbioru 5-minutowych przebiegów sygnału fotopletyzmo­graficznego.

Słowa kluczowe: błąd segmentacji, wskaźnik błędów, sygnał fotopletyzmo­graficzny, zmienność rytmu serca, przedziały tolerancji, czułość, specyficzność.

The detection of segmentation errors in a photoplethysmographic signal**Abstract**

The paper concerns the detection of segmentation errors in a photoplethysmographic signal (PPG). In the paper, the causes of segmentation errors are considered. The technical causes are presented in Figs. 1 and 2 while the biological causes are shown in Fig. 3. Two algorithms of detection of errors are proposed. Both algorithms use statistical tolerance ranges, which are described by Eq. 1. The principles of operation of these algorithms are given in Eqs. 2 and 3. In the study the efficiency of these algorithms was evaluated using the factor of errors defined by Eq. 4. For both algorithms the sensitivity (SE), specificity (SP) and positive prediction value (PPV) and negative prediction value (NPV) were calculated, too. In the experiments real photoplethysmographic signals were analyzed. Time duration of each signal was equal to 5 min. The coefficients of errors obtained for both algorithms are presented in Fig. 4. The comparison of the sensitivity and the positive prediction value is shown in Fig. 5. The causes of differences between the obtained values of the coefficients are considered. The possibility of improvement of SE and PPV is also analyzed.

Keywords: error of segmentation, factor of errors, photoplethysmographic signal (PPG), heart rate variability (HRV), ranges of tolerance, sensitivity, specificity.

1. Wprowadzenie

Sygnał fotopletyzmo­graficzny (ang. PPG) stanowi odpowiedź optyczną ukrwionych tkanek poddanych transiluminacji. Jego podstawową składową jest fala tętna, powstająca w układzie krwionośnym wskutek cyklicznych zmian ciśnienia krwi i propagująca średnią ze prędkością wynoszącą 7 m/s[1].

Nieinwazyjność oraz nieskomplikowana i dobrze zoptymalizowana metoda pozyskiwania implikują opisane w [2] i [3] szerokie spektrum aplikacji klinicznych sygnału fotopletyzmo­graficznego. Obejmuje ono przede wszystkim pomiar saturacji tlenowej krwi SpO₂[4], a ponadto ocenę ciśnienia tętniczego krwi, badanie właściwości dynamicznych naczyń krwionośnych oraz badanie zmienności rytmu serca, którego wyniki są dobrze skorelowane z wynikami uzyskiwanymi przy użyciu sygnału elektrokardiograficznego co zostało wykazane w [5].


Najważniejszym etapem przygotowania danych do prowadzonych badań zmienności rytmu serca[6] jest segmentacja – procedura podziału przebiegu fotopletyzmo­graficznego na podzbiory zawierające pojedyncze okresy sygnału, nazywana też w piśmiennictwie pomiarem okresu. Jej skuteczność zdeterminowana jest wrażliwością na obecność zakłóceń, do których należą: wolno­zmienna składowa oddechowa powodująca okresowe zmiany wartości średniej sygnału fotopletyzmo­graficznego oraz tzw. artefakty ruchowe – zakłócenia powstające wskutek ruchu prze­świetlanego obszaru tkanek.

Procedury segmentacji, charakteryzujące się niewielką złożono­ścią obliczeniową, działają na zasadzie porównania przebiegu z wartością progową. Do jej wyznaczenia można wykorzystać średnią bieżącą przebiegu, obliczaną w przedziale czasu dostoso­wanym do bieżących charakterystyk sygnału, co pozwala na poprawne wyznaczenie do 94% okresów przebiegu[7]. Alternatywą dla wykorzystania wartości progowej jest opisana w [8] dwuetapowa procedura obejmująca cyfrową filtrację pasmowo­przepustową sygnału, a następnie lokalizację tzw. „przejsz przez zero”. Procedury pomiaru okresu sygnału fotopletyzmo­graficznego wykorzystują także przebiegi jego pochodnych, posiadające jedno lub dwa dominujące ekstrema, które można następnie wykrywać przy użyciu detekcji progowej. Rozwiązanie to charakteryzuje się dużą skutecznością czego dowodzi opisana w [9] procedura wykorzystująca drugą pochodną sygnału fotopletyzmo­graficznego, dla której uzyskana empirycznie czułość wynosi 1. Do segmentacji można także wykorzystać analizę wielorozdzielczą sygnału (jedna z metod realizacji dyskretnej transformaty falkowej) co zaprezentowano w przytaczanej już pracy [7] oraz w [10]. Pomimo różnic implementacyjnych obie procedury charakteryzowały się dużą skutecznością działania wyznaczając poprawnie odpowiednio 98% i 97% okresów przebiegu.

W początkowej fazie eksperymentów, w których wykorzystywano segmentację z wartością progową obliczaną przy użyciu bieżącej wartości średniej zaobserwowano, że przeciętnie 5% uzyskiwanych w ten sposób okresów było wyznaczanych niepoprawnie. Wobec relatywnie niewielkiej liczby błędów zrezygnowano z implementowania skuteczniejszej i zarazem bardziej złożonej obliczeniowo procedury segmentacji na rzecz rozwiązania alternatywnego obejmującego: detekcję, klasyfikację i korektę błędów segmentacji.


2. Błędy podziału zbioru próbek

Wspólną cechą zbiorów zawierających okresy sygnału fotopletyzmo­graficznego są niewielkie różnice pomiędzy wartościami ich kolejnych elementów. Podczas badań związanych ze zmiennością rytmu serca zaobserwowano, że w wykorzystywanych zbiorach danych znajdują się pojedyncze elementy, których wartości znacząco różnią się od pozostałych. Ich obecności nie potwierdzała jednak analiza przebiegu sygnału co oznaczało, że zostały one utworzone podczas segmentacji co zilustrowano na rys. 1 i rys. 2.



Rys. 1. Zbyt mała wartość progowa
Fig. 1. The threshold value is too small


W przebiegu pokazanym na rys. 1 kształt jednego z jego okresów nieznacznie różni się od pozostałych. W konsekwencji wartość okresu uzyskana w miejscu wskazanym szarą strzałką, jest nieadekwatna do przebiegu sygnału.



Rys. 2. Chwilowa zmiana amplitudy sygnału fotepletyzmaograficznego
Fig. 2. Momentary change in the amplitude of the PPG signal

Fragment przebiegu, który na rys. 2 wskazuje szara strzałka jest typowym artefaktem ruchowym, który charakteryzuje się chwilową lecz relatywnie dużą zmianą amplitudy. Jest on spowodowany wzajemnymi ruchami czujnika i prześwietlanego obszaru tkanek, które w konsekwencji wywołują zmiany w typowym przebiegu sygnału. W efekcie wyznaczona w tym miejscu wartość okresu dwukrotnie przewyższa wartość faktyczną.

Na rys. 3, pokazano natomiast przebieg sygnału fotepletyzmaograficznego, w którym brakuje kolejnego okresu fali tętna (w miejscu pokazanym szarą strzałką). Podobnie jak w przypadku pokazanym na rys. 2, wyznaczona w tym miejscu wartość okresu jest około dwukrotnie większa od pozostałych. Opisana sytuacja nie jest jednak spowodowana niedoskonałością procedury segmentacji lecz wynika z przyczyn biologicznych i może wskazywać na niektóre zaburzenia pracy serca.



Rys. 3. Brak kolejnego okresu sygnału fotepletyzmaograficznego
Fig. 3. Absence of the next period in the PPG signal

Jedną z głównych przyczyn występujących błędów są wady algorytmu segmentacji polegające na zbyt wolnej adaptacji lub braku reakcji na zmiany zachodzące w analizowanym przebiegu. Zaistniały problem można próbować rozwiązać wykorzystując inną metodę segmentacji co jednak nie daje gwarancji uniknięcia błędów, zwłaszcza jeżeli są one spowodowane przez czynniki biologiczne.

3. Detekcja błędów segmentacji

Ze względu na znaczące rozmiary analizowanych zbiorów danych (5-minutowe zapisy sygnału fotepletyzmaograficznego, zawierające od 300 do 500 okresów) założono, że algorytm detekcji, podobnie jak algorytm segmentacji, będzie pracował automatycznie, a wynikiem jego pracy będzie informacja o liczbie błędów i ich lokalizacji w przebiegu. Przyjęto również, że klasyfikacja i poprawa błędów będą wymagały udziału człowieka.

Do detekcji błędów segmentacji wykorzystano autorski algorytm, opisany w przytaczanym już artykule [7]. Ponieważ różnice pomiędzy wartościami kolejnych, następujących po sobie okresów sygnału fotepletyzmaograficznego nie są znaczące, założono, że oznaczona symbolem T_n wartość aktualnie testowanego okresu będzie spełniała zależność

$$T_n \in (\bar{T} - k(Q, q) \cdot S, \bar{T} + k(Q, q) \cdot S) \quad (1)$$

w której wyrażenie w nawiasie jest przedziałem tolerancji [11] obliczanym na podstawie 60 poprzednich wartości okresu. Stanowi on statystyczny model zmienności okresu badanego przebiegu i określa dopuszczalne granice zmienności tego parametru, determinując tym samym działanie algorytmu detekcji błędów. Występujące w zależności zmienne oznaczone jako T i S oznaczają odpowiednio wartość średnią i odchylenie standardowe, a $k(Q, q)$ jest współczynnikiem przedziału tolerancji odczytywanym z tablic statystycznych [12] przy założeniu, że granice szacowanego przedziału obejmą przynajmniej $Q\%$ wyników z prawdopodobieństwem równym $q\%$.

Działanie algorytmu detekcji błędów segmentacji polegało na testowaniu zależności

$$|T_n - \bar{T}| \leq k(Q, q) \cdot S \quad (2)$$

w której przewidywaną wartością bieżącego okresu była wartość średnia. Przyjmowano, że jeżeli zależność (2) nie była spełniona to oznaczało to wystąpienie błędu segmentacji.

W pracy testowano również algorytm alternatywny, w którym wartością przewidywaną była wartość poprzedniego okresu sygnału oznaczona jako T_{n-1} . W tym przypadku testowane wyrażenie miało postać daną zależnością

$$|T_n - T_{n-1}| \leq k(Q, q) \cdot S \quad (3)$$

Analogicznie jak w przypadku poprzedniego algorytmu, jeżeli zależność (3) nie była spełniona, uznawano że doszło do wystąpienia błędu segmentacji.

4. Analiza wyników

Celem przeprowadzanych eksperymentów obliczeniowych było: sprawdzenie przydatności obu algorytmów detekcji błędów z ewentualnym wskazaniem lepszego z nich oraz określenie optymalnej wartości współczynnika przedziału tolerancji $k(Q, q)$.

W badaniach wykorzystywano 5-minutowe zapisy sygnału fotepletyzmaograficznego. Były one pozyskiwane przy użyciu napalcowego czujnika optoelektronicznego współpracującego z pulsooksymetrem Oxypeth firmy Novamatrix i przesyłane do komputera PC przy użyciu interfejsu RS232. Transmitowane przebiegi były próbkowane z częstotliwością 50 Hz i skalowane do przedziału wartości od 0 do 99. Aby zminimalizować udział artefaktów ruchowych sygnały testowe pozyskiwano w warunkach sportowych, zwracając szczególną uwagę na unikanie ruchów czujnika. Przed rozpoczęciem badań każdy z przebiegów był poddawany segmentacji przy użyciu metody ze stałą wartością progową, której wartość obliczano na podstawie średniej bieżącej. Detekcję błędów realizowano zgodnie z zależnościami (2) oraz (3), w których wykorzystywano 12 wartości współczynnika $k(Q, q)$ z zakresu od 1,887 do 4,206 (dla Q i q , równych odpowiednio 90%, 95%, 99% i 99,9% oraz 90%, 95% i 99%).

Do oceny jakości pracy algorytmu detekcji błędów segmentacji wykorzystywano procentowy wskaźnik błędów dany zależnością


$$d_{1,2} = \frac{m}{n} \cdot 100\% \quad (4)$$

w której m oznacza liczbę wykrytych błędów segmentacji, n jest liczbą okresów badanego przebiegu, a indeksy 1 oraz 2 dotyczą odpowiednio algorytmu opisanego zależnościami (2) oraz (3).

W celu dokładnego zbadania obu algorytmów dokonano łącznej oceny wyników segmentacji 5 plików, które „sztucznie” połączono otrzymując populację liczącą 1949 elementów.

Na rys. 4 pokazano wartości wskaźników błędów segmentacji uzyskane dla testowanej populacji, zaznaczając kolorem szarym wynik uzyskany dla algorytmu opisanego zależnością (2), nato-

miast kolorem czarnym wynik uzyskany dla algorytmu danego zależnością (3).




Rys. 4. Wartości wskaźników błędów segmentacji
Fig. 4. Values of the factors of the segmentation errors

Dla małych wartości współczynnika przedziału tolerancji, uzyskiwano relatywnie duże wartości wskaźników błędów dochodzące do 5%. Jak się okazało, badane algorytmy myliły błędy segmentacji z fizjologiczną zmiennością rytmu serca, przy czym większe wartości wskaźnika błędów uzyskiwano dla algorytmu opisanego zależnością (2). Dla kolejnych wartości współczynników przedziału tolerancji wskaźniki błędów sukcesywnie malały, a w przedziale od 2,955 do 3,293 zaczęły osiągać wartości zbliżone i zarazem adekwatne do faktycznej liczby błędów segmentacji występujących w badanych przebiegach. Jednak począwszy od $k(Q, q) = 3,774$ zaobserwowano pogarszanie zdolności detekcyjnej algorytmów, ponieważ przestawały one wykrywać błędy, których istnienie i lokalizację potwierdziły obserwacje przebiegu oraz wcześniejsze testy.

Badane algorytmy oceniano zgodnie ze standardem stosowanym dla algorytmów klasyfikacyjnych i testów diagnostycznych [13] wyznaczając dla każdej wartości współczynnika przedziału tolerancji: czułość i specyficzność oznaczone jako SE i SP oraz dodatnią i ujemną wartość prognostyczną, oznaczone symbolami PPV i NPV.

Przebiegi czułości (linia ciągła) i dodatniej wartości prognostycznej (linia przerywana) zaprezentowano na rys. 5, zaznaczając konsekwentnie: kolorem szarym wynik uzyskany dla algorytmu opisanego zależnością (2) i kolorem czarnym wynik uzyskany dla algorytmu danego zależnością (3).



Rys. 5. Czułość i dodatnia wartość prognostyczna
Fig. 5. Values of the sensitivity and the positive prediction value

Przebieg dodatniej wartości prognostycznej, ujawnia wspomnianą wcześniej wadę obu algorytmów, które dla małych wartości współczynnika przedziału tolerancji interpretują fizjologiczną zmienność rytmu serca jako błędy segmentacji.

Analizując wyniki segmentacji zauważono, że w przypadku dwóch błędów segmentacji występujących w niedalekim sąsiedztwie drugi z nich bardzo często nie był wykrywany. Źródłem problemu jest najprawdopodobniej sposób wyznaczania granic przedziałów tolerancji, wykorzystujący 60 ostatnich okresów przebiegu, niezależnie od tego, że niektóre z nich były wcześniej sklasyfikowane jako błędy segmentacji. Istnieje wobec tego możliwość poprawy czułości obu algorytmów poprzez modyfikację procedury wyznaczania przedziałów tolerancji polegającą na pominięciu wartości okresów sklasyfikowanych jako błędy segmentacji.

Na rys. 5 nie umieszczono przebiegów specyficzności i ujemnej wartości prognostycznej ponieważ były one równe 0,99 dla wszystkich $k(Q, q)$. Oznacza to, że w przypadku braku błędów segmentacji oba testowane algorytmy działały poprawnie, dokonując błędnej detekcji tylko raz na 100 przypadków. Dowodzi to także poprawności modelu matematycznego wykorzystanego do opisu zmienności okresu przebiegu fotopletyzmo graficznego.

5. Wnioski

Zaproponowane w pracy algorytmy detekcji błędów segmentacji stanowią interesującą alternatywę dla działań zmierzających do optymalizacji metod segmentacji przebiegu. Zakładają one jednak udział człowieka w procesie klasyfikacji błędów, co ogranicza zakres potencjalnych aplikacji do systemów pracujących w czasie własnym.

Przyjęto, że optymalną wartość współczynnika przedziału tolerancji wyznacza odcięta punktu przecięcia przebiegu czułości z przebiegiem dodatniej wartości prognostycznej, która wynosi 3,774 dla algorytmu opisanego zależnością (2) i 3,295 dla algorytmu opisanego zależnością (3).

Testowane algorytmy detekcji błędów segmentacji działają poprawnie i charakteryzują się dużą skutecznością działania. Dla optymalnych wartości współczynników przedziału tolerancji czułość i dodatnia wartość prognostyczna są równe i wynoszą: 0,74 dla algorytmu opisanego zależnością (2) i 0,71 dla algorytmu opisanego zależnością (3). Nie są to jednak wartości ostateczne ponieważ istnieją przesłanki wskazujące na możliwość poprawy obu wymienionych parametrów.

6. Literatura

- [1] Traczyk W.Z., Trzebski A., (red): Fizjologia człowieka z elementami fizjologii klinicznej. Państwowy Zakład Wydawnictw Lekarskich, Warszawa 1980.
- [2] Allen J.: Photoplethysmography and its application in clinical physiological measurement, *Physiological Measurement* 2007; 28: R1-R39.
- [3] Elgendi M.: On the Analysis of Fingertip Photoplethysmogram Signals. *Current Cardiology Reviews*, 2012; 8: 14-25.
- [4] Nałęcz M. (red): Biocybernetyka i Inżynieria Biomedyczna. Biopomiary; Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.
- [5] Lu S., Zaho H., Ju K., Shin K., Lee M., Shelly K., Chon K.: Can Photoplethysmography variability serve as an alternative approach to obtain heart rate variability information? *Journal Clinical Monitoring and Computing*, 2008; 22 (1): 23-29.
- [6] Bołtrukiewicz M.: Zastosowanie wariancji Allana do badania zmienności rytmu serca. *Pomiary Automatyka Kontrola*, nr 12/2011, s. 1486-1488.
- [7] Bołtrukiewicz M., Cysewska-Sobusiak A.: Algorytmy kondycjonowania sygnału fotopletyzmo graficznego. *Pomiary Automatyka Kontrola*, nr 9/2005, s. 22-25.
- [8] Nakajima K., Tamura T., Miike H.: Monitoring of heart and respiratory rate by plethysmography using a digital filtering technique, *Medical Engineering and Physics*; 18: 365-372.
- [9] Elgendi M., Jonkman M., De Boer F.: Heart Rate Variability Measurement Using the Second Derivative Photoplethysmogram. *The 3rd International Conference on Bio-inspired Systems and Signal Processing (BIOSIGNALS 2010) 2010*; Spain.
- [10] Fu T., Liu S., Tang K.: Heart Rate Extraction from Photoplethysmogram Waveform Using Wavelet Multi-resolution Analysis. *Journal of Medical and Biological Engineering* 2008; 28 (4): 229-232.
- [11] Bobrowski D., Maćkowiak-Lybacka K.: Wybrane metody wnioskowania statystycznego. Wyd. Politechniki Poznańskiej 1990.
- [12] Zieliński R.: *Tablice statystyczne*. Wyd. PWN, 1972.
- [13] Weinstein S., Obuchowski N.A., Lieber M.: Clinical Evaluation of Diagnostic Tests, *American Journal of Roentgenology*, 2005; 184: 14-19.