

Streszczenie

W rozprawie przedstawiono wyniki badań dotyczących wykrywania migotania przedsionków (ang. *atrial fibrillation, AF*) na podstawie analizy parametrów zmienności rytmu serca (ang. *heart rate variability, HRV*) wyznaczanych z elektrokardiogramu (EKG).

Analizie poddano możliwość rozróżniania migotania przedsionków i rytmu zatokowego (ang. *sinus rhythm, SR*), czyli fizjologicznego, z użyciem pojedynczych standardowych parametrów HRV i prostego klasyfikatora progowego. Szczegółowo zbadano właściwości parametrów HRV z rodziny pRR x , określających, jaki procent odstępów RR (długości cykli pracy serca) różnił się od poprzedniego odstępu RR o co najmniej x milisekund. Wykazano, że próg zliczania x równy około 30 ms (parametr pRR30) pozwala na bardziej efektywną detekcję migotania przedsionków niż standardowy próg równy 50 ms (parametr pRR50).

Podobne analizy przeprowadzono dla grupy parametrów pRR $x\%$, zdefiniowanych jak parametry pRR x , z tą różnicą, że próg zliczania $x\%$ określa względną, a nie bezwzględną różnicę długości sąsiednich odstępów RR i jest wyrażony w procentach, a nie w milisekundach. Wykazano, że parametry pRR $x\%$ pozwalają na jeszcze skuteczniejszą detekcję migotania przedsionków niż parametry pRR x , szczególnie dla progów $x\%$ w zakresie 3-5% (parametry pRR3%-pRR5%). Przeprowadzone badania dotyczące parametrów pRR x i pRR $x\%$ są według wiedzy autora pierwszymi szczegółowymi analizami właściwości tych grup parametrów w kontekście detekcji migotania przedsionków.

Zbadano także wpływ długości badanego segmentu EKG na skuteczność detekcji migotania przedsionków. Wykazano, że dla EKG o długości od 30 do 300 sekund parametry pRR $x\%$ i pRR x pozwalają na skuteczniejsze różnicowanie migotania przedsionków i rytmu zatokowego niż inne parametry HRV.

W dalszej części pracy zbadano metody wykrywania migotania przedsionków za pomocą algorytmów uczenia maszynowego przy użyciu niewielkich zbiorów odpowiednio dobranych parametrów HRV. Wykazano, że zastosowanie parametrów pRR $x\%$ lub pRR x w modelach uczenia maszynowego pozwala na poprawę efektywności wykrywania migotania przedsionków lub na uproszczenie modeli (zmniejszenie liczby wykorzystywanych przez nie cech) przy jednoczesnym zachowaniu podobnej efektywności. Ograniczanie złożoności modeli uczenia maszynowego może być przydatne w przypadku implementacji algorytmów detekcji arytmii w przenośnych lub wszczepialnych systemach do monitorowania pracy serca, w których priorytetem jest minimalizowanie poboru mocy.

Słowa kluczowe: *migotanie przedsionków, zmienność rytmu serca, HRV, pRR x , pRR $x\%$, detekcja arytmii serca, uczenie maszynowe, elektrokardiogram, EKG*

Abstract

In this thesis, the results of the studies on detecting atrial fibrillation (AF) using heart rate variability (HRV) analysis of electrocardiogram (ECG) were presented.

The ability to differentiate atrial fibrillation (AF) from physiological (sinus) rhythm (SR) using single standard HRV parameters and a simple threshold classifier was analyzed. The properties of HRV parameters from the $pRRx$ group were analyzed in detail. These parameters are defined as the percentages of RR intervals (cardiac cycles) differing from the previous RR interval by at least x ms. The analysis showed that using the threshold value $x = 30$ ms ($pRR30$ parameter) allows for more effective detection of atrial fibrillation than using the standard 50 ms threshold ($pRR50$ parameter).

A similar analysis was conducted for a group of $pRRx\%$ parameters, defined like $pRRx$, but with a threshold $x\%$ measuring relative rather than absolute difference between consecutive RR intervals, and expressed in percentages rather than milliseconds. The experiments showed that the $pRRx\%$ parameters allow for even more effective detection of atrial fibrillation than $pRRx$, especially with thresholds $x\%$ in the 3-5% range ($pRR3\%-pRR5\%$ parameters). The analyses of the $pRRx$ and $pRRx\%$ parameters are to the author's knowledge the first such detailed analyses of the diagnostic properties of these parameters in the context of atrial fibrillation detection.

The impact of the analyzed ECG's length on the effectiveness of atrial fibrillation detection was also investigated. It was shown that for 30-300 s ECG segments the $pRRx\%$ and $pRRx$ parameters are more effective in differentiating atrial fibrillation from sinus rhythm than other HRV parameters.

In the later part of the thesis the methods of atrial fibrillation detection using machine learning algorithms and small sets of selected HRV parameters were analyzed. It was shown that using $pRRx\%$ or $pRRx$ parameters in machine learning models allows for improving the effectiveness of atrial fibrillation detection or for simplifying the models (by reducing the feature set) while maintaining similar effectiveness. Reducing the complexity of machine learning models is especially important when implementing the arrhythmia detection algorithms in mobile or implantable cardiac monitors, where limiting the power consumption is a priority.

Keywords: *atrial fibrillation, heart rate variability, HRV, pRRx, pRRx%, cardiac arrhythmia detection, machine learning, electrocardiogram, ECG*