

Streszczenie pracy doktorskiej

Autor: Monika Prucnal

Tytuł: Metody analizy sygnału EEG ukierunkowane na wykrywanie bezdechu sennego

Bezdech senny to jedno z najczęstszych zaburzeń oddychania podczas snu, charakteryzujące się wielokrotnym czasowym spłyceniem lub całkowitym ustaniem oddechu. Zaburzenie to wiąże się z fragmentacją snu oraz ma znaczący wpływ na samopoczucie i stan zdrowia osób, które go doświadczają. Złotym standardem wykrywania zaburzeń snu jest polisomnografia, podczas której rejestruje się wiele sygnałów, w tym elektroencefalogram (EEG). Badania zaproponowane w niniejszej rozprawie dotyczą analizy jednokanałowego sygnału EEG w celu detekcji epok normalnego oddychania i bezdechu sennego oraz jego typu: obturacyjnego (OSA) lub centralnego (CSA). Celem pracy było zaproponowanie procedury przetwarzania jednokanałowego sygnału EEG z zapisu całonocnego, która zmaksymalizuje dokładność zarówno automatycznego rozróżniania pomiędzy epokami z okresu bezdechu sennego i normalnego oddychania, jak i różnicowanie typów bezdechu.

Analizę sygnału EEG wykonano w pracy poprzez zastosowanie wybranych metod na kolejnych etapach przetwarzania sygnału: przetwarzania wstępnego, ekstrakcji i selekcji cech oraz klasyfikacji. Najkorzystniejszymi metodami przetwarzania wstępnego okazały się: usuwanie wysycień oraz nadmiernych amplitud, filtracja dolnoprzepustowa ograniczająca pasmo do 45 Hz i usunięcie linii trendu oraz standaryzacja sygnału EEG. Ekstrakcję cech wykonano poprzez rozkład sygnału na składowe z zastosowaniem metod jednoetapowych: filtracji pasmowoprzepustowej (BPF), dyskretnej transformacji falkowej (DWT), dekompozycji empirycznej (EMD) i dekompozycji wariacyjnej (VMD) oraz dwuetapowych: transformacji Hilberta-Huanga (HHT), DWT+HT i VMD+HT, dla których obliczono po 9 cech skalarnych: skośność, kurtozę medianę, parametry Hjortha (aktywność, proporcję aktywności do sumy aktywności wszystkich sygnałów, mobilność, złożoność), entropię Shanona oraz maksymalną amplitudą, czego efektem było uzyskanie wektorów cech różniących się ilością (od 45 do 351 cech), co razem dało 873 cech. Jako metodę selekcji cech wybrano algorytm ReliefF, który zastosowano dla każdej metody ekstrakcji i połączono wybrane cechy, uzyskując zbiór całościowy o wymiarze 520. Następnie wykonano ponowną selekcję cech ze zbioru całościowego, której wynikiem była redukcja ilości cech do 387 (66,4% z HHT, 14,99% z DWT+HT).

Uzyskany wektor cech został wykorzystany do badania i optymalizacji następujących klasyfikatorów: k-najbliższych sąsiadów (k-NN), maszyny wektorów nośnych (SVM) i jednokierunkowych sztucznych sieci neuronowych (ANN). Ocenę dokładności klasyfikatorów wykonano poprzez zastosowanie 32-krotnej walidacji krzyżowej. Wśród testowanych klasyfikatorów, k-NN i ANN umożliwiły bezbłędne (100% dokładność) rozróżnienie pomiędzy klasą normalnego oddychania a bezdechem oraz SVM z dokładnością 99,53%. Dokładność klasyfikacji trójetykietowej jest porównywalna dla każdego z klasyfikatorów i wynosi powyżej 82% (83,26% dla SVM). Średnia czułość oraz precyzja klasyfikacji dla wszystkich klasyfikatorów trójetykietowych wyniosła między 73% a 75%. Uzyskanie 100% dokładności rozpoznawania epok EEG związanych z bezdechem sennym powoduje, że zaproponowana procedura przetwarzania sygnału może być stosowana w automatycznym wspomaganiu diagnostyki medycznej.

Słowa kluczowe: analiza danych pomiarowych, elektroencefalografia, bezdech senny, przetwarzanie sygnałów biomedycznych, metody ekstrakcji i selekcji cech, uczenie maszynowe, automatyczne wspomaganie decyzji medycznych.

1.07.2021r. Monika Puczał

Abstract

Tytuł angielski: Methods for EEG signal analysis aimed at sleep apnea detection

Sleep apnea is one of the most common breathing disorders during sleep, characterized by repeated shortening or complete cessation of breathing. This disorder is associated with sleep fragmentation and has a significant impact on the well-being and health of people who experience it. Polysomnography is the gold standard for detecting sleep disorders. During polysomnography many signals are recorded, including an electroencephalogram (EEG). Research proposed in this dissertation concerns the analysis of a single-channel EEG signal in order to detect epochs of normal breathing and sleep apnea (binary classification) and its type: obstructive (OSA) or central (CSA) (three-label classification). The aim of the study was to propose an overnight single-channel EEG signal processing procedure to maximize the accuracy of both automatic classification between sleep apnea and normal breathing epochs, and the types of apnea.

The analysis of the EEG signal was performed by applying selected methods at each stage of signal processing: pre-processing, extraction and selection of features, and classification. As the best pre-processing methods were chosen: removal of saturation and excessive amplitudes, low-pass filtering limiting the frequency band to 45 Hz, removing the trend line and standardization of the EEG signal. Feature extraction were made by decomposing the signal into components using one-step methods: band-pass filtering (BPF), discrete transformation wavelet (DWT), empirical decomposition (EMD) and variational decomposition (VMD) and two-stage methods: Hilbert-Huang transform (HHT), DWT + HT and VMD + HT, for which 9 scalar features were calculated: skewness, median kurtosis, Hjorth parameters (activity, the proportion of activity to the sum of the activities of all signals, mobility, complexity), Shannon's entropy and the maximum amplitude, which resulted in feature vectors varying from 45 to 351 features, which together gave a total of 873 features. The ReliefF algorithm were chosen as the best feature selection method, which was used for each feature set, and then the selected features were combined to obtain a comprehensive set of 520 elements. Subsequently, features were re-selected from this overall set, which resulted in a reduction of the number of features to 387 (66.4% from HHT, 14.99% from DWT + HT).

The obtained feature vector was used to study and optimize the following classifiers: k-nearest neighbors (k-NN), support vector machines (SVM) and feedforward artificial neural networks (ANN). The accuracy of classifiers was assessed by applying 32-fold cross-

validation. Among the tested classifiers, k-NN and ANN enabled a flawless (100% accuracy) differentiation between the class of normal breathing and apnea, and SVM with an accuracy of 99,53%. The accuracy of the three-label classification was comparable for each of the classifiers and was above 82% (83,26% for SVM). The average sensitivity and precision of three-label classification for all classifiers was between 73% and 75%. Achieving 100% accuracy in the recognition of EEG epochs related to sleep apnea means that the proposed signal processing procedure can be used in the automatic support of medical diagnostics.

Keywords: data analysis, electroencephalography, sleep apnea, biomedical signal processing, features extraction and selection methods, machine learning, automatic medical decision support.

1.07.2021r. Monika Puchal