



Politechnika Wroclawska

**Metody analizy sygnału EEG
ukierunkowane na wykrywanie
bezdechu sennego**

Autor:

mgr inż. Monika A. Prucnal

Promotor:

Dr hab. inż. Adam G. Polak, prof. PWR

Wrocław 2021

Streszczenie

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.

Abstract

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), Shanon'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.

Dziękuję Panu dr hab. inż. Adamowi Polakowi za podjęcie funkcji promotora tej pracy, zaangażowanie, życzliwość, wsparcie i opiekę merytoryczną.

Dziękuję Koleżankom i Kolegom z Katedry Metrologii Elektronicznej i Fotonicznej za miłą atmosferę i cenne rozmowy.

Dziękuję mojemu mężowi Pawłowi, moim Rodzicom i Przyjaciołom za serdeczność, troskę i wszelką pomoc. To również dzięki moim Bliskim ta praca mogła powstać.

Spis treści

Streszczenie	3
Abstract	5
Spis oznaczeń	13
Spis skrótów	17
Rozdział 1	21
Wstęp	21
1.1 Motywacja badań	21
1.2 Rozwiązywany problem i metodyka badań	23
1.3 Cel pracy i jej teza	25
1.4 Zawartość pracy	25
Rozdział 2	27
Bezdech senny i jego wykrywanie	27
2.1 Sen	27
2.2 Syndrom bezdechu sennego	27
2.3 Epidemiologia	29
2.4 Typy bezdechu sennego	32
2.4.1 Bezdech obturacyjny	32
2.4.2 Bezdech centralny	33
2.4.3 Bezdech mieszany	34
2.5 Polisomnografia	35
2.6 Automatyzacja diagnostyki bezdechu sennego	36
Rozdział 3	38
Sygnal EEG i jego wykorzystanie w diagnostyce bezdechu sennego	38
3.1 Biofizyczne podstawy elektroencefalografii	38
3.1.1 Powstawanie sygnału EEG	38
3.1.1.1 Źródła prądowe w mózgu	38
3.1.1.2 Sygnal EEG	41
3.1.1.3 Rejestracja sygnału EEG	42
3.1.1.4 Interpretacja sygnału EEG	43
3.1.1.5 Ilościowe EEG (ang. <i>Quantitative EEG</i> (qEEG))	44
3.1.2 Prawidłowy zapis EEG osoby dorosłej	45
3.1.3 Prawidłowy zapis EEG podczas snu	47
3.2 Zmiany w sygnale EEG powiązane z epizodami bezdechu	50
3.2.1 Przyczynowość w zjawiskach fizjologicznych	50
3.2.2 Problem wprost i odwrotny	53
3.2.3 Mechanizmy wpływu bezdechu sennego na EEG	53
3.2.4 Wpływ bezdechu na EEG	58
3.2.4.1 Wpływ bezdechu obturacyjnego na EEG	58
3.2.4.2 Wpływ bezdechu centralnego na EEG	60
3.3 Badania nad wykorzystaniem EEG w diagnostyce bezdechu	61

3.3.1	Badania wykorzystujące EEG wraz z innymi biosygnalami	61
3.3.2	Badania wykorzystujące jedynie sygnał EEG	63
Rozdział 4		71
Baza danych polisomnograficznych		71
4.1	Dostępne bazy danych	71
4.2	Przygotowanie bazy danych do wykorzystania w pracy	72
Rozdział 5		77
Przetwarzanie wstępne całonocnych zapisów EEG		77
5.1	Stosowane metody wstępnego przetwarzania sygnału EEG	78
5.1.1	Metody wczesnego przetwarzania sygnału EEG niezwiązane z artefaktami fizjologicznymi	78
5.1.1.1	Usunięcie fragmentów sygnałów EEG o zbyt dużej amplitudzie	78
5.1.1.2	Normalizacja i standaryzacja	79
5.1.1.3	Usunięcie linii trendu	80
5.1.1.4	Uśrednianie potencjału odniesienia (ang. <i>Rereferencing</i>)	81
5.1.1.5	Usunięcie zakłóceń pochodzących od sieci energetycznej	82
5.1.2	Metody przetwarzania artefaktów	83
5.1.2.1	Metody przetwarzania artefaktów w wielokanałowym EEG	84
5.1.2.2	Metody przetwarzania artefaktów w jednokanałowym sygnale EEG	85
5.1.2.3	Metody przetwarzania artefaktów wykorzystywane dla wielokanałowego i jednokanałowego sygnału EEG	88
5.1.3	Podział sygnału na epoki i klasy	90
5.2	Wybór metod i efekty przetwarzania wstępnego	92
5.2.1.1	Usuwanie wysyczeń i nadmiernych amplitud	94
5.2.1.2	Usuwanie zakłóceń od sieci energetycznej	100
5.2.2	Standaryzacja sygnału	106
5.2.3	Podział na epoki i klasy	109
5.2.3.1	Podział na epoki	109
5.2.3.2	Podział na klasy	111
5.2.4	Wpływ przetwarzania wstępnego na trafność klasyfikacji bezdechu sennego	111
5.3	Podsumowanie	116
Rozdział 6		118
Ekstrakcja cech z epok sygnału EEG		118
6.1	Metody ekstrakcji cech sygnału EEG stosowane w badaniach nad snem	118
6.1.1	Metody dekompozycji na sygnały składowe	119
6.1.1.1	Dekompozycja w dziedzinie czasu	119
6.1.1.2	Dekompozycja w dziedzinach czas-częstotliwość i czas-skala	124
6.1.1.3	Dekompozycja w dziedzinie częstotliwości	129
6.1.2	Metody obliczania skalarnych cech sygnałów	130
6.1.2.1	Cechy energetyczne	130
6.1.2.2	Cechy spektralne – harmoniczne parametry Hjortha	131
6.1.2.3	Cechy kształtu i cechy statystyczne	132

6.1.2.4	Cechy dynamiki nieliniowej	132
6.2	Wybór metod i efekty ekstrakcji cech	133
6.2.1	Dekompozycja sygnału EEG	136
6.2.1.1	Filtracja pasmowoprzepustowa	136
6.2.1.2	Dyskretna transformacja falkowa	140
6.2.1.3	Dekompozycja empiryczna	141
6.2.1.4	Dekompozycji wariacyjna	142
6.2.1.5	Dwuetapowe metody dekompozycji	143
6.2.2	Obliczenie cech skalarnych	146
6.3	Podsumowanie	147
Rozdział 7		149
Selekcja cech charakteryzujących epoki EEG		149
7.1	Metody selekcji cech	149
7.1.1	Filtry	149
7.1.1.1	Algorytm ReliefF	150
7.1.1.2	Ocena cech za pomocą testu t -Studenta	150
7.1.1.3	Analiza wariancji	150
7.1.1.4	Metoda Fishera	151
7.1.1.5	Liniowa analiza dyskryminacyjna	151
7.1.1.6	Analiza korelacji liniowej	151
7.1.1.7	Szybki filtr oparty na korelacji	152
7.1.1.8	Algorytm MRMR	152
7.1.1.9	Analiza składowych głównych	152
7.1.1.10	Selekcja krokowa	153
7.1.2	Metody opakowane	153
7.1.3	Metody wbudowane	154
7.2	Wybór metody selekcji cech	154
7.2.1	Selekcja cech metodą MRMR	155
7.2.2	Selekcja cech metodą ANOVA i MRA	157
7.2.3	Selekcja cech metodą ReliefF i MRA	158
7.2.4	Wyniki selekcji cech wybranymi metodami	160
7.3	Selekcja cech wybraną metodą	161
7.4	Podsumowanie	168
Rozdział 8		169
Algorytmy rozpoznawania bezdechu na podstawie epok EEG		169
8.1	Metody klasyfikacji epok EEG	169
8.1.1	Klasyfikatory statystyczne	169
8.1.1.1	K-najbliższych sąsiadów	170
8.1.1.2	Analiza dyskryminacyjna	170
8.1.1.3	Naiwny klasyfikator bayesowski	170
8.1.1.4	Modele Markova	171
8.1.1.5	Maszyna wektorów nośnych	171
8.1.2	Sztuczne sieci neuronowe	171

8.1.2.1	Sieci klasyczne	172
8.1.2.2	Sieci Kohena	173
8.1.2.3	Sieci z uczeniem głębokim	174
8.1.3	Klasyfikatory rozmyte i mieszane	174
8.1.3.1	Klasyfikator wzmacniający z pod- lub nadpróbkowaniem	175
8.1.4	Ocena jakości klasyfikatora	175
8.2	Wybór klasyfikatora	180
8.3	Rozpoznawanie epok EEG wybranymi klasyfikatorami	181
8.3.1	Ocena wydajności modeli klasyfikatorów	181
8.3.2	Metoda k-najbliższych sąsiadów (k-NN)	182
8.3.3	Maszyna wektorów nośnych (SVM)	186
8.3.4	Jednokierunkowe sztuczne sieci neuronowe	192
8.4	Podsumowanie	201
Rozdział 9		204
Podsumowanie i wnioski		204
9.1	Rozwiązywany problem naukowy, cel i teza pracy	204
9.2	Podsumowanie i wyniki zrealizowanych prac	204
9.3	Oryginalność rozwiązania problemu naukowego	207
9.4	Wnioski i dalsze prace	208
Bibliografia		211

Spis oznaczeń

$x(t)$ – sygnał ciągły

$n(t)$ – sygnał ciągły po normalizacji min-max

$s(t)$ – ciągłe sygnały źródłowe

$e(t)$ – szum addytywny o charakterze szumu białego

\mathbf{B} – macierz mieszania sygnałów

x – sygnał próbkowany

x_{st} – sygnał próbkowany po standaryzacji

x_i – i -ta próbka sygnału

n – długość ciągu próbek

\min_x – minimalna wartość w sygnale x

\max_x – maksymalna wartość w sygnale x

\min – nowa minimalna wartość

\max – nowa maksymalna wartość

μ – wartość oczekiwana z sygnału x

σ – odchylenie standardowe z sygnału x

$prog_+$ – próg dodatni

$prog_-$ – próg ujemny

m_+ – średnia z wartości dodatnich

m_- – średnia z wartości ujemnych

\bar{P}_x – średnia moc sygnału

$u_i(t)$ – i -ta funkcja wrodzona (IMF)

r_p – rezydua

p – liczba poziomów dekompozycji sygnału

$\omega_i(t)$ – i -ta częstotliwość środkowa

$\delta(t)$ – delta Diraca

$X(t)$ – sygnał analityczny

$h(t)$ – transformata Hilberta sygnału

$A(t)$ – chwilowa wartość amplitudy $X(t)$

$\phi(t)$ – chwilowa wartość fazy $X(t)$

$f(t)$ – chwilowa wartość częstotliwości

$f_w(t)$ – chwilowa wartość ważonej częstotliwości

ψ – falka podstawowa

c – parametr przesunięcia
 b – parametr skali
 φ – funkcje skalujące
 $D_B = \{d_{b,c}\}$ – zbiór współczynników szczegółowych
 $A_B = \{a_{b,c}\}$ – zbiór współczynników aproksymujących
 $x(f)$ – sygnał w dziedzinie częstotliwości
 f_c – częstotliwość środkowa
 P_x – widmowa gęstość mocy
 f_σ – szerokość pasma
 S_{f_c} – wartość widmową częstotliwości środkowej
 f_L – częstotliwość minimalna
 f_H – częstotliwość maksymalna
 E – energia sygnału
 $EnSh$ – entropia Shannona
 y_i – scałkowane próbki sygnału x
 m – szerokość okna
 F_m – wartość fluktuacji w zależności od szerokości okna m
 y_m – lokalny trend
 S^2 – wariancja
 $\dot{\sigma}^2$ – wariancja pierwszej pochodnej
 $\ddot{\sigma}^2$ – wariancja drugiej pochodnej
 H_A – aktywność
 H_M – mobilność
 H_c – złożoność
 S_k – skośność
 K – kurtoza
 M_e – mediana
 A – amplituda
 k – ilość najbliższych sąsiadów
 y – etykiety klas dla elementów zbioru
 W – wektor cech
 T – wektor cech zbioru uczącego
 W_i – element klasyfikowany reprezentowany poprzez wektor cech
 T_i – element należący do zbioru uczącego

n_w – wymiar wektora cech
 V_x – współczynnik znaczenia cechy W_i w analizowanym zbiorze W
 W_x – współczynnik nadmiarowości zbioru W
 \bar{W} – wartość średnia W
 \bar{T} – wartość średnia T
 MIQ_x – wartości ilorazu informacji wzajemnej
 I – informacja wzajemna
 \bar{R}^2 – skorygowany współczynnik determinacji
 r – całkowita liczba zmiennych objaśniających w modelu
 h – wynik testu hipotezy
 p_t – prawdopodobieństwo testowe
 λ – parametr regularyzacji

Ocena jakości klasyfikacji

TP – wyniki prawdziwie dodatnie (ang. *True Positive*)
TN – wyniki prawdziwie ujemne (ang. *True Negative*)
FP – wyniki fałszywie dodatnie (ang. *False Positive*)
FN – wyniki fałszywie ujemne (ang. *False Negative*)
 A_c – dokładność klasyfikacji binarnej
 E_r – współczynnik błędu klasyfikacji binarnej
 P – precyzja klasyfikacji binarnej
 R – czułość klasyfikacji binarnej
 S – swoistość klasyfikacji binarnej
 F_β – miara Fishera klasyfikacji binarnej
 F_1 – miara Fishera dla wartości $\beta=1$ klasyfikacji binarnej
AUC – pole pod krzywą ROC dla klasyfikacji binarnej
 A_{cM} – dokładność klasyfikacji wieloetykietowej *Macro-Averaging*
 P_M – precyzja klasyfikacji wieloetykietowej *Macro-Averaging*
 R_M – czułość klasyfikacji wieloetykietowej *Macro-Averaging*
 F_{1M} – miara Fishera klasyfikacji wieloetykietowej *Macro-Averaging*
 $A_{c\mu}$ – dokładność klasyfikacji wieloetykietowej *Micro-Averaging*
 P_M – precyzja klasyfikacji wieloetykietowej *Micro-Averaging*
 R_M – czułość klasyfikacji wieloetykietowej *Micro-Averaging*
 F_{1M} – miara Fishera klasyfikacji wieloetykietowej *Micro-Averaging*

A_{sr} – średnia dokładność:

E_{sr} – średni współczynnik błędów

Metryki obliczania odległości

d_M – odległość Minkowskiego

d_C – odległość Czebyszewa

d_m – odległość miejska

d_E – odległość euklidesowa

d_{ES} – odległość euklidesowa standaryzowana

d_c – odległość kosinusowa

d_k – odległość korelacyjna

σ_c – odchylenie standardowe danej cechy

d_S – odległość Spearmana

r_w – wektor rang powiązany z wektorem W

r_t – wektor rang powiązany z wektorem T

d_H – odległość Hamminga

d_J – odległość Jaccarda

p_p – stopień potęgi

Funkcje jądra

Y – wektor normalny do hiperpłaszczyzny

k_l – liniowa funkcja jądra

k_g – radialna funkcja jądra

k_p – wielomianowa funkcja jądra

p_w – stopień wielomianu

W_w – zbiór cech po standaryzacji

μ_w – ważona średnia

σ_w – ważne odchylenie standardowe

Spis skrótów

AASM	Amerykańska Akademia Medycyny Snu (ang. <i>American Academy of Sleep Medicine</i>)
AF	filtracja adaptacyjna (ang. <i>Adaptive Filtering</i>)
AHD	adaptacyjna dekompozycja Hermite'a (ang. <i>Adaptive Hermite Decomposition</i>)
AHI	współczynnik bezdechu/spłycenia oddechu (ang. <i>Apnea-Hypopnea Index</i>)
AI	współczynnik ilości bezdechów (ang. <i>Apnea Index</i>)
ANN	sztuczne sieci neuronowe (ang. <i>Artificial Neural Network</i>)
ANOVA	analiza wariancji (ang. <i>Analysis Of Variance</i>)
BPF	filtracja pasmowoprzepustowa (ang. <i>Bandpass Filter</i>)
BSS	ślepa separacja źródeł (ang. <i>Blind Source Separation</i>)
C	centralny obszar mózgu (ang. <i>Central</i>)
CC	klasyfikatory mieszane (ang. <i>Combined Classifiers</i>)
CCA	analiza korelacji kanonicznych (ang. <i>Canonical Correlation Analysis</i>)
CNN	konwolucyjna sieć neuronowa (ang. <i>Convolutional Neural Network</i>)
CPAP	leczenie stałym dodatnim ciśnieniem w drogach oddechowych (ang. <i>Continuous Positive Airway Pressure</i>)
CSA	centralny bezdech senny (ang. <i>Central Sleep Apnea</i>)
CSH	centralne splecenie oddychania
CSR	oddech Cheyena-Stokesa (ang. <i>Cheyne-Stokes Respiration</i>)
CSR	okresowe oddychanie Cheyena-Stokesa (ang. <i>Cheyne-Stokes Respiration</i>)
DBN	sieci głębokiego zaufania (ang. <i>Deep Belief Network</i>)
DFA	metoda beztrendowej analizy fluktuacji (ang. <i>Detrended Fluctuation Analysis</i>)
DFT	dyskretna transformata Fouriera (ang. <i>Discrete Fourier Transform</i>)
DLN	sieci z uczeniem głębokim (ang. <i>Deep Learning Network</i>)
DWT	dyskretna transformata falkowa (ang. <i>Discrete Wavelet Transform</i>)
EEG	elektroencefalografia
EKG	elektrokardiografia
ELM	ekstremalne sieci neuronowe (ang. <i>Exreme Learning Machine</i>)
EMD	dekompozycja empiryczna (ang. <i>Empirical Mode Decomposition</i>)

EMD-based ICA	analiza składowych niezależnych oparta na dekompozycji empirycznej (ang. <i>Empirical Mode Decomposition based Independent Component Analysis</i>)
EMG	elektromiografia
EOG	elektrookulografia
EPSP	pobudzający potencjał postsynaptyczny (ang. <i>Excitatory Postsynaptic Potential</i>)
EV	wartość entropii (ang. <i>Entropy Value</i>)
F	czołowy obszar mózgu (ang. <i>Frontal</i>)
FC	klasyfikatory rozmyte (ang. <i>Fuzzy Classifiers</i>)
FCBF	szybki filtr oparty na korelacji (ang. <i>Fast Correlation-Based Filter</i>)
FD	wymiar fraktalny (ang. <i>Fractal Dimension</i>)
FFNN	jednokierunkowa sieć neuronowa (ang. <i>Feedforward Neural Network</i>)
FFT	szybka transformata Fouriera (ang. <i>Fast Fourier Transform</i>)
FIR	filtr o skończonej odpowiedzi impulsowej (ang. <i>Finite Impulse Response</i>)
FLD	liniowa dyskryminacja Fishera (ang. <i>Fisher Linear Discriminant</i>)
FT	transformata Fouriera (ang. <i>Fourier Transform</i>)
GA	algorytmy genetyczne (ang. <i>Genetic Algorithm</i>)
HHT	transformata Hilberta-Huanga (ang. <i>Hilbert-Huang Transform</i>)
HT	transformata Hilberta (ang. <i>Hilbert Transform</i>)
ICA	analiza składowych niezależnych (ang. <i>Independent Component Analysis</i>)
ICSD	Międzynarodowa klasyfikacja zaburzeń snu (ang. <i>International Classification of Sleep Disorders</i>)
IIR	filtr o nieskończonej odpowiedzi impulsowej (ang. <i>Infinite Impulse Response</i>)
IMF	funkcja wrodzona (ang. <i>Intrinsic Mode Functions</i>)
IPSP	hamujący potencjał postsynaptyczny (ang. <i>Inhibitory Postsynaptic Potential</i>)
k-NN	algorytm k -najbliższych sąsiadów (ang. <i>k-Nearest Neighbor</i>)
LDA	liniowa analiza dyskryminacyjna (ang. <i>Linear Discriminant Analysis</i>)
LS-SVM	maszyny wektorów nośnych o najmniejszych kwadratach (ang. <i>Least Squares Support Vector Machine</i>)
MCA	analiza składowych morfologicznych (ang. <i>Morphological Component Analysis</i>)
MIQ_x	iloraz informacji wzajemnej (ang. <i>Mutual Information Quotient</i>)
MLP	perceptron wielowarstwowy (ang. <i>Multilayer Perceptron</i>)
MM	model Markova (ang. <i>Markov Model</i>)

MP	algorytm poszukiwania dopasowującego (ang. <i>Matching Pursuit Algorithm</i>)
MRA	analiza regresji wielokrotnej (ang. <i>Multivariate Regression Analysis</i>)
MRMR	algorytm MRMR (ang. <i>Minimal Redundancy Maximal Relevance</i>)
MSA	mieszany bezdech senny (ang. <i>Mixed Sleep Apnea</i>)
MSH	mieszane spłylenie oddychania
NB	naiwny klasyfikator bayesowski (ang. <i>Naive Bayes Classifier</i>)
NMF	nieujemna faktoryzacja macierzy (ang. <i>Nonnegative Matrix Factorization</i>)
NORM	normalne oddychanie
NREM	sen wolnych ruchów gałek ocznych (ang. <i>Non-Rapid Eye Movement</i>)
O	potyliczny obszar mózgu (ang. <i>Occipital</i>)
OHS	bezdech centralny spowodowany zespołem hipowentylacji otyłych (ang. <i>Obesity Hypoventilation Syndrome</i>)
OSA	obturacyjny bezdech senny (ang. <i>Obstructive Sleep Apnea</i>)
OSH	obturacyjne spłylenie oddychania
OUN	ośrodkowy układ nerwowy
P	tylny obszar mózgu (ang. <i>Posterior</i>)
PB	oddychanie okresowe (ang. <i>Periodic Breathing</i>)
PCA	analiza składowych głównych (ang. <i>Principial Component Analysis</i>)
PPG	fotopletyzmografia
PSD	widmowa gęstość mocy (ang. <i>Power Spectral Density</i>)
PSG	polisomnografia
PTT	czas propagacji fali tętna obwodowego (ang. <i>Pulse Transit Time</i>)
qEEG	ilościowe EEG (ang. <i>Quantitative EEG</i>)
RBM	ograniczonych maszyn Boltzmana (ang. <i>Restricted Boltzmann Machine</i>)
RDI	współczynnik zaburzeń oddechowych (ang. <i>Respiratory Disturbance Index</i>)
REG	regresja liniowa
REM	sen szybkich ruchów gałek ocznych (ang. <i>Rapid Eye Movement</i>)
RiM	model rozkładu Rice'a (ang. <i>Rician model</i>)
RNN	rekurencyjne sieci neuronowe (ang. <i>Recurrent Neural Network</i>)
RUS	losowe podpróbkiowanie (ang. <i>Random Undersampling</i>)
RUSBoost	klasyfikator wzmacniający z losowym podpróbkiowaniem (ang. <i>Random Undersampling Boosting</i>)
SA	wielowarstwowe autoenkodery (ang. <i>Stacked Autoencoders</i>)

SBS eliminacja wsteczna (ang. *Sequential Backward Selection*)
SFS selekcja wstępująca (ang. *Sequential Forward Selection*)
SMOTE syntetyczna technika nadpróbkiwania klasy mniejszościowej (ang. *Synthetic Minority Over-sampling Technique*)
SOM mapy samoorganizujące się (ang. *Self-Organising Maps*)
STFT krótkoczasowa transformata Fouriera (ang. *Short-Time Fourier Transform*)
SU kryterium niepewności symetrycznej (ang. *Symmetrical Uncertainty*)
SVM maszyna wektorów nośnych (ang. *Support Vector Machine*)
T skroniowy obszar mózgu (ang. *Temporal*)
VMD dekompozycja wariacyjna (ang. *Variational Mode Decomposition*)
WT transformata falkowa (ang. *Wavelet Transform*)
WT-based ICA analiza składowych niezależnych oparta na transformacie falkowej (ang. *Wavelet Transform based Independent Component Analysis*)

Rozdział 1

Wstęp

1.1 Motywacja badań

Sen jest jednym z podstawowych stanów centralnego układu nerwowego. Sprzyja jego relaksacji i jest konieczny dla normalnego funkcjonowania zarówno samego układu, jak i całego organizmu człowieka. Dlatego też niezwykle niebezpieczne są zaburzenia snu ze względu na ich wielorakie konsekwencje i trudność w wykryciu. Wśród tych zaburzeń można wyróżnić grupę schorzeń nazywanych bezdechem sennym, który charakteryzuje się wielokrotną (nawet do kilkuset razy w ciągu nocy) czasową redukcją lub całkowitym zaprzestaniem oddychania i tym samym wymiany gazowej w płucach. Syndrom bezdechu sennego jest jednym z najczęściej występujących zaburzeń oddychania podczas snu. Szacuje się, że bezdech obturacyjny może dotyczyć 2-9% (częściej mężczyzn niż kobiety) [297], a centralny około 1% [89] populacji, z tym, że wiele osób może nie być świadomych choroby. Bezdech senny ma znaczący wpływ na samopoczucie i stan zdrowia osób, które go doświadczają. Oprócz uczucia zmęczenia i fragmentacji snu oraz chorób krążenia, bezdech senny może powodować również poważne zmiany w mózgu.

Wyróżnia się trzy podstawowe typy bezdechu sennego: obturacyjny, centralny i mieszany, a podstawową metodą diagnostyczną jest polisomnografia polegająca na całonocnej rejestracji podstawowych sygnałów fizjologicznych w laboratorium snu. Podczas polisomnografii rejestruje się takie sygnały fizjologiczne, jak: elektroencefalogram (EEG), elektrokardiogram (EKG), elektromiogram (EMG), elektrookulogram (EOG), saturacja krwi tętniczej tlenem (SaO_2), przepływ powietrza przy ustach lub nosie, ruchy klatki piersiowej, akustyczny pomiar dźwięków oddechowych czy ruchy brzucha. Zazwyczaj badanie polisomnograficzne realizowane jest w wyspecjalizowanych do tych celów placówkach lub szpitalach. Istnieją również urządzenia, umożliwiające rejestrację wybranych sygnałów w warunkach domowych (np. Embletta MPR lub SleepView Monitor). Przenośne polisomnografy często umożliwiają zapis: saturacji tlenem krwi tętniczej, przepływu powietrza, pulsu oraz akustyczny pomiar dźwięków oddechowych, które są wystarczające do przesiewowych badań nad zaburzeniami oddychania podczas snu. Niektóre są bardziej rozbudowane

i umożliwiają rejestrację większości zalecanych podczas badań nad snem sygnałów, co oczywiście związane jest ze wzrostem kosztów.

Zastosowanie sygnału EEG w polisomnografii dotyczy głównie detekcji faz snu oraz utworzenia hipnogramu, który jest zapisem przejść pomiędzy kolejnymi fazami. Według zaleceń AASM, do tego celu wystarczające jest wykorzystanie dwukanałowego elektroencefalografu. Z zarejestrowanych dwóch sygnałów interpretacja wykonywana jest zazwyczaj dla jednego kanału (rekomendowanego), a drugi traktowany jest jako zapasowy i wykorzystywany w sytuacji, w której sygnał rekomendowany jest nieczytelny lub uległ uszkodzeniu. Znane są rozwiązania sprzętowe umożliwiające rejestrację wielokanałowego sygnału EEG w domu z wykorzystaniem komputera lub dedykowanego rejestratora (np. BrainAmp lub ActiveTwo). Ponadto rozwijana jest możliwość rejestracji elektrycznej aktywności mózgu z wykorzystaniem od jednego do trzech kanałów poprzez zastosowanie układów specjalizowanych (jak np. TI ADS1298) lub przenośnych urządzeń (np. MindWave Mobile 2, NeuroFocus Mynd, Polymate AP216, Macrotellect Brainlink Lite EEG).

O ile w ostatnich latach co roku publikowanych jest ponad 3 tysiące prac dotyczących polisomnografii wykorzystywanej do diagnozowania bezdechu sennego (*Google Scholar*, słowa kluczowe: *polysomnography, apnea, detection*), o tyle w ramach szczegółowych studiów literaturowych przeprowadzonych w ramach tej pracy, zidentyfikowano po 2010 r. tylko kilkadziesiąt publikacji poświęconych automatycznemu wykrywaniu bezdechu sennego **jedynie** na podstawie sygnału EEG (tj. bez uwzględniania innych sygnałów). Przed otwarciem przewodu doktorskiego, a więc do roku 2017, znanych było niewiele prac nad detekcją bezdechu w odróżnieniu od normalnego oddychania u osób chorych, z zastosowaniem **jednokanałowego** sygnału EEG, których dokładność klasyfikacji wynosiła: 54,10% [188], 78,10% [189], 82,28% [9], 87,03% [288], 80,43% [287] i 87,64% [275] (szerokie omówienie aktualnego stanu wiedzy w obszarze pracy znajduje się w Rozdziale 2, 3 oraz 5-8). Wszystkie badania, których dokładność klasyfikacji zaprezentowano powyżej, dotyczyły **klasyfikacji binarnej** w zakresie normalnego oddychania i bezdechu sennego (bez względu na jego typ lub tylko obturacyjnego). Rozróżnienie typu bezdechu, a więc zastosowanie trójetykietowej klasyfikacji i rozróżnienie oprócz normalnego oddychania, również dwóch typów bezdechu: obturacyjnego (OSA) lub centralnego (CSA) z jednego kanału EEG nie było prezentowane

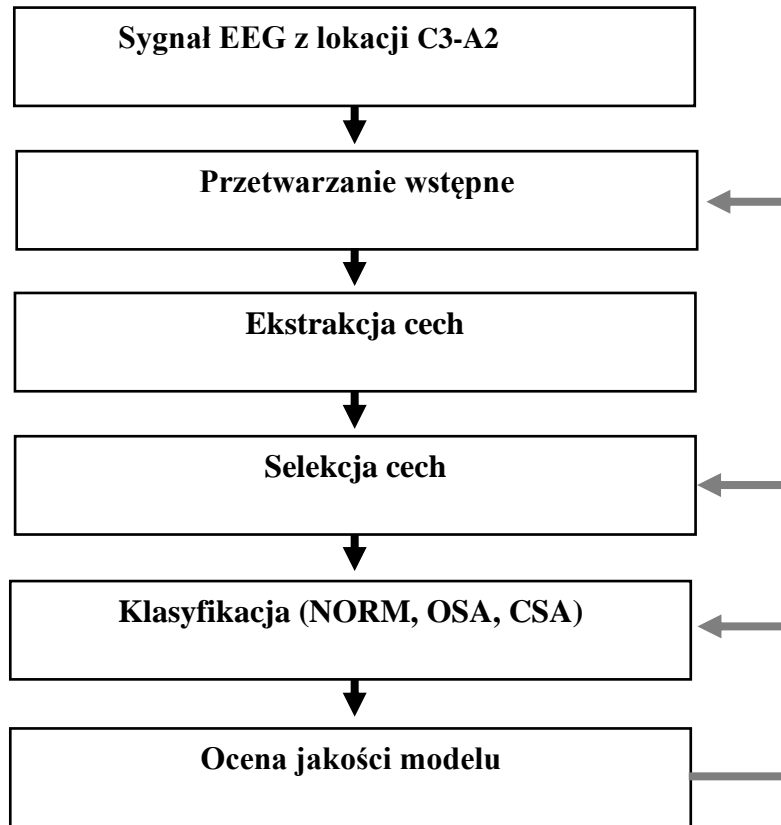
w wyszukanych i przeanalizowanych badaniach. Dokładność klasyfikacji binarnej poniżej 90% oraz brak prac nad rozróżnieniem typu bezdechu na podstawie jednokanałowego sygnału EEG były jedną z motywacji podjęcia badań nad detekcją i różnicowaniem bezdechu sennego, opisanych w niniejszej pracy.

Sama detekcja ilości zdarzeń oddechowych: bezdechów lub słyceń oddychania, umożliwia określenie postaci bezdechu: łagodnej, umiarkowanej, ciężkiej lub ekstremalnej. Natomiast rozróżnienie typu zdarzeń oddechowych: obturacyjnego, centralnego lub mieszanego, jest istotne w kontekście możliwości terapeutycznych i doboru sposobu leczenia, gdyż są to oddzielne jednostki chorobowe o różnych patogenezach. Sygnał EEG, będący zapisem elektrycznej aktywności mózgu, jest bogaty w informacje o stanie organizmu. Zastosowanie EEG do diagnostyki bezdechu może umożliwić obserwację związanych z nim zmian w funkcjonowaniu mózgu, ale również uzyskać pełniejszą informację o przebiegu zdarzenia oraz zaburzeniach w ośrodkowej kontroli oddychania podczas snu. Zaburzenia oddychania (w tym bezdech) manifestują się w przebiegu EEG, zatem diagnostyka z zastosowaniem przenośnych i stosunkowo tanich urządzeń do rejestracji sygnału EEG mogłaby w przyszłości poprawić skuteczność wykrywania zaburzeń oddychania podczas snu. Natomiast analiza tylko najprostszego, jednokanałowego sygnału EEG z całonocnego badania umożliwi sprawdzenie, w jaki sposób zmaksymalizować ilość informacji uzyskanych tylko z jednego odprowadzenia, co w przyszłości może być pomocne w analizie wielokanałowego EEG lub jego połączenia z innymi sygnałami, również w innych zastosowaniach, niż badania snu. Umiejętność analizy sygnału EEG można dalej zastosować w szeregu zadań związanych z pozyskaniem na jego podstawie informacji o innych stanach chorobowych, m. in. związanych z pamięcią, epilepsją, zaburzeniami psychicznymi (np. depresją, nerwicą i schizofrenią) oraz w badaniach nad emocjami i ich rozpoznawaniem

1.2 Rozwiązywany problem i metodyka badań

Biorąc powyższe pod uwagę zidentyfikowano **problem badawczy**, polegający na braku systematycznych prac pokazujących najefektywniejsze metody stosowane na poszczególnych etapach przetwarzania jednokanałowego EEG w kontekście maksymalizacji dokładności nie tylko automatycznego wykrywania bezdechu, ale również różnicowania jego typu. Istotą proponowanej **metodyki** rozwiązania powyższego problemu jest zastosowanie szeregowego przetwarzania sygnału EEG zaprezentowanego

na Rysunku 1.1 poprzez wybór jednego, rekomendowanego sygnału EEG z lokacji C3-A2 i zastosowanie klasycznych etapów przetwarzania sygnału: przetwarzania wstępnego, ekstrakcji i selekcji cech, klasyfikacji i oceny jakości modeli.



Rysunek 1.1. Schemat przedstawiający tor przetwarzania sygnału EEG w celu wyboru optymalnych metod na poszczególnych etapach jego analizy i klasyfikacji bezdechu sennego.

Na podstawie rozeznania literaturowego zdecydowano się na przetestowanie metod, które umożliwiły wysoką dokładność klasyfikacji z wykorzystaniem sygnału EEG w badaniach nad snem i ich przetestowanie na etapie przetwarzania wstępnego, selekcji cech i wyborze klasyfikatora. Wybór suboptymalnych metod został wykonany poprzez ocenę jakości klasyfikacji i maksymalizację uzyskanych wartości trafności (na etapie przetwarzania wstępnego i selekcji cech) oraz średniej dokładności klasyfikacji (przy wyborze struktur klasyfikatorów) w zadaniu trójetykietowej detekcji bezdechu (OSA, CSA) i normalnego oddychania (NORM). Ocena jakości klasyfikacji na etapie przetwarzania wstępnego i selekcji cech została zrealizowana z wykorzystaniem jednego, wybranego klasyfikatora. Metody, które na danym etapie analizy zostały wybrane jako poprawiające dokładność

klasyfikacji, były następnie wykorzystywane w automatycznym rozpoznawaniu bezdechu sennego i jego typu. Tym samym praca ta dotyczy przetwarzania w trybie offline sygnału biomedycznego rejestrowanego elektronicznie za pomocą jednokanałowego elektroencefalografu, które jest ukierunkowane na wspomaganie diagnostyki medycznej.

1.3 Cel pracy i jej teza

Biorąc pod uwagę przedstawiony wyżej problem naukowy, sformułowano **cel pracy**, którym jest 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.

U podstaw prezentowanych badań leży **teza**, że odpowiedni dobór metod przetwarzania jednokanałowego sygnału EEG na poszczególnych etapach: przetwarzania wstępnego, ekstrakcji i selekcji cech, oraz uczenia maszynowego pozwoli na uzyskanie dokładności automatycznego rozróżniania między bezdechem sennym a normalnym oddychaniem oraz różnicowania typu bezdechu większej, niż uzyskano w dotychczasowych badaniach.

1.4 Zawartość pracy

Dysertacja zawiera 9 rozdziałów. W niniejszym rozdziale przedstawiono motywację, cel i tezę oraz zawartość pracy. W Rozdziale 2 zaprezentowano aktualny stan wiedzy odnośnie syndromu bezdechu sennego, jego epidemiologię oraz podstawy metod detekcji epizodów bezdechu. Rozdział 3 w całości jest poświęcony omówieniu wykorzystania sygnału EEG w diagnostyce bezdechu sennego. Przedstawiono podstawy rejestracji sygnału EEG, jego interpretację, badania odnośnie zmian w sygnale związanych z bezdechem oraz dotychczasowe badania nad wykorzystaniem EEG w diagnostyce bezdechu. W Rozdziale 4 przedstawione zostało kilka wybranych baz danych zawierających opisane przez ekspertów wyniki badań nad snem oraz opisano przygotowanie bazy danych wybranej do wykorzystania w dalszych etapach tej pracy. Następne rozdziały prezentują kolejne etapy analizy sygnału EEG, których celem jest klasyfikacja epok EEG jako reprezentujących nie tylko bezdech senny i normalne oddychanie, ale również rozróżnienie bezdechu obturacyjnego i centralnego. W Rozdziale 5 przedstawiono stan wiedzy odnośnie stosowanych metod wstępnego przetwarzania sygnału EEG oraz wybór metod i efekty

zaproprowanego przetwarzania wstępnego. Rozdział 6 dotyczy ekstrakcji cech z epok sygnalu EEG. W pierwszej jego części zostały opisane znane i stosowane metody, natomiast w drugiej zaprezentowano wybrane metody ekstrakcji, w tym zaproponowane przez autora połączenie dyskretnej transformacji falkowej z transformacją Hilberta oraz efekty wykonanej ekstrakcji cech w postaci wektora cech. W Rozdziale 7 opisano metody selekcji cech charakteryzujących epoki EEG, wykonano selekcję cech z zastosowaniem wybranych metod oraz wskazano na najefektywniejszą spośród nich. Uzyskany ostateczny wektor cech został wykorzystany w Rozdziale 8, którego przedmiotem są metody automatycznej klasyfikacji epok EEG. Przedstawione zostały stosowane metody oraz wykonano klasyfikację w obrębie trzech klas z zastosowaniem wybranych algorytmów rozpoznawania bezdechu na podstawie epok EEG oraz określono ich efektywność. W Rozdziale 9 zaprezentowano podsumowanie zrealizowanych prac, przedstawiono wnioski oraz zaproponowano dalsze prace w tym obszarze.

Rozdział 2

Bezdech senny i jego wykrywanie

2.1 Sen

Sen jest jednym z podstawowych stanów ośrodkowego układu nerwowego, który charakteryzuje się zniesieniem świadomości oraz bezruchem. W cyklu dobowym sen występuje naprzemiennie z okresami całkowitego wybudzenia, czyli normalnej aktywności podczas dnia. Zасыпianiu towarzyszy szereg modyfikacji procesów fizjologicznych, powodujących między innymi zmiany w mechanizmie kontroli oddychania, które w rezultacie mogą mieć wpływ na występowanie zaburzeń oddychania podczas snu [137]. Wśród zaburzeń oddychania podczas snu można wyróżnić grupę schorzeń nazywanych bezdechem sennym. Bezdech senny charakteryzuje się powtarzającą się czasową redukcją lub całkowitym zniesieniem respiracji [137], [214], [229], [277], [283].

2.2 Syndrom bezdechu sennego

Według Międzynarodowej Klasyfikacji Zaburzeń Snu (ang. *International Classification of Sleep Disorders (ICSD)*), zjawisko bezdechu sennego jest zaliczane do dyssomnii pochodzenia wewnętrznego, czyli zaburzeń snu charakteryzujących się nieprawidłową jakością, niewystarczającą ilością i czasem trwania snu, których głównej przyczyny należy upatrywać w zmianach zachodzących bezpośrednio w organizmie osoby chorej związanych z nieprawidłową fizjologią lub patologią. Dyssomnie to zaburzenia, które w szczególności powodują trudności z zaśnięciem i utrzymaniem snu lub nadmierną senność. Wśród tego typu zaburzeń, oprócz tych pochodzenia wewnętrznego, wyróżnia się również dyssomnie pochodzenia zewnętrznego oraz związane z zaburzeniami rytmu dobowego. Do dyssomnii pochodzenia wewnętrznego, oprócz bezdechu sennego, zalicza się również bezsenność, zespół niespokojnych nóg, zespół hipowentylacji pęcherzyków płucnych, narkolepsję i zaburzenia związane z nadmierną sennością [17].

Bezdech senny (ang. *Apnea*) jest poważnym zaburzeniem snu, podczas którego u osoby śpiącej występują co najmniej 10. sekundowe przerwy w oddychaniu, powtarzające się wiele razy w ciągu nocy, zazwyczaj połączone ze spadkiem saturacji krwi

tętniczej. Takie przerwy w oddychaniu powodują przerwanie cyklu snu, co ma negatywny wpływ na ogólny stan zdrowia oraz samopoczucie osoby chorej [17], [65].

Oprócz bezdechów, w czasie których występuje całkowite zniesienie oddychania i brak przepływu powietrza przez drogi oddechowe, jako szkodliwe przerwy w oddychaniu wyróżnia się również spłycenia oddychania (ang. *Hypopnea*), charakteryzujące się zmniejszeniem przepływu powietrza przez drogi oddechowe o co najmniej 30% oraz związanym z tym spadkiem poziomu nasycenia tlenem krwi tętniczej o minimum 4%, które trwa 10 sekund lub dłużej [17].

Obserwuje się wiele czynników, które mogą mieć wpływ na wystąpienie bezdechu sennego, dlatego wyróżnia się 3 typy zaburzeń respiracji podczas snu: centralny bezdech senny (ang. *Central Sleep Apnea (CSA)*), obturacyjny bezdech senny (ang. *Obstructive Sleep Apnea (OSA)*) i bezdech senny typu mieszanego (ang. *Mixed Sleep Apnea (MSA)*), [17], [283] (zostały one omówione bardziej szczegółowo w Rozdziale 2.4).

Diagnozę odnośnie występowania bezdechu sennego podejmuje się na podstawie wartości współczynnika bezdechu (ang. *Apnea Index (AI)*) oraz współczynnika bezdechu/spłycenia oddechu (ang. *Apnea-Hypopnea Index (AHI)*), które oblicza się podczas wykonywania całonocnej polisomnografii. Współczynnik bezdechu to liczba epizodów bezdechu wszystkich typów (obturacyjnego, centralnego i mieszanego) na jedną godzinę snu. Czasami, aby porównać częstość występowania, osobno podaje się współczynnik bezdechu obturacyjnego i centralnego. Współczynnik AHI jest liczbą epizodów bezdechu wszystkich typów oraz spłyceń oddechu na jedną godzinę snu.

Ocena nasilenia bezdechu sennego wykonywana jest w oparciu o wskaźnik AHI [103], [128], [234]. Postać łagodna jest rozpoznawana gdy $5 \leq \text{AHI} < 15$, czyli gdy na jedną godzinę snu występuje od 5 do 15 zdarzeń, umiarkowana gdy $15 \leq \text{AHI} < 30$, a ciężka gdy $\text{AHI} \geq 30$ [103], [128]. Ogólnie bezdech senny jest diagnozowany, gdy współczynnik AHI obliczony podczas badania polisomnograficznego jest większy niż 5 oraz gdy u pacjenta występują inne typowe dla bezdechu sennego objawy, np. nadmierna senność w ciągu dnia [234]. Uważa się, że klasyfikacja chorych na podstawie współczynnika AHI jest wystarczająco dobra, mimo że nie uwzględnia odmian bezdechu związanych z wiekiem oraz płcią [103].

2.3 Epidemiologia

Zjawisko bezdechu sennego prawdopodobnie towarzyszyło człowiekowi od wieków. Pierwsze wzmianki o tym schorzeniu można znaleźć już w IV w. [158], jednak dopiero w XIX i XX wieku przeprowadzone zostały liczne badania z udziałem pacjentów z zaburzeniami snu, w tym także cierpiących na tzw. zespół Pickwicka. Umożliwiły one rozwój wiedzy medycznej na temat bezdechu sennego [158], [184]. Jednak szczegółowo został on po raz pierwszy opisany w 1965 roku w oparciu o pomiary sygnałów fizjologicznych wykorzystywanych do diagnostyki depresji i narkolepsji, ze szczególnym uwzględnieniem bezdechu obturacyjnego, [158], [161], [185]. Od tamtego czasu wzrasta świadomość konsekwencji zaburzeń oddychania podczas snu oraz rozwijają się techniki diagnostyki i sposoby leczenia [158]. Co więcej, świadomość przyczyn oraz skutków tej choroby w społeczeństwie powoli wzrastała i od około 25 lat coraz częściej mówi się o drastycznym wzroście liczby chorych na zaburzenia oddychania podczas snu oraz o wpływie, jaki mają one na zdrowie oraz jakość życia osób chorych [32], [119], [178], [321], [335], [336].

Wśród zaburzeń oddychania określanych jako zjawisko bezdechu sennego najczęściej występującym jest bezdech obturacyjny [321]. Uważa się, że znaczący wzrost zachorowań na bezdech obturacyjny jest ściśle związany z globalną epidemią otyłości, ponieważ u osób z nadwagą częściej obserwuje się opadanie górnych dróg oddechowych, które jest jedną z podstawowych przyczyn występowania bezdechu obturacyjnego [183]. Szacuje się, że bezdech obturacyjny może dotyczyć od 2-9% (częściej mężczyzn niż kobiety) [297], a centralny około 1% [89] populacji. Uważa się jednak, że ilość osób doświadczających bezdechów może być większa, ponieważ nie wszyscy są świadomi choroby i nie podejmują leczenia. Najbardziej narażone są osoby z otyłością i w wieku średnim, jednak podkreśla się, że bezdech obturacyjny może wystąpić w każdym wieku, od niemowlęctwa do późnej starości. Największa część pacjentów cierpiących na bezdech mieści się w przedziale wieku od 40 do 60 lat. Kobiety są bardziej narażone na wystąpienie bezdechu obturacyjnego po menopauzie, co związane jest ze zmianami hormonalnymi, które mają wpływ na utrzymanie właściwego napięcia mięśniowego oraz zmiany masy ciała. Wśród osób dorosłych współczynnik chorych mężczyzn do kobiet wynosi 2:1. Natomiast w okresie preadolescencji możliwość zachorowania jest taka sama dla dziewcząt jak i dla chłopców. Opisywane były przypadki dziedziczenia choroby w rodzinie, jednak

u większości pacjentów nie obserwuje się wpływu czynników genetycznych, które warunkowałyby zaistnienie choroby. Według ICSID obserwuje się, że częstość zachorowań na bezdech centralny wzrasta wraz z wiekiem oraz w większym stopniu dotyczy mężczyzn niż kobiet. Ponadto uważa się, że bezdech centralny może być bezobjawowy, dlatego trudno jest oszacować częstość występowania tej choroby w populacji. Uważa się, że bezdech centralny patologiczny jest wtedy, gdy epizody bezdechu wystarczająco często zakłócają sen oraz powodują hipoksemię lub zmiany w pracy serca. Stopień bezdechu centralnego oraz rozwój powiązanych z nim zaburzeń snu są uzależnione od występowania takich czynników, jak choroba naczyń krwionośnych, niewydolność krążeniowo-oddechowa oraz wzrost masy ciała [17].

Dostępne są wyniki wielu badań nad częstością występowania bezdechu sennego w populacji. Jednak niejednorodność metodologiczna wśród przeprowadzonych badań epidemiologicznych powoduje znaczny rozrzut w zakresie liczebności osób chorujących na bezdech senny w badaniach przeprowadzonych wśród poszczególnych populacji, dlatego trudno jest określić, ile w ogólności osób choruje na bezdech senny w populacji ludzi dorosłych [282]. W roku 2017 przeprowadzono przegląd badań epidemiologicznych odnośnie częstości występowania bezdechu obturacyjnego, w którym wśród wielu dostępnych, zostały wybrane 24 badania wykonane w różnych regionach świata i na przestrzeni 30 lat. Wśród analizowanych badań częstość występowania bezdechu obturacyjnego dla $AHI \geq 5$ wahała się od 9% do 38% i była wyższa u mężczyzn niż u kobiet. Zaobserwowano również, że ilość osób chorych na bezdech obturacyjny wzrasta wraz z wiekiem i w niektórych grupach starszych mężczyzn wynosiła aż 90% i 78% wśród kobiet. Ilość chorych na bezdech obturacyjny o $AHI \geq 15$ wynosiła od 6% do 17% wśród całej populacji ludzi dorosłych, a wśród osób starszych aż 49%. Ponadto częstość występowania bezdechu obturacyjnego była większa u otyłych mężczyzn i kobiet. Podsumowując, podstawowymi czynnikami ryzyka zachorowania na bezdech obturacyjny są: starszy wiek, płeć męska i wyższe BMI (wskaźnik masy ciała) [282].

Ogólnie uważa się, że bezdech centralny występuje dużo rzadziej od bezdechu obturacyjnego [160]. Mimo to istnieją badania, które wykazały, że w niektórych populacjach, na przykład wśród mężczyzn chorych na zastoinową niewydolność serca, częstość występowania bezdechu centralnego jest bardzo wysoka i może wynosić nawet 45% [154], [160], [292]. Z badań wynika, że idiopatyczny bezdech centralny jest częstszy

wśród mężczyzn, niż wśród kobiet [40], [41], [160], [292]. Innymi czynnikami ryzyka oprócz płci są: wiek, waga ciała, niewydolność serca oraz zażywania opioidowych leków [137], [160], [292]. Częstość występowania bezdechu centralnego różni się znacznie pomiędzy różnymi jego formami [94]. Jedną z bardziej popularnych form bezdechu centralnego, która może dotknąć znaczną część zupełnie zdrowych osób, jest bezdech spowodowany przebywaniem na znacznej wysokości, przy której może wystąpić niedotlenienie pęcherzyków płucnych i ponadto okresowe oddychanie Cheyena-Stokesa (ang. *Cheyne-Stokes Respiration* (CSR)) podczas snu [94], [325]. Inną formą, na której częstość występowania ma wpływ globalna epidemia otyłości, jest występowanie bezdechu centralnego spowodowanego zespołem hipowentylacji otyłych (ang. *Obesity Hypoventilation Syndrome* (OHS)) [243], [94]. Stosunkowo rzadki jest idiopatyczny bezdech centralny i może on stanowić mniej niż 5% pacjentów ze zdiagnozowanym bezdechem [198], [94]. Jednak w niektórych populacjach obecność bezdechu centralnego może być bardzo wysoka. Przykładem takiej grupy osób są pacjenci z niewydolnością serca i frakcją wyrzutową lewej komory, wśród których częstość występowania bezdechu centralnego może wynosić nawet 37% [94], [156] mimo, że bezdech obturacyjny wśród tej grupy osób stanowi jedynie 12%. Ponadto obserwuje się przypadki, kiedy to bezdech centralny jest przyczyną rozwoju bezdechu obturacyjnego przy podatnej anatomii gardła i górnych dróg oddechowych i odwrotnie, bezdech obturacyjny leczony lub nie, może być przyczyną rozwoju bezdechu centralnego. Uważa się, że zarówno za rozwój bezdechu obturacyjnego jak i centralnego odpowiadają te same lub podobne mechanizmy. Częstość występowania bezdechu centralnego w populacji może być również zaniżona ze względu na kwalifikację epizodów bezdechu, ponieważ aby zdiagnozować bezdech centralny podczas polisomnografii aż 50% lub więcej epizodów bezdechu powinna być pochodzenia centralnego [94].

Niedawno wykonany przegląd literatury z zakresu epidemiologii bezdechu mieszanego, w którym porównane zostało dziewięć różnych badań epidemiologicznych, wskazywał na częstość występowania bezdechu mieszanego w zakresie od 5% [98] do 20,3% [27], [223], [252]. Ponadto w badaniach wykonanych z zastosowaniem urządzenia CPAP (ang. *Continuous Positive Airway Pressure*) w warunkach laboratorium snu, częstość występowania bezdechu mieszanego wynosiła od 5% do 12,1 %, podczas gdy w badaniach z wykorzystaniem całonocnej polisomnografii od 6,5% do 20,3% [223]. Pacjenci ze zdiagnozowanym bezdechem mieszanym charakteryzowali się wiekiem od 44

do 65 lat oraz średnim BMI między 29 a 36 kg · m⁻² [27], [223]. Większość chorych, bo aż od 81% do 99%, stanowili mężczyźni. Dla dwóch badań, wykonanych na największej próbie pacjentów, częstość występowania bezdechu mieszanego wyniosła 5% [98] i 6,5% [27], [155], [223]. W sumie wśród 4375 pacjentów ze zdiagnozowanym bezdechem obturacyjnym, jedynie 366 osób wykazywało objawy umożliwiające zdiagnozować bezdech mieszany. Daje to łączną częstość występowania bezdechu mieszanego wśród populacji chorych na bezdech obturacyjnego na poziomie 8,37% [27], [223]. Na podstawie przeprowadzonych badań epidemiologicznych określono podstawowe czynniki ryzyka zachorowania na bezdech mieszany, którymi są: starszy wiek, wyższy wskaźnik AHI oraz większa częstość występowania epizodów bezdechu centralnego, płeć męska [27]. Innymi czynnikami sprzyjającymi rozwojowi bezdechu mieszanego są: niska waga ciała, używanie w przeszłości narkotyków, leczenie bezdechu obturacyjnego z wykorzystaniem CPAP oraz obecność takich schorzeń, jak niewydolność krążeniowo-oddechowa i choroby niedokrwiennej serca [27].

Na podstawie omawianych badań nad częstością występowania bezdechu sennego w społeczeństwie szacuje się, że na bezdech senny może cierpieć nawet 936 milionów ludzi na świecie, w tym około 175 milionów Europejczyków. W Polsce na ten typ zaburzeń oddychania podczas snu może chorować około 1,5 miliona ludzi. W związku z dość dużą częstością występowania bezdechu sennego w społeczeństwie, jego wpływem na zdrowie i samopoczucie oraz funkcjonowanie chorych cierpiących na zaburzenia oddychania podczas snu, widać jest jak ważne jest kontynuowanie badań na rozwojem metod wykrywania bezdechu sennego. Szczególnie dotyczy to metod automatycznych, które mogą pomóc zwiększyć dostępność przesiewowych badań diagnostycznych.

2.4 Typy bezdechu sennego

2.4.1 Bezdech obturacyjny

Bezdech obturacyjny jest zaburzeniem oddychania podczas snu, które charakteryzuje się powtarzającymi się epizodami zatrzymania przepływu powietrza wynikającego z niedrożności górnych dróg oddechowych, przy zachowanym rytmie oddechowym, zwykle powiązanego z obniżeniem saturacji krwi tętniczej. Za bezpośrednią przyczynę bezdechu obturacyjnego uważa się zwężanie górnych dróg oddechowych spowodowane nadmierną ilością tkanek miękkich lub nieprawidłową

anatomią czaszkowo-twarzową nosa lub jamy ustnej i nosogardła, oraz osłabionym napięciem mięśniowym. Ponadto u niektórych pacjentów neurologicznych specyficzne uszkodzenie układu nerwowego może mieć wpływ na kontrolę mięśni gardła, a tym samym być odpowiedzialne za rozwój bezdechu obturacyjnego [17].

Jednym z podstawowych objawów bezdechu obturacyjnego jest głośne chrapanie powiązane z krótkimi oddechami oraz okresami ciszy, trwające zazwyczaj od 20 do 30 sekund. Chrapanie jest zwykle tak głośne, że zakłóca sen innych osób śpiących w tym samym pomieszczeniu. Osoba chora zazwyczaj wie o tym, że chrapie, jednak podczas snu nie zdaje sobie sprawy z jego intensywności. Ponadto objaw, którym jest chrapanie, może towarzyszyć choremu od wielu lat i zaostrzać się po spożyciu alkoholu lub przy znacznym wzroście masy ciała. Wśród innych nocnych objawów bezdechu obturacyjnego, oprócz epizodów bezdechów i chrapania, wyróżnia się wzmożoną aktywność motoryczną podczas snu, wybudzenia powiązane z uczuciem duszności, dławienia i dyskomfortu w klatce piersiowej, które dodatkowo często połączone są z uczuciem silnego lęku, zaburzenia rytmu serca, nokturię oraz wrażenie, że sen nie przynosi wypoczynku. Bezdechowi obturacyjnemu towarzyszą również objawy pojawiające się w ciągu dnia, a wśród nich najbardziej powszechnym jest wzmożona senność w ciągu dnia, która jest najbardziej widoczna podczas czynności relaksujących lub takich, w których osoba chora pozostaje częściowo bierna, jak czytanie, oglądanie telewizji, uczestnictwo w koncertach i spektaklach teatralnych, oraz podczas różnych spotkań grupowych, wykładów i szkoleń. W skrajnych przypadkach nadmiernej senności pacjent może zasnąć nawet podczas rozmowy, jedzenia, wykonywania pracy zawodowej, chodzenia lub prowadzenia samochodu. Wśród pozostałych objawów bezdechu obturacyjnego obserwuje się ranne bóle głowy, suche usta po przebudzeniu, obniżoną zdolność koncentracji, pogorszenie funkcji intelektualnych oraz stan obniżonego nastroju i zaburzenia depresyjne [17], [70], [95], [183].

2.4.2 Bezdech centralny

Bezdech centralny to zaburzenie oddychania podczas snu, charakteryzujące się całkowitym zniesieniem lub zmniejszeniem wysiłku wentylacyjnego mięśni oddechowych, powiązany ze spadkiem saturacji krwi tętniczej [17]. Bezpośrednią przyczyną bezdechu centralnego zazwyczaj są różne uszkodzenia ośrodkowego układu nerwowego, które mają wpływ na pracę pólkul mózgowych lub pnia mózgu. Jednak u większości pacjentów nie

można zidentyfikować specyficznych anatomicznych nieprawidłowości. Zauważa się, że przerwy w oddychaniu zdiagnozowane jako bezdech centralny są bezpośrednio powiązane z oscylacjami związanymi z fizjologiczną pętlą sprzężenia zwrotnego pomiędzy układem oddechowym, a mózgiem.

Objawami bezdechu centralnego zazwyczaj są bezsenność (insomnia) i problemy z zasypianiem lub nadmierna senność. Często również pojawiają się przebudzenia podczas snu nocnego powiązane z uczuciem duszności oraz krótkimi, szybkimi oddechami. Niektórzy pacjenci nie odczuwają żadnego dyskomfortu podczas snu ani podczas dnia, a mimo to zgłaszają się do diagnostyki z powodu obserwacji ich snu przez inną osobę. Innymi objawami są: uczucie snu, które nie przynosi wypoczynku, zmęczenia i senności podczas dnia. U chorych na bezdech centralny obserwuje się również epizody bezdechów obturacyjnych oraz okresy hipowentylacji. Jednak wśród wszystkich epizodów bezdechu i spłycenia oddechu dominują epizody bezdechu centralnego [17]. Wśród innych cech towarzyszących bezdechowi centralnemu wyróżnia się chrapanie oraz powikłania powiązane z bezdechem, takie jak nadciśnienie, arytmia serca, niewydolność krążeniowo-oddechowa i nadciśnienie płucne. Te schorzenia towarzyszące bezdechowi centralnemu mogą unaoczniać pierwotne zaburzenia układu sercowo-naczyniowego, które są źródłem prowadzącym do rozwoju bezdechu centralnego. Ponadto mogą występować zaburzenia pamięci i funkcji poznawczych, wynikające z nadmiernej senności, bóle głowy po przebudzeniu. Czasami pacjenci uskarżają się na problem z libido. Mogą również wystąpić epizody depresyjne i stany obniżonego nastroju. Bezdech centralny jest często powiązany z innymi schorzeniami i to one mogą być przyczyną rozwoju tego zaburzenia. Takimi czynnikami predysponującymi mogą być choroba układu krążenia czy zaburzenia neurologiczne, które mogą mieć wpływ na mechanizm kontroli wentylacji przez centralny układ nerwowy, np. uszkodzenie półkul mózgowych, pnia mózgu i rdzenia kręgowego. Ponadto nadmierna masa ciała również może zaostreć rozwój i przebieg bezdechu centralnego [17], [137], [214], [229], [277], [283].

2.4.3 Bezdech mieszany

Bezdech mieszany to zaburzenie oddychania podczas snu, charakteryzujące się tym, że źródłem epizodu bezdechu jest zarówno czynnik pochodzenia centralnego jak i czynnik obturacyjny. U niektórych pacjentów częste epizody bezdechu centralnego obserwuje się po podjęciu leczenia bezdechu obturacyjnego z wykorzystaniem aparatu CPAP i w takich

sytuacjach diagnozowany jest bezdech mieszany [17], [27], [186], [212], [321]. Terapia z wykorzystaniem protezy powietrznej CPAP jest standardową metodą leczenia bezdechu obturacyjnego, która umożliwia utrzymanie przepływu powietrza w drogach oddechowych [321]. Proteza powietrzna CPAP jest urządzeniem, które zapewnia wytwarzanie ciągłego dodatniego ciśnienia wdychanego powietrza, co pozwala na pokonanie bariery zapadania górnych dróg oddechowych, dzięki czemu umożliwia normalny wdech i neutralizuje wzbudzenia wywoływane występowaniem bezdechu sennego [70], [321].

Objawy bezdechu mieszanego są podobne do objawów występujących u pacjentów cierpiących na bezdech obturacyjny jak i na bezdech centralny. Wśród podstawowych można wyróżnić senność oraz związany z tym dłuższy sen i trudności z wybudzeniem się, chrapanie, zaburzenia funkcji poznawczych, drażliwość, zaburzenia koncentracji, problem z pamięcią, drażliwość i poranne bóle głowy.

2.5 Polisomnografia

Diagnostyka zjawiska bezdechu sennego, oprócz stwierdzenia uczucia senności w ciągu dnia i innych subiektywnych objawów, wymaga obiektywnej oceny, która jest wykonywana podczas badania zwanego polisomnografią [47], [158], [170]. Polisomnografia jest badaniem diagnostycznym uważanym za *złoty standard* diagnostyki bezdechu sennego i innych zaburzeń snu. Wykonywana jest podczas snu nocnego i polega na pomiarze oraz zapisie różnych sygnałów fizjologicznych, które umożliwią ocenę długości i jakości snu nocnego oraz przebiegu oddychania [47], [158]. Standardowo całonocne badanie wykonuje się w laboratorium snu z wykorzystaniem specjalistycznego sprzętu diagnostycznego, który umożliwia pomiar wielu sygnałów fizjologicznych [58]. Polisomnografia umożliwia ocenę jakościową i ilościową snu między innymi poprzez zliczanie epizodów bezdechu sennego, a następnie obliczeniu współczynnika bezdechu/spłycenia oddychania (AHI) oraz współczynnika bezdechu (AI). Na tej podstawie określono minimalną wartość $AHI \geq 5$, powyżej której diagnozuje się u osoby badanej bezdech senny [58], [254].

Z jednej strony całonocna polisomnografia w dokładny sposób odwzorowuje stan fizjologiczny pacjenta, z drugiej jest to długie, kosztowne badanie, wykonywane poza domem, a ponadto analiza wyników jest bardzo pracochłonna i musi być wykonywana przez eksperta. Podczas polisomnografii wykonywane są pomiary takich sygnałów, jak:

przepływ powietrza przez drogi oddechowe (przy ustach lub przy nosie), pomiar saturacji tlenem krwi tętniczej (SaO_2), pomiar wysiłku oddechowego (ruchów oddechowych klatki piersiowej i brzucha), akustyczny pomiar odgłosów oddechowych (w tym chrapania), fotopletyzmografia (PPG), elektrokardiografia (EKG), pomiar ciśnienia krwi, elektroencefalografia (EEG), elektrookulografia (EOG) czy elektromiografia (EMG). Standardowe podejście do diagnostyki bezdechu sennego na podstawie polisomnografii, zgodne z zaleceniami American Academy of Sleep Medicine (AASM), polega na wykryciu i rozróżnieniu (przez eksperta lub dwóch niezależnych ekspertów) epizodów bezdechu i/lub splotenia oddechu, a następnie obliczeniu ich średniego występowania na jedną godzinę snu [1].

2.6 Automatyzacja diagnostyki bezdechu sennego

Aktualnie cały czas prowadzone są badania nad automatyzacją polisomnografii, która usprawniłaby i przyspieszyła diagnostykę zaburzeń snu oraz umożliwiła przeprowadzanie tańszych, ale wciąż wiarygodnych badań przesiewowych. Ponadto, podczas wielu badań próbuje się oba te procesy zautomatyzować, a ich wyniki porównywać z analizą wykonywaną przez ekspertów.

Identyfikację poszczególnych zdarzeń (bezdechów oraz splotień oddychania) wykonuje się na podstawie analizy zarejestrowanych przebiegów sygnałów fizjologicznych. Aby zautomatyzować ten proces, wykorzystuje się zaawansowane metody przetwarzania danych. Ta automatyczna analiza wybranych sygnałów może być wykonywana w trybie *offline* lub w czasie rzeczywistym przy wykorzystaniu właśnie zarejestrowanych próbek. Analiza wykonywana jest najczęściej w obrębie fragmentów sygnału o równym czasie, które są nazywane epokami. Wykrywanie epizodów bezdechu lub splotenia oddychania wykonuje się przede wszystkim na podstawie analizy przepływu powietrza przez drogi oddechowe oraz saturacji krwi tętniczej, ale też na podstawie innych zarejestrowanych sygnałów. Najczęściej wykrywanie epizodów bezdechu jest wykonywane na podstawie przepływu powietrza przez drogi oddechowe [26], [33], [47], [125], [126], [141], [202], [211], [261], [269], [270], [273] lub na podstawie sygnału oddechowego pochodzącego z EKG (ang. *ECG-Derived Respiratory Signal* (EDR)) [20], [45], [147], [166], [196], [205]. Epizody bezdechu wykrywane są również na podstawie ruchów oddechowych (ruchów klatki piersiowej i brzucha), z których obliczana jest różnica fazowa [11], [141], [273], [304] oraz na podstawie sygnału akustycznego, którym są

dźwięki oddechowe [84], [85], [273], [296], [330]. Zmiany poziomu saturacji tlenem krwi tętniczej umożliwiają pośrednią obserwację epizodów bezdechu z pewnym opóźnieniem [47], [202], [210], [273], [330]. Ponadto, na podstawie analizy saturacji krwi, możliwa jest ilościowa ocena poprzez obliczenie liczby spadków SaO₂ poniżej progu 4% na godzinę snu [13], [46], [68], [269], [303], [328] oraz poprzez obliczenie łącznego czasu snu, w którym poziom SaO₂ wynosił poniżej 90% [13], [46], [68], [328]. Spośród innych sygnałów wykorzystywanych do wykrywania epizodów bezdechu i spłycenia oddychania najbardziej popularne są: elektrokardiogram [11], w szczególności zmienność rytmu serca wydobywana z EKG [24], [45], [55], [112], [122], [134], [135], [166], [199], [205], [210], [273], [320], [328], [333], fotopletyzmoграфия (PPG), która jest powiązana z aktywnością mechaniczną serca [118], [303] lub pulsoksymetria [224], [303]. EKG w połączeniu z PPG umożliwiają obliczenie czasu propagacji *fali tętna* obwodowego (ang. *Pulse Transit Time* (PTT)), którego oscylacje są skorelowane z epizodami bezdechu obturacyjnego [67], [118]. Analiza sygnału EEG, w tym wykrywanie wzbudzeń (ang. *arousals*) [15], [16], [60], [107], [201], [290], [300], oraz analiza sygnału EMG, który umożliwia ocenę napięcia mięśni podbródka [15], [16], [21], [213], [273] lub ruchów żuchwy [202], również mogą być wykorzystywane w celu wykrycia epizodów bezdechu. Zazwyczaj w celu precyzyjnej oceny ilości epizodów bezdechu i/lub spłycenia oddychania wykonuje się analizę kilku powiązanych ze sobą sygnałów fizjologicznych. Ponadto, efektywność wykrywania zależy nie tylko od rodzaju użytych sygnałów, ale również od wykorzystanej metody ich przetwarzania. Na podstawie takiej analizy, oprócz współczynników AHI i AI, oblicza się również współczynnik zaburzeń oddechowych RDI (ang. *Respiratory Disturbance Index*), który definiuje się jako ilość epizodów bezdechu i spłycenia oddechu na godzinę od położenia się spać do wstania z łóżka (wliczając to czas przed zaśnięciem i po wybudzeniu, ale przed wstaniem).

Przetwarzanie sygnałów polisomnograficznych, którego celem jest analiza zarejestrowanych danych pomiarowych, umożliwiające jakościową i ilościową ocenę snu, zazwyczaj jest wykonywane poprzez zastosowanie metodyki składającej się z następujących kroków: przetwarzania wstępnego, ekstrakcji cech, selekcji cech, klasyfikacji oraz oceny jakości metody. Na każdym z etapów przetwarzania stosowanych jest wiele typów metod, a wybór konkretnej z nich zależy przede wszystkim od sygnału, który jest analizowany.

Rozdział 3

Sygnal EEG i jego wykorzystanie w diagnostyce bezdechu sennego

W tym rozdziale przedstawiony został aktualny stan wiedzy na temat sygnału elektroencefalograficznego (EEG) oraz jego analizy ukierunkowanej na wspomaganie diagnostyki bezdechu sennego.

3.1 Biofizyczne podstawy elektroencefalografii

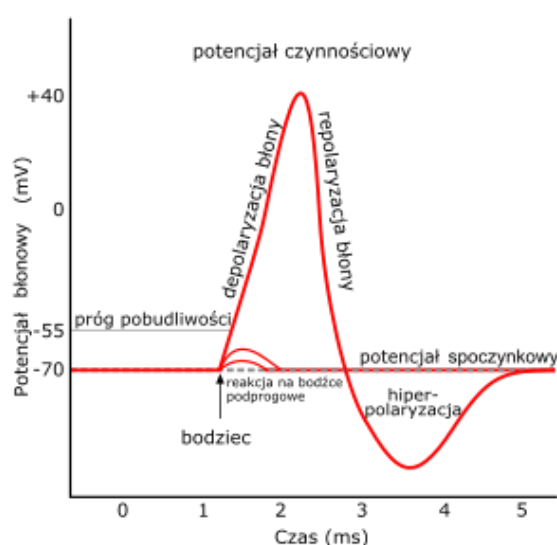
3.1.1 Powstawanie sygnału EEG

3.1.1.1 Źródła prądowe w mózgu

Ludzki mózg składa się z ponad 100 miliardów neuronów, z których większość ma zdolność oddziaływania na wiele innych neuronów [139]. Jedną z podstawowych funkcji układu nerwowego jest komunikacja realizowana w procesie sygnalizacji. W układzie nerwowym można wyróżnić dwa podstawowe rodzaje komórek: komórki nerwowe (neurony) i komórki neurogleju (glejowe). Neurony zbudowane są z dendrytów, które otrzymują informację, ciała komórki, które przetwarza otrzymaną informację i aksonu, który przenosi sygnały do innych obszarów mózgu. Komórki glejowe nie uczestniczą bezpośrednio w przewodzeniu impulsów elektrycznych, ale wspierają prawidłową pracę komórek nerwowych. Można wyróżnić trzy główne rodzaje komórek glejowych: astrocyty, które utrzymują prawidłowe środowisko metaboliczne dla przekazywania sygnałów przez neurony, oligodendrocyty, które mielinują neurony oraz komórki mikrogleju, które są odmianą makrofagów rezydującą w ośrodkowym układzie nerwowym (OUN) i pomagają w regeneracji mózgu po urazie [139].


Wszystkie komórki nerwowe mają dwuwarstwowe błony lipidowe, które oddzielają wnętrze komórki od środowiska zewnętrznego oraz są izolatorem, oddzielającym różne stężenia jonów wewnątrz od jonów na zewnątrz komórki. Aktywność kanałów jonowych ma fundamentalne znaczenie dla procesu sygnalizacji w układzie nerwowym. Ruch jonów przenosi ładunek elektryczny przez kanały jonowe i powoduje zmiany napięcia na błonie. Różnica potencjałów pomiędzy wnętrzem komórki nerwowej, a jej otoczeniem, wynikająca z różnicy w stężeniu jonów po obu stronach błony, nazywana jest potencjałem

błonowym. Zazwyczaj na powierzchni błony znajduje się więcej jonów dodatnich niż w jej wnętrzu. W stanie spoczynku nie obserwuje się przepływu jonów przez błonę komórkową i obserwowany wtedy stan nazywa się potencjałem spoczynkowym, którego wartość w neuronach zazwyczaj wynosi około -70 mV, ale może również być mniejszy lub większy i mieści się w zakresie od -40 mV do -90 mV [139], [242]. Utrzymujący się potencjał spoczynkowy umożliwia przekazywanie impulsów po reakcji neuronu na bodźce, a wbudowanym w błonę aktywnym mechanizmem, który utrzymuje ten potencjał jest pompa sodowo-potasowa, która umożliwia utrzymanie większej ilości jonów sodu na zewnątrz, a jonów potasu wewnątrz neuronu. Bodźce, nazywane również impulsami, powodują wytrącenie neuronu z równowagi i, jeśli przekroczony zostanie próg pobudliwości, który zazwyczaj wynosi -55 mV, wtedy wygenerowany zostanie potencjał czynnościowy, który umożliwia przekazywanie informacji pomiędzy neuronami. Potencjał czynnościowy rozpoczyna się nagłym i gwałtownym przepływem jonów sodu do wnętrza komórki przez błonę, co nazywane jest depolaryzacją błony, czego efektem jest wzrost potencjału błonowego do około 40 mV, przy których następnie potencjał zaczyna maleć, gdy jony potasu zaczynają przenikać na zewnątrz komórki, proces ten nazywany jest repolaryzacją błony. Następnie przez pewien czas neuron jest nieaktywny jest w stanie hiperpolaryzacji przez okres refrakcji aby z powrotem wrócić do stanu spoczynkowego, w którym komórka nerwowa może reagować na kolejne impulsy [78], [139], [242]. Schemat przedstawiający zmiany potencjału błonowego, w tym przejście od potencjału spoczynkowego do czynnościowego został przedstawiony na Rysunku 3.1 poniżej.



Rysunek 3.1. Schemat przedstawiający zmiany wartości potencjału błonowego komórki nerwowej podczas trwania potencjału czynnościowego [Źródło: [221]].

Potencjał czynnościowy propaguje wzdłuż aksonu do synapsy, która znajduje się przy zakończeniu aksonu i jest błoną, umożliwiającą komunikację z inną komórką nerwową lub inną docelową komórką. Neuron, który przekazuje pobudzenie dalej nazywa się neuronem presynaptycznym, a ten, który go odbiera – postsynaptycznym. Procesy chemiczne zachodzące w komórce mogą powodować zmiany potencjału błonowego wzdłuż błony neuronu postsynaptycznego i związane z tym powstanie pobudzającego (ang. *Excitatory Postsynaptic Potential* (EPSP)) lub hamującego (ang. *Inhibitory Postsynaptic Potential*, (IPSP)) potencjału postsynaptycznego. EPSP powoduje wzbudzenie potencjału czynnościowego i przekazywanie impulsu dalej, natomiast IPSP utrzymuje neuron w potencjale spoczynkowym. Sumowanie przychodzących do komórki EPSP i IPSP ma wpływ na dalsze przekazywanie impulsu do kolejnych neuronów [242]. W wielu warstwach kory mózgowej dominują neurony piramidalne, ułożone równoległe do siebie i prostopadle względem powierzchni czaszki. Aktywność synaptyczna różnych grup tych komórek kory mózgowej, której efektem jest powstanie EPSP i IPSP, powoduje również przepływ prądów w środowisku zewnątrzkomórkowym, których efektem jest powstanie zmiennego pola elektrycznego. Ułożenie neuronów piramidalnych skutkuje sumowaniem się pól elektrycznych poszczególnych komórek, co powoduje powolne ich zanikanie i możliwość obserwacji potencjału dodatniego i ujemnego na powierzchni skóry czaszki [326]. Schemat przedstawiający przekrój czaszki oraz źródła prądowe sygnału EEG w mózgu jest zaprezentowany na Rysunku 3.2.



Rysunek 3.2 Schemat czynności elektrycznej neuronów piramidowych w czasie rejestracji sygnału EEG [Źródło:[293]].

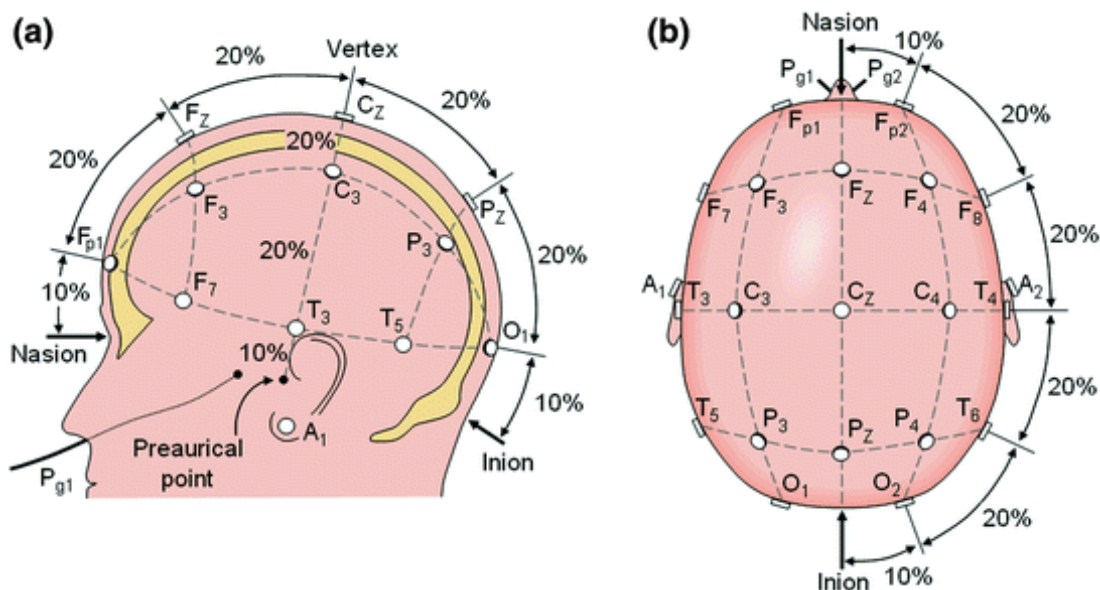
3.1.1.2 Sygnał EEG

Elektrody stosowane do rejestracji sygnału EEG umożliwiają rejestrację jedynie zbiorczej aktywności grup neuronów o synchronicznej aktywności elektrycznej. Potencjały czynnościowe mogą mieć dużą amplitudę (70-110 mV), ale ich czas trwania jest krótki (0,3 ms), dlatego możliwość synchronicznych potencjałów czynnościowych wielu komórek jest mało prawdopodobna. To potencjały postsynaptyczne o amplitudzie 0,1-10 mV, pochodzące z synchronicznej aktywności neuronów korowych, których czas trwania wynosi 10-20 ms, są generatorami pola potencjału zewnątrzkomórkowego, którego zmiany mogą być rejestrowane za pomocą elektrod ułożonych na powierzchni skóry głowy. Rejestrowany sygnał jest sumą wielu pól elektrycznych generowanych w pobliżu elektrody pomiarowej. Zakres amplitudy rejestrowanego sygnału EEG jest rzędu mikrowoltów [127], [139]. Aktywność głębszych struktur mózgu, takich jak hipokamp, wzgórze i pień mózgu, nie może być obserwowana bezpośrednio z wykorzystaniem EEG. Jednak przenoszenie impulsów elektrycznych z tych miejsc do kory mózgowej ma wpływ na kształt sygnału EEG. Przykładem takiej aktywności widocznej w sygnale EEG są wrzeciona, które są wynikiem interakcji pomiędzy komórkami wzgórza a komórkami kory mózgowej [139]. Efektem tej skomplikowanej neuronalnej aktywności elektrycznej jest generowanie nieregularnych sygnałów EEG, które pozornie wydają się wręcz

bezludnymi i ciągle zmieniającymi się falami EEG [272]. Mimo to, zarówno wzorce, czyli charakterystyczne fragmenty sygnału, widoczne podczas czuwania jak i podczas snu, mają charakter rytmiczny. Wśród fizjologicznych mechanizmów odpowiadających za rytmiczność sygnału EEG wyróżnia się dwa procesy: interakcję między korą a wzgórzem oraz funkcjonalną charakterystykę aktywności dużych sieci neuronowych w korze, które posiadają zdolność do tworzenia rytmiczności [272]. Skutkiem tych mechanizmów jest wytwarzanie rozpoznawalnych wzorów EEG, charakterystycznych dla określonych obszarów kory mózgowej, dzięki którym możliwe jest zrozumienie występowania różnych fal mózgowych.

3.1.1.3 Rejestracja sygnału EEG

Aktualnie obowiązującym standardem rozmieszczenia elektrod podczas rejestracji sygnału EEG jest utworzony w latach 50. Międzynarodowy system umieszczania elektrod 10-20 (Rysunek 3.3) [153]. System ten standaryzuje rozmieszczenie i oznaczenie elektrod na powierzchni skóry głowy. Powierzchnię czaszki podzielono na proporcjonalne odległości od punktów charakterystycznych czaszki: nasion – zagłębienie na szczycie nosa, punktów przeduszných oraz inionu – wypukłości w linii środkowej podstawy potylicy, tak aby zapewnić równomierne pokrycie wszystkich obszarów mózgu. Etykieta 10-20 określa proporcjonalną odległość w procentach między uszami, a nosem, w której wybierane są punkty dla elektrod. Miejsce umieszczania elektrod określone jest literami na podstawie nazw sąsiadujących obszarów mózgu: F (*frontal*) czołowa, C (*central*) centralna, T (*temporal*) skroniowa, P (*posteriori*) tylna i O (*occipital*) potyliczna, którym towarzyszą liczby nieparzyste, dla elektrod po lewej stronie głowy i parzyste dla tych po prawej [272], [309]. Do pomiaru EEG można stosować elektrody bipolarne, wtedy mierzy się różnicę potencjałów między parą elektrod lub jednobiegunowe, wtedy potencjał każdej metody jest porównywany z elektrodą neutralną lub średnią ze wszystkich elektrod [309].



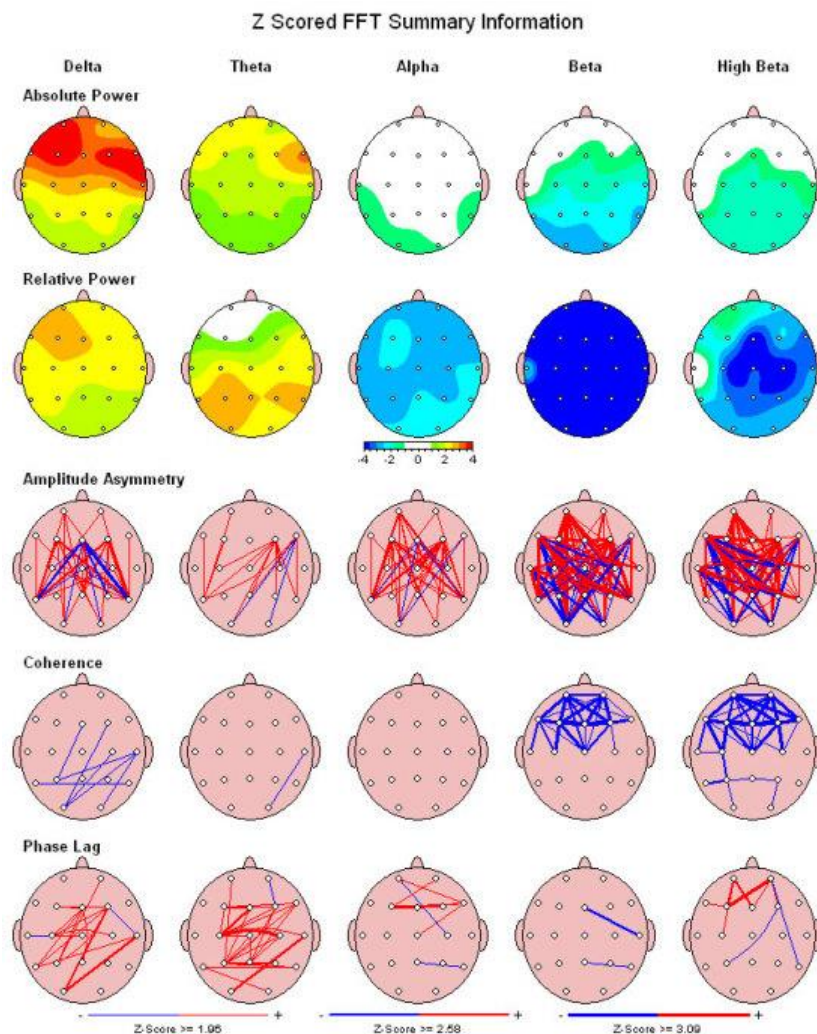
Rysunek 3.3 Rozmieszczenie elektrod na powierzchni głowy w międzynarodowym systemie umieszczania elektrod 10-20 [Źródło:[293]].

3.1.1.4 Interpretacja sygnału EEG

Interpretacja sygnału EEG powinna być wykonywana w oparciu o znajomość prawidłowego zapisu EEG, rejestrowanego u osoby zdrowej. Ponadto, poza zmiennością międzypersonalną należy również brać pod uwagę różnice spowodowane wiekiem – sygnał EEG ulega zmianom w trakcie życia człowieka, stąd wynikają pewne różnice w EEG, szczególnie u niemowląt, dzieci i osób starszych. Jedną z procedur elektroencefalograficznych o największym znaczeniu diagnostycznym jest rejestracja elektrycznej aktywności mózgu podczas snu [272]. Związane jest to z faktem, że podczas snu nawet niewielkie nieprawidłowości zapisu EEG wykonanego podczas czuwania mogą być bardziej zauważalne lub pojawić się inne, charakterystyczne dla stanu snu [272]. Istotna jest również umiejętność rozróżnienia artefaktów, będących przejściowymi potencjałami, których źródłem nie jest elektryczna aktywność mózgu, występujących w sygnale od zjawisk fizjologicznych. Wśród artefaktów i zakłóceń można wyróżnić „trzaskanie” elektrody i różne rytmiczne częstotliwości, związane z nieprecyzyjnym przyleganiem elektrod, czynnościowe potencjały mięśniowe, zakłócenia związane z ruchem, artefakty z EKG oraz z tętna, związane z pracą innych urządzeń, np. respiratora, zakłócenia częstotliwością 50 Hz, które związane są z bliskością aparatury elektronicznej lub złym uziemieniem [272].

3.1.1.5 Ilościowe EEG (ang. *Quantitative EEG* (qEEG))

Ilościowe EEG (ang. *Quantitative EEG* (qEEG)) nazywane jest również mapowaniem mózgu i polega na rejestracji sygnału EEG z powierzchni głowy, a następnie zastosowanie matematycznych procedur do przekształcenia zarejestrowanych danych z wykorzystaniem bazy danych pochodzącej od zdrowych osób w celu porównania zarejestrowanej aktywności mózgu pacjenta z aktywnością innych osób oraz zaobserwowania różnic (Rysunek 3.4). W tym celu sygnał EEG jest filtrowany w celu podziału na składowe odpowiadające częstotliwości fal mózgowych. Następnie uzyskane składowe są porównywane z zapisami w bazach danych i tworzone są kolorowe mapy, naniesione na kulisty model mózgu, których interpretacja umożliwia uzyskanie odpowiedzi na to, w jakich obszarach pojawia się dana aktywność mózgu [214], [253].



Rysunek 3.4. Przykład qEEG [Źródło: [253]].

3.1.2 Prawidłowy zapis EEG osoby dorosłej

W prawidłowym zapisie EEG, wykonanym u zdrowej osoby dorosłej, można wyróżnić następujące fale mózgowie: *delta*, *theta*, *alfa*, *beta*, *gamma*, przedstawione na Rysunku 3.5 oraz fale *mu* i *lambda*.

Fale *delta* o częstotliwości od 0 Hz do 4 Hz są wolnymi i wysokonapięciowymi potencjałami. Ogniskowa aktywność tych fal jest rzetelnym wskaźnikiem miejscowego uszkodzenia mózgu [272]. W prawidłowym zapisie EEG podczas czuwania u osoby dorosłej fale *delta* nie powinny występować. Natomiast w czasie czuwania występują u niemowląt i małych dzieci. Zdarza się to również wśród młodzieży w tylnych odprowadzeniach i nie jest to zjawisko nieprawidłowe oraz u osób starszych, co jednak jest związane z pewną dysfunkcją mózgu. Są jednak integralną częścią prawidłowego zapisu EEG podczas snu. Fale *delta* o bardzo wysokiej lub bardzo niskiej amplitudzie mogą wskazywać na poważną dysfunkcję mózgu [272].

Fale *theta* o zakresie częstotliwości od 4 Hz do 7 lub 8 Hz występują zwykle podczas stanu czuwania, jednak mogą również nie występować. Częściej są bardziej wyraźne w odprowadzeniach z linii środkowej i skroniowych. Zwiększone występowanie fal *theta* zwykle jest związane sennością. Rozkład tego rytmu w odprowadzeniach powinien być symetryczny. Ogniskowe występowanie fal *theta* może świadczyć o uszkodzeniu strukturalnym mózgu.

Fale *alfa* są pierwszym rytmem, odkrytym przez Hansa Bergera w 1929 r., który został opisany na podstawie sygnału EEG. Dominują w stanie rozluźnienia podczas czuwania z zamkniętymi oczami. Zanikają po otwarciu oczu. Fale *alfa*, o częstotliwości od 7 lub 8 Hz do około 15 lub 16 Hz, są głównym, podstawowym rytmem prawidłowego zapisu EEG osoby dorosłej. Największą amplitudę fal *alfa* obserwuje się w okolicach potylicznych, może też ona przechodzić na obszary skroniowe tylne i ciemieniowe. Rzadko obserwuje się fale *alfa* u osób zdrowych, bez schorzeń neurologicznych, w okolicach czołowych [272].

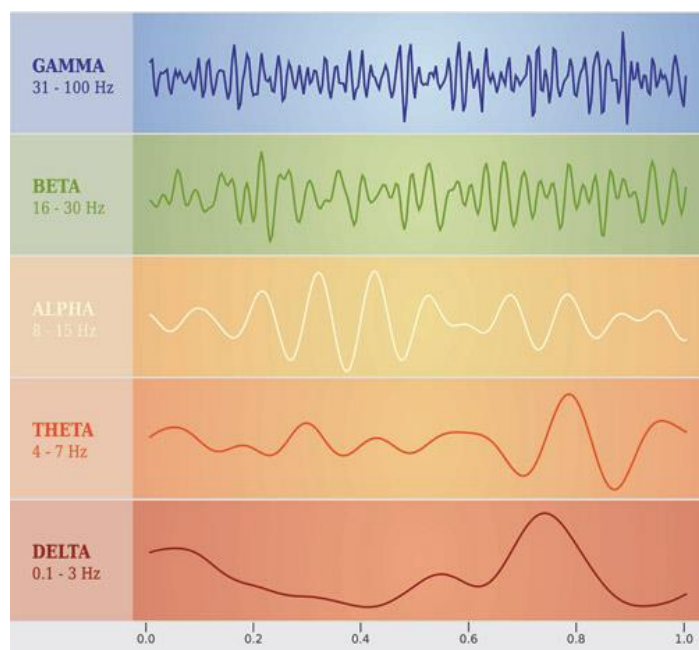
Fale *beta* są drugim rodzajem fal, który również został opisany przez Hansa Bergera. Są to fale o częstotliwości od mniej więcej 14 Hz do około 30 Hz i rytmicznym charakterze. U większości osób stanowią tło zapisu EEG. Amplituda tych fal ma znaczne wahania, jednak cecha ta ma niewielkie znaczenie diagnostyczne. Podczas analizy sygnału

EEG fale *beta* należy odróżnić od czynnościowych potencjałów mięśniowych, które również mogą być rytmiczne, jednak trwają krócej niż fale *beta*. Maksymalną amplitudę fal *beta* obserwuje się zwykle w okolicach czołowo-centralnych, ale mogą też obejmować więcej obszarów mózgu. Może się wydawać, że fale *beta* w stanie senności zwiększają swoją amplitudę, jednak jest to związane ze zmniejszeniem amplitudy innych rytmów podstawowych. Zaobserwowana asymetria międzypółkulowa w amplitudzie fal *beta* może świadczyć o chorobie. Zmniejszona lub zwiększona amplituda tych fal może wskazywać na lokalizację procesu chorobowego [272].

Fale *gamma* to fale mózgowe o częstotliwości powyżej 30 Hz do około 80 Hz i związana jest ze świadomością percepcyjną. Natomiast jako wysokoczęstotliwościowe fale *gamma* (ang. *High Gamma*), występujące podczas aktywacji kory mózgowej w odpowiedzi na bodźce określa się aktywność mózgu od 80 Hz do około 200 Hz. Fale *gamma* są charakterystyczne dla funkcji motorycznych, aktywności ruchowej oraz wyższymi funkcjami poznawczymi [245].

Nazwa fali *mu* pochodzi od kształtu rytmicznej fali o częstotliwości od 7 Hz do 11 Hz, przypominającej grecką literę *mu*. Może występować obustronnie lub jednostronnie w odprowadzeniach centralnych. Rytm ten pojawia się podczas senności jak i podczas zapisu EEG z otwartymi oczami, a zanika podczas ruchów kończyny górnej po stronie przeciwnej [272].

Fale *lambda* to dodatnie potencjały, które występują przejściowo w okolicach potylicznych. Są ostro zarysowane i zwykle symetryczne, dlatego mogą być mylone z potencjałami padaczkowymi. Fale *lambda* zwykle pojawiają się podczas oglądania obrazu, który jest interesujący dla osoby badanej [272].



Rysunek 3.5 Przykładowy zapis pięciu podstawowych fal mózgowych [Źródło: [104]].

3.1.3 Prawidłowy zapis EEG podczas snu

Rejestracja sygnału EEG podczas snu jest jedną z podstawowych procedur elektroencefalograficznych o znaczącym znaczeniu diagnostycznym [272]. Związane jest to z faktem, że podczas snu mogą ulec wzmocnieniu nawet niewielkie nieprawidłowości sygnału EEG, niewykrywalne podczas rutynowego zapisu wykonywanego podczas czuwania, a mogą również pojawić się nowe, związane ze stanem snu. Wśród zmian w sygnale EEG związanych ze snem wyróżnia się wzrost fal wolnych (fal *delta* i *theta*), występowanie iglic ogniskowych oraz fal ostrych.

Na sen składają się dwie główne fazy: sen wolnych ruchów gałek ocznych (ang. *Non-Rapid Eye Movement* (NREM)) i sen szybkich ruchów gałek ocznych, nazywany również snem paradosksalnym lub niesynchroniczny (ang. *Rapid Eye Movement* (REM)) [1]. Prawidłowy zapis EEG podczas snu charakteryzuje się cyklicznym przechodzeniem przez wszystkie fazy snu: NREM1–3 i REM, o czasie trwania jednego cyklu około 90 minut oraz okresy czuwania (W) występujące po każdym cyklu. Taki cykl powtarza się około 3, 4 razy w ciągu nocy. W każdym z kolejnych cykli obserwuje się wzrost ilości snu REM i mniejszą ilość snu wolnofalowego. Cykl snu rozpoczyna się od fazy NREM, która zwykle zajmuje 75–80% całego snu i przeważa na początku snu [177]. Sen NREM dzieli się na stadium 1 i 2, które nazywane są snem płytkim, oraz 3, który nazywany jest snem wolnofalowym,

w którym obserwuje się dominującą aktywność fal *delta* [1], [177]. Przykładowe fragmenty sygnału EEG reprezentujące poszczególne fazy snu zostały przedstawione na Rysunku 3.6.


Faza W jest okresem czuwania, wybudzeniem powiązaniem z sennością, i złożona jest z więcej niż 50% rytmu *alfa* z przedziału częstotliwości 8–13 Hz (u osób dorosłych zazwyczaj 9–11 Hz) [1]. Maksymalna amplituda fal *alfa* jest obserwowana w obszarze potylicznym podczas zamykania oczu.

Faza NREM 1 zazwyczaj wskazuje na początek snu. W fazie tej dominują fale *theta* z zakresu częstotliwości 4–7 Hz, mogą również występować fale ostre o krótkim czasie trwania (mniej niż 0,5 sekundy) [1].

W Fazie NREM 2 dominują fale *theta* (4–7 Hz), naprzemiennie z kompleksami K i/lub z wrzecionami snu. Kompleksy K (ang. *K-Complex*) definiuje się jako falę wysokonapięciową, niskoczęstotliwościową, o ostrym spadku poprzedzonym dodatnim maksimum, o czasie trwania przekraczającym 0,5 sekundy [245], [1]. Wrzeciona snu (ang. *Sleep Spindles*) są aktywnością o częstotliwości 12–14 Hz i o czasie trwania 0,5–1,5 sekundy. Obwiednia tej aktywności przypomina kształt wrzeciona.

W Fazie NREM 3 dominują fale wolne o częstotliwościach 0,5–3 Hz. Aktywność EEG w tej fazie powinna wynosić przynajmniej 75 μ V. Około 20 % czasu powinno być wypełnione przez wrzeciona snu oraz kompleksy K [1].

Faza REM jest fazą szybkiego ruchu gałek ocznych, w której dominują fale *theta* o częstotliwości 4–7 Hz. Występują również fale *alfa*, ale wolniejsze o około 1–2 Hz od tych występujących w fazie W. Ponadto obserwuje się również fale piłokształtne o częstotliwości 2–6 Hz, które poprzedzają gwałtowne ruchy gałek ocznych [1].



Rysunek 3.6. Fazy snu w EEG wraz z charakterystycznymi dla snu strukturami: wrzocionami snu i kompleksami K oraz zaznaczonymi falami mózgowymi: *delta*, *theta*, *alfa* i *beta* [Źródło: [96]].

Na charakter sygnału EEG mają również wpływ stany chorobowe, takie jak epilepsja czy choroby neurologiczne: stany splątania, urazy głowy, guzy mózgu, stwardnienie rozsiane, choroba Alzheimera, zakażenia mózgu lub zaburzenia metaboliczne wpływające na mózg; choroby psychiczne, takie jak: zaburzenia świadomości, schizofrenia, zaburzenia afektywne (mania, depresja, zaburzenia lękowe) oraz zaburzenia snu i zaburzenia oddychania. Zmiany w EEG obserwowane są również po farmakoterapii, nadużyciu leków psychoaktywnych oraz po zatruciu środkami neurotoksycznymi [25].

3.2 Zmiany w sygnale EEG powiązane z epizodami bezdechu

3.2.1 Przyczynowość w zjawiskach fizjologicznych

Zjawiska fizjologiczne to procesy oraz reakcje zachodzące w organizmach żywych, a także związane z nimi mechanizmy oraz czynniki fizyczne, chemiczne i elektryczne. Na organizm człowieka i jego czynność wpływają zarówno bodźce pochodzące ze środowiska zewnętrznego, jak i wewnętrznego [346]. Niektóre reakcje, zachodzące jako odpowiedź na bodźce, mogą prowadzić do zmian w procesach organizmu, które przyczyniają się do rozwoju zjawisk patofizjologicznych, a w ich efekcie do rozwoju chorób [346]. W fizjologii obserwuje się mechanizmy kontroli i regulacji przebiegu procesów życiowych, dzięki którym możliwe jest utrzymanie optymalnych funkcji organizmu. Regulacja organizmu ludzkiego odbywa się równocześnie na wielu poziomach. Ponadto wszystkie mechanizmy regulujące pracę organizmu są ze sobą sprzężone. W szczególności sprzężone ze sobą są układ nerwowy: ośrodkowy i obwodowy, układ wewnątrzwydzielniczy i układ odpornościowy [346]. Zarówno bodźce zewnętrzne jak i wewnętrzne są odbierane przez receptory, następnie przekazywane są drogą nerwową i drogą krwi do ośrodkowego układu nerwowego. Całość procesu regulacji odbywa się na zasadzie układu sprzężeń zwrotnych [346], w którym skutki określonego zjawiska są zapamiętywane i mają wpływ też na jego przyczynę [346]. Rozróżnia się dwa rodzaje sprzężeń zwrotnych: dodatnie i ujemne. Kiedy skutek powoduje podtrzymanie przyczyny, a w konsekwencji dalsze narastanie skutku, obserwuje się sprzężenie zwrotne dodatnie. Natomiast sprzężenie zwrotne ujemne ma działanie stabilizujące, polegające na tym, że skutek zjawiska przeciwdziała jego przyczynie – jest on obecny w wielu systemach autoregulacji procesów fizjologicznych [346]. W związku z występowaniem w zjawiskach fizjologicznych sprzężeń zwrotnych, zagadnienie ich przyczynowości jest bardziej złożone. Zmiany w procesach fizjologicznych mogą być kontrolowane przede wszystkim poprzez wykonanie badań laboratoryjnych, diagnostykę obrazową, ale również poprzez pomiar różnych sygnałów biomedycznych, w tym pomiar elektrycznej aktywności mózgu z wykorzystaniem EEG.

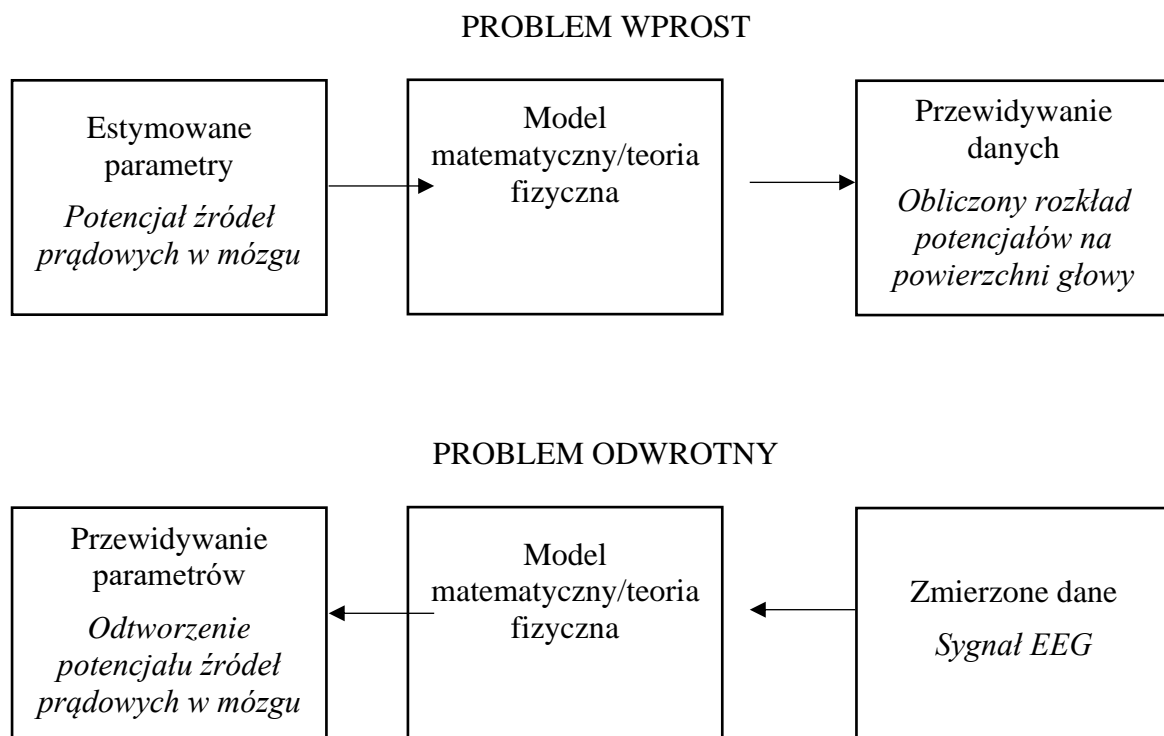
Przyczynowość jest zagadnieniem filozoficznym badanym już od czasów starożytnych, oznaczającym stosunek przyczyny do skutku, a więc wyraża ich związek oraz wskazuje na funkcję przyczyny, która polega na powodowaniu czegoś [226]. Podstawą

przyczynowości jest generowanie i określanie jednego zjawiska przez inne zjawisko. Pod tym względem związek przyczynowo-skutkowy różni się od innych rodzajów połączeń, jakimi jest prosta sekwencja zdarzeń oraz regularnością występowania zdarzeń towarzyszących. Koncepcja przyczynowości jest jednym z elementarnych zagadnień filozofii przyrody, która próbuje znaleźć odpowiedź na pytanie: *Czy każda zmiana w świecie ma przyczynę, która ją powoduje, czy tylko niektóre z nich?* [226]. Poszukując odpowiedzi na to pytanie została sformułowana zasada przyczynowości, która głosi, że to, co powstaje, ma swoją przyczynę [226]. Na jej podstawie oraz kilku innych: zasady jedności świata, zasady zmienności i zasady powiązania łańcuchów przyczynowych możliwe jest sformułowanie przyczynowej wizji świata [226]. Według przyczynowej wizji świata prawa naukowe opisują łańcuchy przyczynowe i dzięki nauce można opisywać nie tylko poszczególne zmiany oraz związane z nimi związki przyczynowe, ale również wzajemne powiązania między tymi związkami.

Przez bardzo długi czas zjawiska biologiczne były tylko opisywane lub porównywane, ponieważ badanie ich związków na drodze eksperymentalnej przysparzało wiele trudności [37]. Jedną z pierwszych dziedzin, w której zaczęto rozpatrywać kwestię przyczynowości na przełomie XVII i XVIII wieku, była fizjologia. Jednak za początek rozpatrywania przyczynowego jako powszechnej metody można uznać XIX wiek, w którym to również utrwaliła się definicja fizjologii jako nauki doświadczalnej, której celem jest poszukiwanie przyczyn zjawisk zachodzących w organizmach żywych [37]. W różnych dziedzinach nauki na różny sposób rozwiązuje się zagadnienie powiązania pomiędzy skutkiem a przyczyną, biorąc pod uwagę złożoności badanych związków, ich regularności lub przeciwnie nieregularności w występowaniu oraz wzajemnych powiązań poszczególnych czynników. W związku z tym rozróżnianie przyczyn i skutków oraz ich związków w różnych naukach może się różnić. Dla przykładu przyczynowość w biologii nie przejawia się tak samo co predykcja w mechanice klasycznej. Związane jest to z faktem, że do opisu nawet najprostszego zjawiska biologicznego potrzebne jest uwzględnienie bardzo wielu przyczyn [203]. Ponadto opis utrudnia duża złożoność poszczególnych przyczyn. Z uwagi na obserwowaną losowość wielu procesów biologicznych, przyczynowość w układach biologicznych zazwyczaj nie jest przewidywalne, czasem jest jedynie statystycznie prawdopodobna [203]. Co więcej, trudne jest jednoznaczne opisywanie powiązań pomiędzy zjawiskami biologicznymi, a zjawiskami fizycznymi. Należy jednak podkreślić, że przyczynowość w biologii nie jest sprzeczna

z przyczynowością mechaniki klasycznej. Fizyka współczesna wykazała, że przyczynowość mechaniki klasycznej jest tylko bardzo prostym, szczególnym przypadkiem przyczynowości oraz, że przewidywalność nie jest jej koniecznym elementem [203].

Poszukiwanie związków przyczynowo-skutkowych nie dotyczy jedynie opisu samych zjawisk. Możliwe jest również istnienie związku między różnymi sygnałami, w których jeden z nich jest źródłem informacji dla drugiego [245]. W takiej sytuacji poszukuje się kierunku wzajemnego wpływu sygnałów po to, żeby spróbować określić, który z sygnałów ma wpływ na inny sygnał. Aby określić kierunek wzajemnego oddziaływania dwóch sygnałów możliwe jest zbadanie fazy koherencji, czyli kierunku przesunięcia fazowego, na którego podstawie możliwe jest określenie, który z sygnałów jest wcześniejszy od drugiego. Zazwyczaj taka metoda wykorzystywana jest jedynie dla prostych sygnałów i zwykle nie jest stosowana dla danych biologicznych, które posiadają charakter stochastyczny [245]. Mimo, że jest to zagadnienie trudne, cały czas podejmowane są próby opisu związków przyczynowo skutkowych pomiędzy różnymi sygnałami [245].



Rysunek 3.7. Problem wprost i problem odwrotny w EEG [Źródło: [150]].

3.2.2 Problem wprost i odwrotny

Problem wprost to modelowanie, które obejmuje przewidywanie skutków lub wyników dla zestawu znanych parametrów pobudzeń. Problem wprost w EEG jest rozwiązywany zaczynając od znanego źródła prądowego, na podstawie którego obliczany jest potencjał na elektrodach zlokalizowanych na skórze głowy. Rozwiązanie zagadnienia problemu wprost jest niezbędne do rozwiązania problemu odwrotnego w EEG, którym jest znalezienie źródeł prądowych w mózgu, które są odpowiedzialne za generację mierzonego potencjału na podstawie zmierzonego sygnału EEG [127]. Ogólnie problem odwrotny polega na tym, że w sposób jakościowy i/lub ilościowy poszukuje się przyczyny na podstawie jej zarejestrowanego skutku. Sygnały biomedyczne bardzo często są zapisem pewnych informacji, na podstawie których można wnioskować o nieznanymi zjawiskach lub parametrach organizmu. W przypadku sygnału EEG (Rysunek 3.7) problem odwrotny od strony fizycznej sprowadza się do odtworzenia prądów płynących wewnątrz czaszki oraz ich lokalizacji na podstawie zmierzonego rozkładu potencjałów [245].

Często do rozwiązania problemu odwrotnego w sygnale EEG przyjmowany jest pewien uproszczony model źródeł prądowych w mózgu jako dipoli prądowych, które są umieszczone w jednorodnym przestrzennie przewodniku o kształcie kuli (Rysunek 3.7). Czasem stosowane są również realistyczne modele głowy. Rozwiązanie tego problemu jest skomplikowane ze względu na złożoność modeli źródeł, dlatego jego rozwiązanie nie jest jednoznaczne, a uzyskane obrazy za pomocą qEEG są czymś innym niż te uzyskiwane za pomocą tomografii komputerowej lub rezonansu magnetycznego [150], [245].

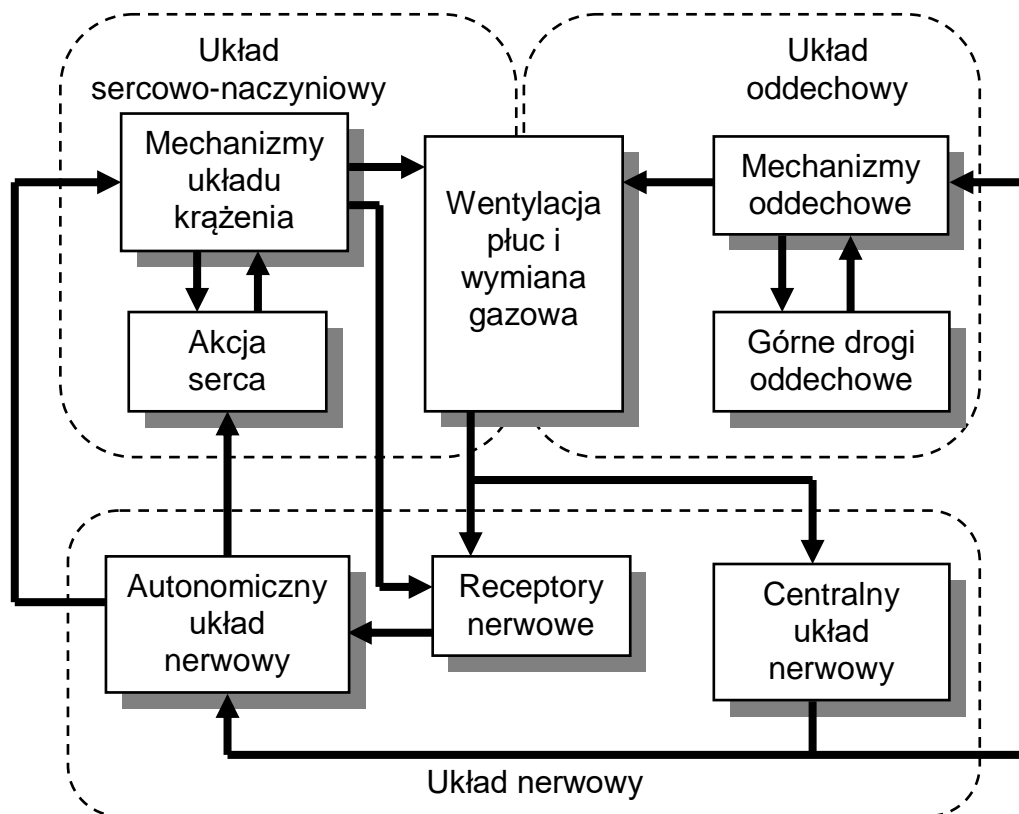
Niniejsza rozprawa ukierunkowana jest na badanie czynników wpływających na jakość wnioskowania o bezdechu sennym na podstawie zarejestrowanego EEG, dotyczy ona zatem problemu odwrotnego.

3.2.3 Mechanizmy wpływu bezdechu sennego na EEG

Bezdech senny jest jednym z zaburzeń, których występowanie można obserwować jako zmiany w sygnale EEG, a więc które mają wpływ na jego zapis. Należy pamiętać, że aktualnie złotym standardem wykrywania zaburzeń snu, w tym bezdechu sennego, jest wykonywanie polisomnografii (PSG) i tym samym do jego detekcji wykorzystuje się głównie inne sygnały biomedyczne, w których zapisie bardzo łatwo jest zaobserwować przerwy w oddychaniu.

Jednakże również w zapisie sygnału EEG możliwe jest obserwowanie zmian związanych z występowaniem bezdechu sennego. Znakomita większość dotychczasowych prac skupia się na zmianach w sygnale EEG związanych z występowaniem obturacyjnego bezdechu sennego [29], [60], [71], [262], [290]. Według najlepszej wiedzy autora rozprawy, aktualnie istnieje niewiele prac, w których w sposób szczegółowy byłyby opisane zmiany związane z centralnym bezdechem sennym. W pracy Zhou i in., w której badano zmiany w EEG związane z bezdechem, spośród 2804 zdarzeń oddechowych tylko 128 pochodziło z CSA [344]. Jedną z najczęściej opisywanych zmian występujących w sygnale EEG związanych z bezdechem sennym jest występowanie wzbudzeń (ang. *Arousals*) [14], [60], [238], [278], [290], [300], [334], [344] oraz zmiany w widmie sygnału EEG [29], [60], [71], [344].

Złożoność przyczynowo-skutkową rozważanego w pracy problemu można przedstawić na wielu płaszczyznach. Jedną z nich jest ściśle współoddziaływanie podstawowych systemów fizjologicznych człowieka, a w szczególności układu oddechowego, krążenia i nerwowego, przedstawione schematycznie na Rysunku 3.8. Istnieją badania, które wykazują związek pomiędzy chorobami układu krążeniowego, a bezdechem sennym obu typów [3], [157], [164] oraz powiązania pomiędzy chorobami układu nerwowego a bezdechem centralnym opisane poniżej.



Rysunek. 3.8. Schemat przedstawiający współdziałanie podstawowych systemów fizjologicznych człowieka, w tym układu oddechowego i nerwowego [Źródło: [240]].

W ujęciu procesowym, powiązania pomiędzy bezdechem obturacyjnym oraz centralnym, które mogą również prowadzić do rozwoju bezdechu mieszanego, zostały przedstawione na Rysunku 3.9. Schematyczne przedstawienie typowej sekwencji patofizjologicznej w OSA można podzielić na powiązanie procesów fizjologicznych, które zachodzą w całym cyklu i mają działanie albo ochronne/regulujące lub utrwalające występowanie bezdechu. Sen może powodować zmniejszoną aktywność mięśni gardła, a tym samym opadanie górnych dróg oddechowych, powodujących ograniczony przepływ powietrza przez drogi oddechowe, powodujące bezdech i prowadząc do hipowentylacji, będącej niedostateczną eliminacją dwutlenku węgla z organizmu, co powoduje wzmożony wysiłek oddechowy. Zakończeniem epizodu bezdechu lub spłycenia oddychania może być występowanie wzbudzeń, po którym następuje otwarcie dróg oddechowych. Bezdech może kończyć się wystąpieniem wyrównawczej hiperwentylacji, prowadzącej do hipokapnii, po której oddech zwalnia, co powoduje powrót do snu [95], [128], [200]. W związku z tym, że u wielu pacjentów obserwuje się przypadki, w których zdarzenia CSA prowadzą do OSA oraz odwrotnie, to powiązanie pomiędzy typami bezdechu zostało przedstawione na

jednym rysunku [94]. Jedną z głównych przyczyn bezdechu centralnego jest wzrost poziomu dwutlenku węgla w stanie czuwania, który może mieć różne przyczyny związane z nieprawidłowościami ośrodków oddychania: ośrodków koordynacji oddychania w korze mózgowej, ośrodkowego generatora rytmu oddechowego w pniu mózgu lub rdzeniowych neuronów ruchowych [94]. Wzrost dwutlenku węgla może nasilać się podczas snu oraz powodować hiperwentylację, która w efekcie obniża ciśnienie dwutlenku węgla, co prowokuje wystąpienie bezdechu centralnego. Koniec epizodu bezdechu centralnego również może kończyć się wystąpieniem wzbudzeń, po których następuje ponowna aktywność oddechowa i powrót do stanu snu. Inną bezpośrednią przyczyną CSA może być odwrotność hiperwentylacji, czyli hipowentylacja, która może być związana z nieprawidłową odpowiedzią na leczenie aparatem CPAP [94], [200], [285].

3.2.4 Wpływ bezdechu na EEG

W literaturze opisano badania, w których poszukiwano związku pomiędzy zmianami w sygnale EEG, a bezdechem sennym. Ogólną zmianą u osób cierpiących na bezdech każdego typu jest swego rodzaju destrukcja snu, związana z ilościowymi zmianami występowania poszczególnych faz snu u osoby chorej [262]. Zmiany te można obserwować poprzez analizę sygnału EEG. Większość badań nad wpływem bezdechu na sygnał EEG dotyczy OSA [29], [60], [71], [262], [290], [312]. W jednym z nich ocena wpływu zdarzeń oddechowych na ten sygnał został wykonany dla obu typów bezdechu, z tym, że większość epok, ponad 95%, zawierała zdarzenia typu obturacyjnego [344], dlatego wyniki tych badań zostaną omówione w Rozdziale 3.2.4.1.


3.2.4.1 Wpływ bezdechu obturacyjnego na EEG

U osób z bezdechem obturacyjnym, po zdecydowanie dłuższym czasie niż u osoby zdrowej, obserwuje się sen wolnofalowy (NREM3) i fazę REM. Ponadto u takich osób większą część snu zajmuje faza NREM1, a zdecydowanie mniejszą fazą snu głębokiego. Co więcej, większość zdarzeń oddechowych obserwuje się w fazie NREM1 i REM [262].

Istnieją też badania, które informują, że z sygnału EEG możliwe jest odczytanie zmian związanych z mechanizmem oddechowym [60]. Chervin i in. zaobserwowali różnice w wartościach średniej mocy sygnału EEG w poszczególnych fazach cyklu wentylacyjnego [60]. W szczególności różnice te występują w mocy fal *delta*, *alfa* i *gamma* [60]. W nawiązaniu do tych badań można wnioskować, że prawdopodobnie w sygnale EEG można również obserwować zmiany w cyklu wentylacyjnym związane z bezdechem sennym.

Inną często opisywaną zmianą w sygnale EEG, występującą po bezdechu sennym, są wzbudzenia układu nerwowego, czyli nagła zmiana częstotliwości sygnału EEG trwająca od 3 do 15 sekund. Wzbudzenie może występować jednocześnie z końcem zdarzenia, ale również kilka oddechów po zakończeniu zdarzenia. Zgodnie z badaniami Simms i in., czas od zakończenia bezdechu do początku wzbudzenia jest krótszy przy OSA ($1,95 \text{ s} \pm 0,68$) i dłuższy przy CSA ($4,97 \text{ s} \pm 2,54$) [290]. Wzbudzenia mogą również występować spontanicznie, nie towarzysząc bezdechom lub innym zaburzeniom snu. Efektem wystąpienia wzbudzenia jest powrót do lżejszych faz snu. Jeśli wzbudzenie trwa więcej niż 15 sekund, wtedy przechodzi w przebudzenie. Różnica między wzbudzeniem,

a przebudzeniem jest taka, że osoba nie jest świadoma doświadczania wzbudzeń. Jednak im więcej wzbudzeń, tym większe prawdopodobieństwa uczucia zmęczenia po przebudzeniu. Chroniczną senność może powodować już indeks wzbudzeń o wartości 5, ale w najgorszych przypadkach może wynosić 100 lub więcej wzbudzeń na godzinę [17].



Rysunek 3.10. 30-sekundowa epoka polisomnogramu przedstawiająca bezdech obturacyjny wraz ze wzbudzeniem (zaznaczony strzałką w sygnale EEG) [Źródło: [310]].


Kolejna grupa badań dotyczy zmian w energii poszczególnych fal mózgowych. Wskazują one na powiązania pomiędzy zmianami w amplitudzie fal mózgowych, w szczególności fal *delta*, z epizodami bezdechu sennego [71], [344]. Coito i in. wykonali ocenę wartości widmowej gęstości mocy (ang. *Power Spectral Density* (PSD)) przed, podczas oraz po epizodzie bezdechu sennego z wykorzystaniem modeli autoregresji [71]. Wynikiem tych badań jest zaobserwowanie znaczącego spadku mocy fal *delta* w sygnale EEG w trakcie epizodów obturacyjnego bezdechu sennego. Ponadto zaobserwowano, że po epizodzie bezdechu moc fal *delta* wzrasta, jednak nie osiąga takiego samego poziomu jak przed bezdechem [71]. Po okresie spadku mocy w falach *delta* następuje wzbudzenie układu nerwowego, widoczne jako desynchronizacja zapisu EEG, i zakończenie epizodu bezdechu sennego zarówno w fazach NREM jak i REM. Nie zaobserwowano natomiast

istotnych zmian w innych zakresach częstotliwości sygnału EEG, czyli zmian w falach *theta*, *alfa* i *beta* [71]. Zhou i in. w podobnym badaniu przeanalizowali zmiany w sygnale EEG związane z epizodami bezdechu, których efektem jest zaobserwowanie wzrostu fal *delta* podczas zdarzeń oddechowych w śnie REM oraz NREM1. Co więcej, zaobserwowano wzrost mocy fal *delta*, *theta*, *alfa* i *beta* podczas snu NREM2. Po epizodach bezdechu zaobserwowano wzrost średniej mocy we wszystkich pasmach częstotliwości i fazach snu [344].

Bandla i Gozal wykonali analizę spektralną sygnału EEG przed, podczas oraz po epizodzie bezdechu sennego z wykorzystaniem szybkiej transformaty Fouriera. W wyniku przeprowadzonych badań również zaobserwowali zdecydowany spadek średniej mocy fal *delta* podczas obturacyjnego bezdechu sennego. Jednak w ich badaniach średnia moc fal *delta* po epizodzie bezdechu była wyższa niż przed. Ponadto zaobserwowali wzrost mocy fal *theta* podczas epizodu bezdechu sennego i ich zdecydowany spadek po epizodzie OSA. Nie zaobserwowano znaczących zmian w mocy fal *alfa* i *beta* [29].

3.2.4.2 Wpływ bezdechu centralnego na EEG

W literaturze znaleźć można zdecydowanie mniej badań nad związkami pomiędzy zmianami w sygnale EEG a bezdechem centralnym. Prawdopodobnie jest to związane z tym, że bezdech centralny obserwuje się rzadziej od bezdechu obturacyjnego. Bezdech centralny, tak samo jak bezdech obturacyjny, powoduje dekonstrukcję snu, która objawia się licznymi przerwami w oddychaniu i związanymi z nimi wzbudzeniami oraz zmianą zawartości poszczególnych faz snu, które można obserwować w sygnale EEG. Osoby z bezdechem centralnym posiadają więcej fazy NREM1 w porównaniu do osób zdrowych oraz mniej fazy NREM3, czyli snu głębokiego [262]. Ponadto większość zdarzeń oddechowych obserwowana jest w fazie NREM1 i REM [262]. Bezdech centralny, podobnie jak obturacyjny, jest związany z możliwością występowania wzbudzeń w sygnale EEG [290]. Wzbudzenie związane z bezdechem centralnym jest przedstawione na Rysunek. 3.11.



Rysunek. 3.11 Bezdech centralny i wzbudzenie w sygnale EEG (podkreślone kreską) [Źródło: [94]].

3.3 Badania nad wykorzystaniem EEG w diagnostyce bezdechu


Aktualnie automatyczna klasyfikacja zaburzeń snu, w tym również zaburzeń oddychania, wykonywana jest w oparciu o PSG [1]. Jednak w ostatnich latach obserwuje się rozwój badań nad prostszymi metodami detekcji bezdechu sennego w oparciu o mniejszą ilość sygnałów biomedycznych niż podczas tradycyjnej polisomnografii. Celem takich badań jest określenie możliwości wykonywania diagnostyki w warunkach ambulatoryjnych oraz skrócenie czasu wykonywania badań przesiewowych, a więc również zwiększenie dostępności tego rodzaju testów. Ponadto zainteresowanie rozwojem metod automatycznej detekcji bezdechu sennego, z wykorzystaniem pojedynczych sygnałów fizjologicznych, przyczynia się do rozwoju metod analizy sygnałów, a tym samym do wzrostu wiedzy na temat danego sygnału. Automatyczna klasyfikacja zdarzeń, w tym również bezdechu sennego, najczęściej wykonywana jest według następujących kroków: wybór oraz przygotowanie bazy danych, przetwarzanie wstępne, ekstrakcja cech, selekcja cech, klasyfikacja oraz ocena jakości metody.

3.3.1 Badania wykorzystujące EEG wraz z innymi biosygnalami

Pomimo, że znaczna część zaburzeń snu jest diagnozowana wyłącznie na podstawie objawów klinicznych, występowanie niektórych z nich można potwierdzić dopiero po przeprowadzonych badaniach w laboratoriach snu [234]. W polisomnografii sygnał EEG wykorzystuje się przede wszystkim do klasyfikacji faz snu. Wyniki automatycznej klasyfikacji faz snu z wykorzystaniem kilku metod ekstrakcji: PSD, dyskretnej transformacji falkowej (ang. *Discrete Wavelet Transform* (DWT)) i dekompozycji

empirycznej (ang. *Empirical Mode Decomposition* (EMD)) oraz sztucznej sieci neuronowej (ang. *Artificial Neural Network* (ANN)) zostały porównane w pracy autora dysertacji [248]. Sygnał EEG nie jest powszechnie wykorzystywany do bezpośredniej detekcji bezdechu sennego. Związane jest to z wysokim stopniem skomplikowania tego sygnału. Znana jest praca porównująca skuteczność PSG i pojedynczego sygnału EEG w badaniach snu [194]. W pracy tej została wykonana analiza spektralna, której efektem była klasyfikacja parametrów snu, takich jak fazy snu oraz porównanie uzyskanej klasyfikacji dla PSG i pojedynczego sygnału EEG pozyskanych na tej samej grupie badawczej. W badanej grupie były osoby z lekkim lub średnim zdiagnozowanym OSA oraz nikogo z CSA. Uzyskane w tej pracy wyniki pokazują, że analiza jednokanałowego sygnału EEG zapewnia wyniki porównywalne do tych uzyskanych z analizy PSG w klasyfikacji fazy REM i połączonych faz NREM2 i NREM3 oraz aktywności fal wolnych. Szczególnie słabą zgodność klasyfikacji dla pojedynczego kanału EEG uzyskano dla fazy NREM1. Rozbieżność w klasyfikacji faz snu zauważono również podczas analizy PSG i sygnału EEG u osób cierpiących na zaburzenia snu, w tym na bezdechach senny. Mimo to, wyniki tej pracy potwierdzają, że analiza jednokanałowego sygnału EEG może być przydatnym narzędziem w diagnostyce snu [194].

W diagnostyce bezdechu sennego najczęściej wykorzystywanymi sygnałami polisomnograficznymi są: przepływ powietrza, ruchy klatki piersiowej i brzucha, EMG oraz saturacja krwi tętniczej [21], [52], [57], [64], [102], [108], [145], [180], [170], [172], [201], [241], [244], [257], [260], [300]. Na podstawie wymienionych wyżej sygnałów w łatwy sposób można również rozróżnić bezdech od spłycenia oddychania oraz typ bezdechu. Podczas CSA nie występują ruchy klatki piersiowej i brzucha, które obserwuje się podczas OSA, a oba te mechanizmy są obserwowane podczas MSA. Symptomy te zostały przedstawione na Rysunek 3.12.



Rysunek 3.12. Bezdech obturacyjny, centralny, mieszany i spłylenie oddychania widoczne w sygnałach PSG [Źródło: [102]].

Wśród badań nad detekcją bezdechu sennego dominują takie, w którym sygnał EEG był wykorzystywany wraz z innymi biosygnalami, takimi jak: pomiar rozmiaru źrenicy [192], HRV [102], EMG [21], [213], [279], EKG [213], [172], [279], EOG [100], [279] oraz pomiar aktywności ruchowej podczas snu [108].

3.3.2 Badania wykorzystujące jedynie sygnał EEG

Analizę sygnału EEG ukierunkowaną na wykrywanie epizodów bezdechu sennego lub zmian w EEG związanych z bezdechem wykonywano w oparciu o następujące kanały sygnału EEG, pobrane z lokacji elektrod: C3-A2 lub C4-A1 [29], [35], [144], [145], [159], [276], [308], [322], lub Cz-A1 [31] lub O2-A1 [35], [159], [308] lub C3-O1 [35], [159], [308], [322].

Przetwarzanie wstępne sygnału EEG najczęściej uwzględniało usunięcie linii trendu, normalizację sygnału i jego filtrację częstotliwościową. Usunięcie linii trendu polega na odjęciu od sygnału EEG wartości zmieniających się liniowo w celu powrotu sygnału do stanu odniesienia [121], [275], [276]. Normalizacja umożliwia porównanie fragmentów danych między sobą poprzez ustalenie minimalnego i maksymalnego zakresu amplitud w obrębie analizowanych fragmentów sygnałów EEG [36], [121], [275], [276], [300], [308], [324], [343]. Niweluje ona różnice pomiędzy zakresem amplitud danych pochodzących z różnych, niezależnych pomiarów. Filtracja sygnału to ograniczenie zakresu częstotliwości poprzez zastosowanie filtru pasmowoprzepustowego lub usunięcie znanych szumów z sygnału, np. mrugania lub ruchu oczu, szumu białego czy rytmu serca [124], [145], [159], [288], [300], [322]. Ponadto jednym z elementów przetwarzania wstępnego jest podział sygnału EEG na mniejsze fragmenty 30-sekundowe, zwane epokami [31], [35], [36], [102], [107], [108], [124], [159], [172], [322], [334], w obrębie których wykonywana jest klasyfikacja występowania epizodów bezdechu sennego oraz określenie jego typu.

Podstawowym celem ekstrakcji cech jest przekształcenie epoki sygnału EEG złożonej z wielu próbek w wektor cech o znacznie mniejszym rozmiarze, tak aby zachowana została informacja użyteczna zawarta w sygnale – w niniejszej pracy jest to informacja o wystąpieniu i rodzaju bezdechu sennego. Każda epoka sygnału jest analizowana z wykorzystaniem wybranej metody ekstrakcji cech, czego efektem jest utworzenie macierzy cech złożonej z wielu wektorów, reprezentujących kolejne epoki sygnału. Wśród metod ekstrakcji cech wykorzystywanych do analizy sygnału EEG można wyróżnić metody statystyczne, które umożliwiają obliczenie takich cech sygnału jak: mediana, odchylenie standardowe, średnia, kurtoza, skośność [31], [35], [36], [260], [308], [322]; parametry Hjortha (HP): aktywność, mobilność i złożoność [31], [102] oraz niestatystyczne, takie jak: wartość entropii (ang. *Entropy Value*, EV) [36], [121], [308], [322], [329]; energia i moc sygnału, które należą do grupy analiz przebiegu czasowego oraz odległość Itakury [102], [322], [329]. Inną powszechnie wykorzystywaną grupą metod są te umożliwiające analizę sygnału w oparciu o jego właściwości częstotliwościowe, takie jak: filtracja z wykorzystaniem filtrów cyfrowych [31], [36], [144], [145], FFT [121], [201], [275], [276], STFT [159], PSD [124], [172], [300], dyskretna transformata falkowa (ang. *Discrete Wavelet Transform* (DWT)) [181], [189], transformata Hilberta-Huanga

(ang. *Hilbert-Huang Transform* (HHT)) [144], [145], [322], [329]. Ponadto do analizy niestacjonarnego sygnału EEG wykorzystuje się, oprócz DWT i HHT, również dekompozycję empiryczną (ang. *Empirical Mode Decomposition* (EMD)) [329] czy dekompozycję wariacyjną (ang. *Variational Mode Decomposition* (VMD)) [35]. Właściwości dynamiczne bada się przez analizę fluktuacji po usunięciu trendu z sygnału (ang. *Detrended Fluctuation Analysis* (DFA)) [52], [102], [343]. Inną metodą dekompozycji sygnału na składowe była adaptacyjna dekompozycja Hermite'a (ang. *Adaptive Hermite Decomposition* (AHD)) [308].

Selekcja cech polega na takim wyborze ograniczonej ilości wyekstrahowanych wcześniej cech, które są najbardziej różnicujące oraz niosą najwięcej informacji o analizowanym stanie obiektu. Wśród metod selekcji cech, wykorzystywanych podczas analizy sygnału EEG w celu detekcji epizodów bezdechu sennego, stosowano takie metody, jak: analiza wariancji (ang. *Analysis Of Variance* (ANOVA)) [244], [343], analiza składowych głównych (ang. *Principial Component Analysis* (PCA)), regresja liniowa, liniowa analiza dyskryminacyjna (ang. *Linear Discriminant Analysis* (LDA)) i liniowa dyskryminacja Fishera (ang. *Fisher Linear Dicriminant* (FLD)), analiza składowych niezależnych (ang. *Independent Component Analysis* (ICA)) oraz algorytm minimalnej redundancji – maksymalnej istotności MRMR (ang. *Minimal Redundancy Maximal Relevance* (MRMR)) [31]. Wykorzystywano w tym celu również algorytmy genetyczne (ang. *Genetic Algorithm*, GA) [230], [308].

Metody klasyfikacji umożliwiają automatyczne rozróżnienie epok, w których wystąpił epizod bezdechu sennego od tych, w których nie wystąpił. Jako klasyfikatory zazwyczaj wykorzystuje się jedną ze znanych metod inteligencji obliczeniowej [241], takich jak sztuczne sieci neuronowe (ang. *Artifical Neural Network* (ANN)) [189], [322], [324], konwolucyjne sieci neuronowe (ang. *Convolutional Neural Network* (CNN)) [159], maszynę wektorów nośnych (ang. *Support Vector Machine* (SVM)) [124], [181], [288], [308], [322], [343], algorytm *k*-najbliższych sąsiadów (ang. *k-Nearest Neighbor* (k-NN)) [35], [36], [121], [124], [275], [276], [288], [322], drzewa decyzyjne [124] oraz algorytm RUSBoost [31].

Ocena jakości metody klasyfikacji wykonana za pomocą znanych narzędzi umożliwia obiektywne porównanie wyników uzyskanych podczas różnych i niezależnych badań. Najprostszym wskaźnikiem jakości metody jest trafność klasyfikacji, która dla

klasyfikacji binarnej jest równoznaczna z dokładnością (ang. *Accuracy*) i polega na zliczeniu poprawie zaklasyfikowanych epok do klas, a następnie obliczeniu ich procentowego udziału wśród wszystkich analizowanych epok. Dla klasyfikacji wieloetykietowej podstawową miarą jest średnia dokładność klasyfikacji, opisana szczegółowo w Rozdziale 8. Bardzo popularnymi wskaźnikami jakości metody są ponadto precyzja, czułość oraz swoistość (ang. *Precision, Sensitivity, Specificity*), które oblicza się z wykorzystaniem tablicy pomyłek (ang. *Confusion Matrix*) [241]. W tablicy pomyłek zawarta jest informacja o umiejętności klasyfikatora do poprawnej klasyfikacji przypadków pozytywnych i negatywnych oraz o błędzie I i II rodzaju. W związku z tym jest to metoda oceny jakości klasyfikacji powszechnie wykorzystywana podczas detekcji chorób w badaniach przesiewowych w medycynie, ponieważ wskazuje wrażliwość klasyfikatora na błąd II rodzaju, czyli sklasyfikowanie osoby chorej do osób zdrowych. Na podstawie tablicy pomyłek oblicza się też kolejne wskaźniki precyzji klasyfikacji: wartość predykcyjną pozytywną (ang. *Positive Predictive Value, PPV*) i wartość predykcyjną negatywną (ang. *Negative Predictive Value, NPV*) [338]. Miary oceny jakości klasyfikatorów opisane są szerzej w Rozdziale 8.

Opublikowane prace dotyczące detekcji bezdechu sennego na podstawie jednokanałowego EEG można podzielić na dwa rodzaje klasyfikacji: detekcji epok bezdechu i normalnego oddychania u osób chorych ze zdiagnozowanym bezdechem sennym [9], [35], [36], [124], [159], [188], [249], [250], [251], [275], [276], [288], [308], [329], [342] oraz detekcji bezdechu u osób chorych w odniesieniu do normalnego oddychania zarejestrowanego u grupy kontrolnej osób zdrowych [12], [31], [181], [190], [322], [343]. Ponadto realizowane są prace, których celem jest detekcja nie zdarzeń oddechowych, a wzbudzeń, których występowanie w sygnale EEG jest między innymi związane z występowaniem bezdechów [14], [15], [16], [60], [107], [201], [238], [244], [290], [278], [300]. Jedyne pierwsza grupa publikacji może stanowić bezpośrednie tło dla niniejszej dysertacji.

Porównanie uzyskanych w niniejszej pracy wyników klasyfikacji bezdechu na podstawie jednokanałowego sygnału EEG zostanie wykonane tylko w odniesieniu do tych badań, w których metodyka była wystarczająco dobrze opisana (w artykułach [10], [144], [145], [322] brakowało podstawowych informacji pozwalających na weryfikację ich rezultatów), wykorzystano 1 kanał sygnału EEG, a detekcja bezdechu była wykonywana

w obrębie epok bezdechu i normalnego oddychania pozyskanych tylko i wyłącznie od osób chorych. Wyniki tych prac przedstawiono skrótowo w Tabeli 3.1. (badania opublikowane przed otwarciem przewodu) i Tabelach 3.2. oraz 3.3. (badania opublikowane po 2017 roku), prezentując miary oceny klasyfikacji binarnej: dokładność (A_c), czułość (R) i swoistość (S).

Tabela 3.1. Opis badań opublikowanych przed 2017 rokiem oraz wyniki klasyfikacji bezdechu sennego i normalnego oddychania u osób chorych na podstawie jednokanałowego EEG (A_c -dokładność, R -czułość i S -swoistość).

Autor	Metody	Sygnały	Klasy	Wyniki [%]		
				A_c	R	S
Lin i in. 2006 [188]	DWT, ANN	EEG (C3-O1)	OSA vs NORM	54,10	69,64	44,44
Lin i in. 2011 [189]	DWT, ANN	EEG (1 kanał)	APNEA vs NORM	78,10	-----	-----
Ahmed i in. 2016 [9]	BPF, k-NN	EEG (1 kanał)	OSA vs NORM	82,28	90,58	77,72
Shahnaz i in. 2016 [288]	WT, SVM, k-NN	EEG (1 kanał)	APNEA vs NORM	87,03	89,62	84,43
Shahnaz i Minhaz 2016 [287]	EMD, SVM	EEG (1 kanał)	APNEA vs NORM	80,43	85,59	77,87
Saha i in. 2016 [275]	BPF, k-NN	EEG (1 kanał)	APNEA vs NORM	87,64	89,02	86,27

Przed otwarciem przewodu doktorskiego, znanych było niewiele prac nad detekcją bezdechu w odróżnieniu od normalnego oddychania u osób chorych z zastosowaniem jednokanałowego sygnału EEG, których dokładność klasyfikacji wynosiła od 54,10% do 87,64% [9], [188], [189], [275], [287], [288]. Wszystkie znane do tej pory prace dotyczyły klasyfikacji binarnej, a dokładność powyżej 85% uzyskano w dwóch badaniach [275], [288].

Shanhaz i in. przetwarzanie sygnału EEG rozpoczęli od usunięcia szumu z wykorzystaniem DWT, następnie obliczona została średnia moc dla pięciu zakresów częstotliwości charakterystycznych dla fal mózgowych oraz stosunki mocy dla pięciu fal: *delta*, *theta*, *alfa*, *beta* i *gamma* poprzez podzielenie mocy każdej z fal przez sumę mocy

wszystkich fal mózgowych [288]. Jako klasyfikator zostały wykorzystane metody k-NN i SVM. Ocena klasyfikacji została wykonana z zastosowaniem 10-krotnej walidacji skróśnej oraz miar: dokładności, czułości i specyficzności wynoszących odpowiednio 86,15%, 87,50% i 84,80 dla k-NN i 87,03, 89,62 i 84,43 dla SVM [288].

Natomiast Saha i in. uzyskali dokładność 87,64%, czułości 89,02% oraz specyficzności 86,27% [275]. Na kolejne etapy przetwarzania sygnału EEG składały się: usunięcie linii trendu i normalizacja, obliczenie entropii z pięciu zakresów częstotliwości charakterystycznych dla fal mózgowych (uzyskanych poprzez zastosowanie filtrowania w dziedzinie częstotliwości) oraz k-NN jako klasyfikator z walidacją skróśną *leave-one-out* do oceny klasyfikacji.

Dokładność klasyfikacji binarnej opisanej w badaniach znanych przed otwarciem przewodu nie przekraczała 90%, a zatem nie była wystarczająca do praktycznego zastosowania we wspomaganie diagnostyki medycznej.

Tabela 3.2. Opis badań opublikowanych po 2017 roku oraz wyniki klasyfikacji bezdechu sennego i normalnego oddychania u osób chorych na podstawie jednokanałowego EEG z sygnałami z odprowadzenia C3-A2.

Autor	Metody	Sygnały	Klasy	Wyniki [%]		
				A_c	R	S
Bhattacharjee i in. 2018 [35]	VMD, RiM, k-NN, SVM	EEG (C3-A2)	APNEA vs NORM	90,46	94,00	86,92
Bhattacharjee i in. 2019 [36]	BPF, k-NN	EEG (C3-A2)	APNEA vs NORM	89,37	95,86	82,90

Podczas realizacji doktoratu (po 2017 roku), opublikowanych zostało kilka badań, które raportowały możliwość uzyskania dokładności klasyfikacji dla jednokanałowego sygnału EEG od 89,01% do 99,53% [35], [36], [159], [307], [308].

Wśród tych badań można wyróżnić te, wykorzystujące sygnały z bazy danych (tej samej co w niniejszej pracy), które dla wszystkich pacjentów zostały zarejestrowane z jednakowych odprowadzeń EEG (Tabela 3.2) [35], [36]. Bhattacharjee i in. metodę klasyfikacji epok bezdechu i normalnego oddychania polegającą na zastosowaniu dekompozycji wariacyjnej (VMD) i modelu rozkładu Rice'a (ang. *Rician model* (RiM)) oraz algorytmu k-NN, testowali na trzech bazach danych, w których jedna posiadała epoki

EEG tylko od grupy kontrolnej osób zdrowych, a dwie od osób ze zdiagnozowanym bezdechem sennym zarejestrowane z tego samego odprowadzenia EEG dla wszystkich pacjentów oraz z różnych, ale jednokanałowych EEG. Jedną z baz danych była tą samą, którą wykorzystano w niniejszej pracy, z tym, że Bhattacharjee i. in wykonali klasyfikację na podstawie sygnału z lokacji C3-A2 dla 23, nie 25 pacjentów oraz dla sygnałów podzielonych na 15 sekundowe, nakładające się fragmenty sygnału, uzyskując dokładność 90,46% oraz czułość i swoistość kolejno 94,00% i 86,92%. Natomiast całkowita dokładność (dla różnych jednokanałowych EEG) dla walidacji krzyżowej 10-krotnej wyniosła 92,36% [35]. Ci sami autorzy w kolejnym artykule zastosowali filtrację pasmowoprzepustową (BPF) i k-NN jako klasyfikator uzyskując dokładność 89,37% dla sygnałów z lokacji C3-A2 od 11 wybranych pacjentów [36].

Tabela 3.3. Opis badań opublikowanych po 2017 roku oraz wyniki klasyfikacji bezdechu sennego i normalnego oddychania u osób chorych na podstawie jednokanałowego EEG z sygnałami z różnych odprowadzeń.

Autor	Metody	Sygnały	Klasy	Wyniki [%]		
				A_c	R	S
Taran i in. 2017 [307]	EMD, LS-SVM	EEG (1 kanał, różne lokacje)	APNEA vs NORM	95,29	100,00	91,99
Jiang i in. 2018 [159]	BPF, STFT, MSPCNN	EEG (1 kanał, różne lokacje)	APNEA vs NORM	89,01	93,10	82,90
Taran&Bajaj 2020 [308]	AHD, ELM, LS-SVM	EEG (1 kanał, różne lokacje)	APNEA vs NORM	99,53	99,47	99,58

Ponadto opublikowane zostały również badania, w których analizowane sygnały, były rejestrowane z różnych odprowadzeń i żaden z nich nie był z lokacji C3-A2, którą wykorzystano w tej pracy (Tabela 3.3) [159], [307], [308]. W związku z tym powoduje to, że ich wyników nie da się bezpośrednio porównać z wynikami uzyskanymi w tej pracy, ponieważ każde odprowadzenie EEG może nieść inną informację o aktualnym stanie pracy mózgu. Uzyskana w tych badaniach dokładność klasyfikacji wynosi od 89,01% do 99,53% [159], [307], [308], która jest najwyższą jak dotąd uzyskaną. Najlepszy dotąd wynik dokładności klasyfikacji uzyskano z badań nad detekcją bezdechu i normalnego oddychania realizowanych na podstawie jednokanałowych sygnałów EEG, ale z bazy danych, w której różni pacjenci mieli rejestrowane EEG z różnych kanałów [307], [308].

Taran i in. stosując dekompozycję empiryczną (EMD) i maszyny wektorów nośnych o najmniejszych kwadratach (ang. *Least Squares Support Vector Machine* (LS-SVM)) uzyskali dokładność, czułość i swoistość klasyfikacji kolejno 95,29%, 100% i 91,99% [307]. Natomiast Taran i Bajaj poprzez zastosowanie adaptacyjnej dekompozycji Hermite'a (ang. *Adaptive Hermite Decomposition* (AHD)) na etapie ekstrakcji cech, algorytmów genetycznych i metody Fishera podczas selekcji i ekstremalnych sieci neuronowych (ang. *Exreme Learning Machine* (ELM)) i LS-SVM jako klasyfikatorów uzyskując kolejno dokładność, czułość i specyficzność 99,53%, 99,47% i 99,58% dla ELM i 99,44%, 98,95% i 99,83% dla LS-SVM [308].

Wszystkie znane do tej pory prace dotyczyły klasyfikacji binarnej. Do momentu zakończenia badań, realizowanych w ramach prezentowanej pracy, nie odnotowano publikacji, oprócz prac własnych autora, dotyczących klasyfikacji bezdechu i jego typu w klasyfikacji trójetykietowej na podstawie jednokanałowego, całonocnego sygnału EEG. W pracach tych dokładność klasyfikacji bezdechu i jego typu wyniosła dla metody ekstrakcji DWT+HT i ANOVA+MRA jako metody selekcji cech kolejno 77,30% [249] i 63,80% [250] dla ANN i k-NN jako klasyfikatora.

Pod koniec realizacji badań zaprezentowanych w dysertacji ukazały się publikacje odwołujące się do prac autora [250], [251], w których wykonano trójetykietową klasyfikację, ale na podstawie dwóch symetrycznych kanałów EEG (C3-A2 i C4-A1). Szczegółowe odniesienie uzyskanych wyników w stosunku do tych badań zostało zaprezentowane w podsumowaniu Rozdziału 8 [342]. Fakty te świadczą m.in. o aktualności prac realizowanych w ramach niniejszej pracy doktorskiej i dynamice analogicznych badań w innych ośrodkach naukowych.

Rozdział 4

Baza danych polisomnograficznych

4.1 Dostępne bazy danych

Uzyskanie wiarygodnych wyników analizy sygnałów jest zależne od jakości oraz prawidłowego opisu zgromadzonych danych. W tym celu często wykorzystuje się dane zgromadzone w różnych bazach danych, co powala na porównywanie otrzymanych wyników z rezultatami prac innych autorów. Istnieją zbiory danych, które są udostępnione za darmo dla naukowców. Wśród baz danych zawierających sygnały EEG zarejestrowane u osób cierpiących na bezdech senny można wyróżnić następujące zbiory:

- 1) The DREAMS Apnea Database,
- 2) MIT-BIH Polysomnographic Database,
- 3) ISRUC-SLEEP Dataset,
- 4) St. Vincent's University Hospital/University College Dublin Sleep Apnea Database.

Baza danych The DREAMS Apnea Database została przygotowana z danych zebranych podczas projektu DREAMS realizowanego przez University of Mons w latach 2003-2008 we współpracy z Université Libre de Bruxelles [247]. Składa się z 12 całonocnych zapisów badania polisomnograficznego wykonanych u osób z bezdechem sennym. Sygnały: EEG, EKG, EOG i EMG były analizowane przez specjalistów w celu wykrycia zdarzeń oddechowych, stąd baza danych, oprócz sygnałów, zawiera również adnotację o wystąpieniu epizodów spłylenia oddychania oraz bezdechu wraz z jego typem (centralny, obturacyjny i mieszany).

MIT-BIH Polysomnographic Database jest bazą danych pochodzącą z badań wykonanych w Beth Israel Hospital Laboratory w Bostonie wśród pacjentów cierpiących na obturacyjny bezdech senny w celu oceny wpływu terapii z wykorzystaniem CPAP (stałego dodatniego ciśnienia w drogach oddechowych) na redukcję epizodów bezdechu sennego i spłyceń oddychania. Baza składa się z 18 badań polisomnograficznych, każde zawierające sygnał EEG, EKG, EOG, EMG oraz saturację i sygnał oddechowy, wykonane

u różnych osób z adnotacjami odnośnie faz snu oraz bezdechu sennego podzielonego na typ obturacyjny i centralny [311].

Baza ISRUC-Sleep jest zbiorem całonocnych badań polisomnograficznych wykonanych zarówno u osób z zaburzeniami snu, jak i u grupy kontrolnej osób zdrowych. Podczas badania PSG zarejestrowane zostały sygnały EEG, EOG, EKG, EMG, przepływ powietrza, ruchy klatki piersiowej, pozycja ciała, saturacja oraz nagranie odgłosów chrapania. Badania zostały wykonane w Centrum Medycyny Snu na Uniwersytecie Coimbra (CHUC) w latach 2009-2013. Sygnały w bazie zostały opisane przez ekspertów oraz podzielone na trzy grupy:

- 1) sygnały z jednego całonocnego badania PSG wykonanego u 100 osób z zaburzeniami snu oraz adnotacje o fazach snu;
- 2) sygnały z dwóch całonocnych badań PSG wykonanych u 8 osób z zaburzeniami snu oraz adnotacje o fazach snu i zdarzeniach oddechowych (spłyceń oddychania oraz bezdechach sennych typu: obturacyjnego, centralnego i mieszanego);
- 3) sygnały z całonocnego badania PSG wykonanego u 10 zdrowych osób oraz adnotacje o fazach snu [167].

W niniejszej pracy wykorzystano dane z czwartej z wymienionych baz [317], dlatego też została ona omówiona bardziej szczegółowo poniżej.

4.2 Przygotowanie bazy danych do wykorzystania w pracy

W pracy wykorzystana została baza danych University College Dublin Sleep Apnea Database dostępna na portalu *PhysioNet* [317]. Wybór tej bazy danych zdeterminowała dostępność dość dużej ilości plików z badań wykonanych u osób z podejrzeniem bezdechu sennego różnego typu lub innych zaburzeń oddychania podczas snu, przygotowane adnotacje, które oprócz hipnogramu (wykres przedstawiający kolejne fazy snu w funkcji czasu) zawierają również informację o zdarzeniach oddechowych z dokładną informacją o czasie ich występowania, pozwalającej na lokalizację epizodów, w tym o spłyceń oddychania i bezdechach sennych oraz ich typie. W badaniach nie zarejestrowano sygnałów od osób zdrowych, bez podejrzenia bezdechu sennego. Ponadto jest to jedna z baz danych często wykorzystywana w literaturze [21], [36], [51], [55], [101], [102], [124], [131], [130], [133], [213], [215], [235], [273], dzięki czemu możliwe jest porównywanie uzyskiwanych wyników analizy sygnałów. Baza danych składa

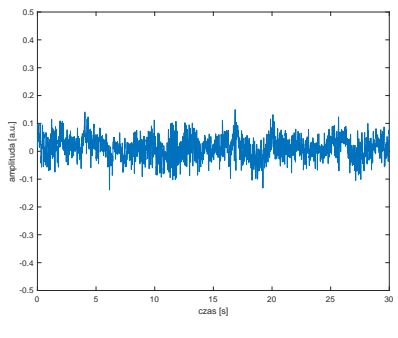
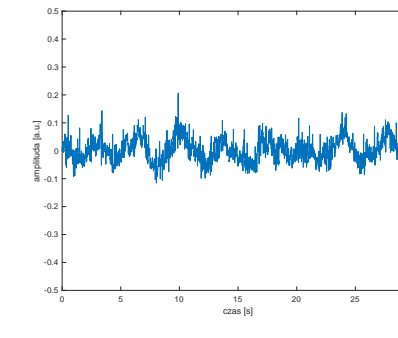
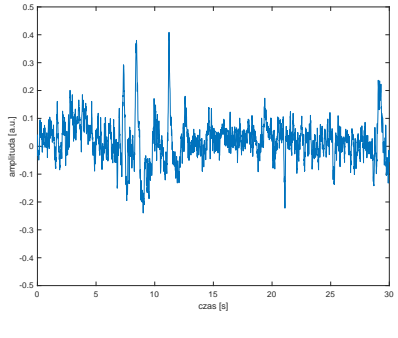
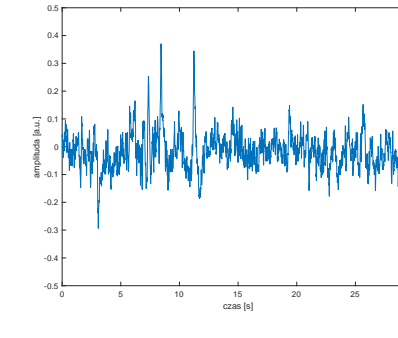
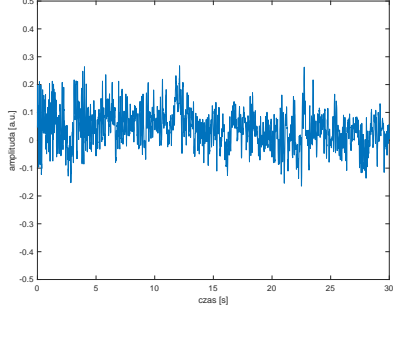
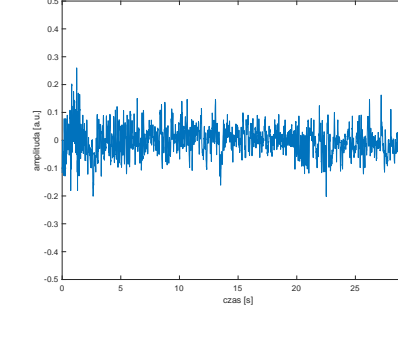
się z zapisów całonocnej polisomnografii: EEG, EOG, EMG oraz przepływ powietrza przy nosie i ustach, ruchy klatki piersiowej oraz brzucha, saturacja krwi tętniczej, poziom głośności chrapania i zmiany pozycja ciała wraz z równoczesnym trzykanałowym EKG, wykonanym metodą Holtera [317]. Badania diagnostyczne wykonane u pacjentów z podejrzeniem zaburzeń oddychania podczas snu zostały zarejestrowane w *St. Vincent's University Hospital Sleep Disorders Clinic* w Dublinie [317]. Sygnały polisomnograficzne zostały pozyskane z wykorzystaniem systemu Jaegera-Toenniesa (Erich Jaeger GmbH, Germany) [317]. Zapis całego badania wykonanego u każdego pacjenta zapisany jest w pliku w formacie .rec, który składa się ze wszystkich wymienionych sygnałów biomedycznych zapisanych w formacie EDF. Sygnał EEG został zarejestrowany w dwóch lokalizacjach elektrod: C3-A2 i C4-A1 i próbkowany z częstotliwością 128 Hz. W bazie danych znajdują się pliki z badaniami 25 osób (4 kobiet i 21 mężczyzn, w wieku od 38 do 68 lat). Sygnały są opisane przez jednego specjalistę i zawierają adnotację odnośnie faz snu, zgodnie z zaleceniami opracowanymi przez Rechtschaffen i Kalesa [263] oraz czas rozpoczęcia i czas trwania zdarzeń oddechowych z dokładnością do 1 sekundy. Wśród zdarzeń oddechowych rozróżniono bezdech obturacyjny, centralny i mieszany oraz spłycenia oddychania (obturacyjne, centralne i mieszane) oraz epizody oddechu periodycznego (Cheyne'a-Stokesa) [317].

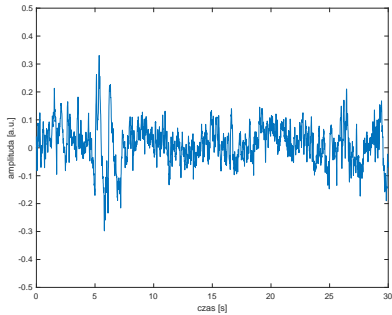
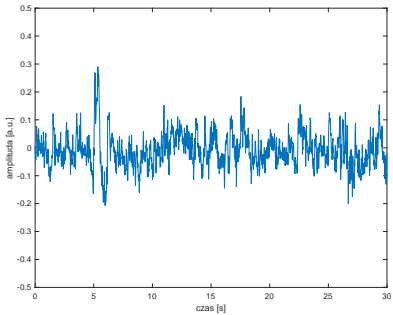
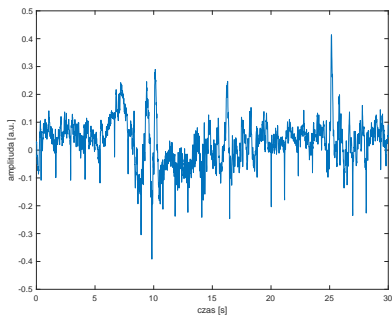
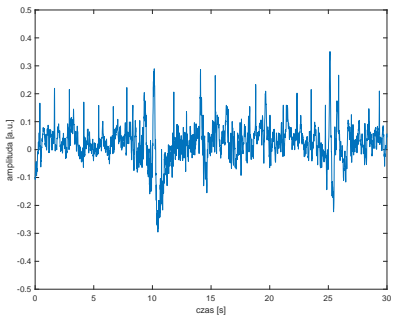
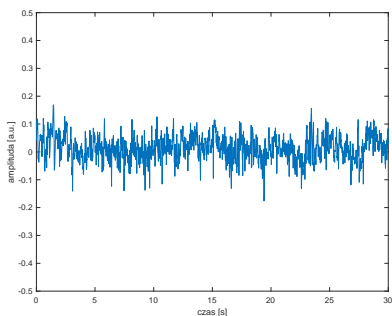
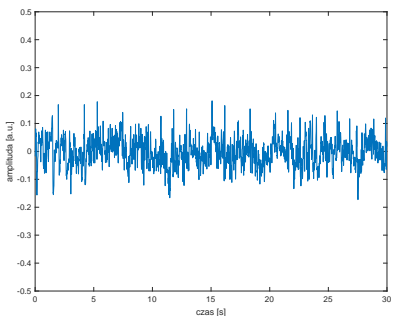
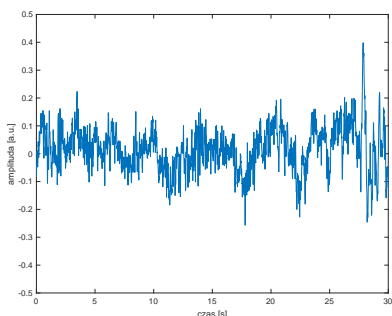
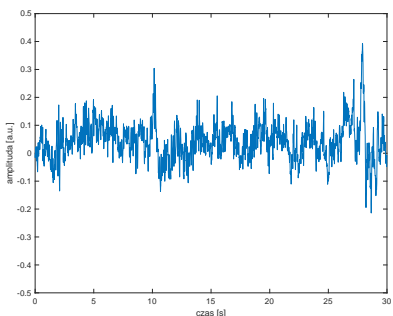
Pliki są ciągłym zapisem całonocnego badania o czasie trwania od około 7 do 8 godzin. Sygnały te zostały podzielone na 30-sekundowe epoki. Podział EEG na 30-sekundowe epoki jest zgodny z aktualnymi zaleceniami międzynarodowej klasyfikacji zaburzeń snu (ICSD-3) zatwierdzonej przez American Academy of Sleep Medicine [17]. Długość epizodów bezdechu i spłycenia oddychania w tej bazie danych wynosi od kilku do maksymalnie kilkudziesięciu sekund, przy czym większość zdarzeń oddechowych ma czas trwania od 20 do 35 sekund. Szczegóły procedury podziału sygnałów opisane są w następnym Rozdziale. Dlatego zamiast równomiernego podziału sygnału, 30-sekundowe epoki zostały opisane wokół epizodów bezdechu lub spłycenia oddychania w taki sposób, że w połowie epoki znajduje się środek epizodu oddechowego bez względu na jego długość trwania. Ponadto została również losowo wybrana pewna ilość epok zawierających normalne oddychanie bez odnotowanych zdarzeń oddechowych. Podział został wykonany w oparciu o adnotacje przygotowane przez specjalistów. Wydzielone z sygnału epoki zostały wstępnie podzielone na 7 klas: 1 – normalne oddychanie (NORM), 2 – bezdech

obturacyjny (OSA), 3 – bezdech centralny (CSA), 4 – bezdech mieszany (MSA), 5 – obturacyjne s płycenie oddychania (OSH), 6 – centralne s płycenie oddychania (CSH), 7 – mieszane s płycenie oddychania (MSH). Podział taki umożliwia w przyszłości łączenie danych w większe klasy. Ze wszystkich sygnałów EEG, dla każdej z dwóch lokacji elektrod uzyskano 6016 epok, pochodzących z różnych klas, zatem łącznie jest ich 12032. Szczegółowy opis dotyczący ilości epok w poszczególnych klasach oraz przykładowe epoki pochodzące z zsynchronizowanych odprowadzeń z dwóch lokalizacji elektrod przedstawiono w Tabeli 4.1. Najwięcej epok pochodzi z okresów normalnego oddychania. Epoki pochodzące ze zdarzeń oddechowych można podzielić na bezdechy oraz s płycenia oddychania. S płycenia oddychania występowały dużo częściej niż pełne bezdechy. Wśród bezdechów wyróżniono 288, 170 i 128 kolejno dla centralnego, obturacyjnego i mieszanego bezdechu co w sumie daje 586 epok. Natomiast s płycień oddychania zaobserwowano 2397 epok, w tym 1326 typu obturacyjnego, 969 typu centralnego i 102 mieszanego.

Epoki zapisane zostały w formacie .mat w folderach odpowiadającym poszczególnym klasom, w celu dalszego przetwarzania ich w środowisku Matlab. Nazwy plików zostały utworzone według schematu 30_epoka_C3A2_xxxx.mat lub 30_epoka_C4A1_xxxx.mat rozpoczynając od 0001, w zależności z którego odprowadzenia sygnału EEG pochodzi epoka, gdzie xx oznacza jej numer w danej klasie (numerowany od 01). Ponadto każdy plik oprócz 30-sekundowego fragmentu sygnału EEG zapisanego pod nazwą zmiennej epoka zawiera również inne dane takie jak: przedzial_epoki – czyli przedział czasowy epoki w sygnale w oryginalnych adnotacji z dokładnością do 1 sekundy, klasa – zawierająca numer klasy, do której należy epoka, czas_zdarzenia – w którym jest informacja o czasie trwania zdarzenia oddechowego w epoce oraz plik – w którym zapisany jest numer pliku, z którego pochodzi epoka. Baza danych epok została opracowana dla obu kanałów EEG: C3-A2 i C4-A1, jednak w niniejszej pracy, zgodnie z jej celem, na dalszych etapach wykorzystane zostaną tylko sygnały jednokanałowego EEG z lokalizacji elektrod C3-A2.

Tabela 4.1. Opis przygotowanej bazy danych 30-sekundowych epok sygnału EEG wraz z przykładowymi zapisami epok równocześnie z obu kanałów EEG C3–A2 i C4–A1.

Klasa		Przykładowe epoki EEG		
Numer	Nazwa	Ilość epok	C3–A2	C4–A1
1	Normalne oddychanie (NORM)	3033×2		
2	Bezdech obturacyjny (OSA)	170×2		
3	Bezdech centralny (CSA)	288×2		

Numer	Nazwa	Ilość epok	C3-A2	C4-A1
4	Bezdech mieszany (MSA)	128×2		
5	Obturacyjne sptyczenie oddychania (OSH)	1326×2		
6	Centralne sptyczenie oddychania (CSH)	969×2		
7	Mieszane sptyczenie oddychania (MSH)	102×2		

Rozdział 5

Przetwarzanie wstępne całonocnych zapisów EEG

Przetwarzanie wstępne jest zbiorem wielu etapów przetwarzania sygnału, poprzedzającym właściwą analizę danych, które jest niezbędne do uzyskania sygnału EEG pozbawionego zakłóceń. Projektowanie procedur wstępnego przetwarzania sygnału może mieć wpływ na późniejsze wyniki automatycznej analizy danych EEG [148].

Zakłócenia w zarejestrowanym sygnale EEG można podzielić na dwa rodzaje: pochodzenia zewnętrznego oraz fizjologiczne, nazywane również artefaktami. Wśród zakłóceń pochodzenia zewnętrznego wyróżnia się pochodzące od:

- sprzętu – związane z:
 - polem e-m linii energetycznej (50 Hz),
 - elektronicznym przetwarzaniem sygnału,
 - elektrodami:
 - impedancją odprowadzeń,
 - elektrodą odniesienia,
 - złemu przyleganiu elektrod lub przemieszczaniu się przewodów,
 - uszkodzeniem elektrody lub przewodu,
 - zakłóceniem elektromagnetycznym odbieranym przez doprowadzenia,
 - zakłóceniem typu „*electrode pop*”, związanymi z nagłym wzrostem amplitudy potencjału, a następnie szybkim zanikiem związane z różnicą potencjałów pomiędzy elektrodą, a skórą,
- oraz otoczenia zewnętrznego – związane z pracą różnych urządzeń elektrycznych i elektronicznych znajdujących się w otoczeniu, w tym również podczas rejestracji innych sygnałów biomedycznych w trakcie polisomnografii [267].

Wśród zakłóceń wewnętrznych związanych z funkcjonowaniem narządów i układów fizjologicznych wyróżnia się artefakty wywołane:

- pracą serca i tętnem,
- aktywnością mięśni szkieletowych, w tym poruszaniem się,
- ruchami gałek ocznych i mruganiem,
- aktywnością oddechową,
- zmianami w potliwości skóry,
- ruchami języka i żuchwy,
- chrapaniem [267].

5.1 Stosowane metody wstępnego przetwarzania sygnału EEG

Celem przetwarzania wstępnego sygnału EEG jest jego przygotowanie do dalszego, efektywnego przetwarzania. Jego efektem jest uzyskanie sygnału zawierającego jedynie elektryczną aktywność mózgu bez zakłóceń lub ograniczenie zakłóceń istniejących w oryginalnym sygnale. Zakłada się, że zastosowanie metod wstępnego przetwarzania sygnału może mieć pozytywny wpływ na wyniki dalszej analizy sygnału EEG [38], [106], [165], [265]. Wstępne przetwarzanie sygnału EEG obejmuje takie metody jak: regulacja odniesienia, eliminacja kanałów EEG nienadających się do dalszej analizy oraz usuwanie zakłóceń i artefaktów z sygnału EEG [148].

5.1.1 Metody wczesnego przetwarzania sygnału EEG niezwiązane z artefaktami fizjologicznymi

Wczesne przetwarzanie sygnału EEG (ang. *Early-Stage Preprocessing*) obejmuje podstawową analizę sygnału, która zazwyczaj jest wykonywana w obrębie całego sygnału EEG i jest niezależna od konkretnego typu artefaktów. Analiza ta dotyczy usuwania szumów z sygnału, ustalenie poziomu odniesienia, eliminację niewłaściwie zarejestrowanych sygnałów z bazy danych oraz standaryzacji, normalizacji, podziału sygnału na epoki i klasy [148].

5.1.1.1 Usunięcie fragmentów sygnałów EEG o zbyt dużej amplitudzie

Jedynym z podstawowych etapów przetwarzania wstępnego zarejestrowanych sygnałów EEG jest wykrycie zakłóconego lub niepoprawnie zarejestrowanego sygnału EEG lub jego fragmentu. Możliwe jest odrzucenie całych sygnałów, które z powodu dużej ilości zakłóceń tego rodzaju nie nadają się do dalszej analizy, usunięcie fragmentów sygnałów, które zawierają zakłócenia lub rekonstrukcję zakłóconych fragmentów sygnału

poprzez interpolację wykonaną na podstawie sąsiadujących próbek sygnału, wielomianów wyższego rzędu lub funkcji radialnej. Ponadto sygnał EEG jest podatny na występowanie czasowo zlokalizowanych zakłóceń o nadmiernej amplitudzie (ang. *Glitches*), które mogą być związane z artefaktami pochodzenia zewnętrznego lub wewnętrznego np. z artefaktami mięśniowymi lub zakłóceniami wynikającymi z ruchu elektrod lub przewodów. Zakłócenia tego typu mogą być skorelowane pomiędzy różnymi odprowadzeniami EEG zarejestrowanymi w tym samym badaniu lub występować niezależnie dla każdego kanału EEG. Jednak należy pamiętać, że zazwyczaj prawdziwa aktywność mózgu ma tendencję do skorelowania różnych kanałów EEG [61].

Wykrycie zakłóconych sygnałów polega na przeglądzie wszystkich zarejestrowanych sygnałów oraz identyfikacji sygnałów o nadmiernie dużych amplitudach spowodowanych np. odklejeniem się elektrody lub nasyceniem toru pomiarowego. Wykrycie sygnału o zbyt dużych amplitudach może być przeprowadzone poprzez:

- Obliczenie *z-score*, czyli liczby odchyłeń standardowych charakteryzujących różnicę próbki od średniej zbioru danych i porównanie tej wartości do wartości progu odrzucenia.
- Zbadanie korelacji pojedynczego kanału z innymi - prawidłowe zapisy EEG wykazują korelację między kanałami w zakresie niskich częstotliwości. W związku z tym zbadanie korelacji jednego kanału z innymi zarejestrowanymi równocześnie po filtrowaniu dolnoprzepustowym może umożliwić wykrycie zakłóconych sygnałów EEG.

Co więcej, zakłócony kanał EEG często wykazuje stosunkowo dużą energię w pasmach o wysokiej częstotliwości. W związku z tym możliwe jest wykrycie zakłóconego kanału EEG poprzez obliczenie stosunku mocy składowych o wysokiej częstotliwości do mocy składowych o niskiej częstotliwości [148].

5.1.1.2 Normalizacja i standaryzacja

Normalizacja i standaryzacja sygnału może być wykonywana dla surowego, całonocnego sygnału EEG jak i dla danych pochodzący z sygnału EEG, które zostały już poddane przetwarzaniu wstępnemu lub dalszej analizie. Umożliwiają zniwelowanie różnic pomiędzy sygnałami związanych z różnicami w wartościach poprzez przeskalowanie wartości w wybranych zakresie.

Normalizacja umożliwia ujednoczenie wszystkich elementów w wektorze w zakresie od wybranej minimalnej do maksymalnej wartości, niezależnie od ich oryginalnych wartości i odchyleń standardowych. Normalizacja min-max wykonywana jest w oparciu o wzór:

$$n(t) = \frac{(x(t) - \min_x)}{\max_x - \min_x} \cdot (\max - \min) + \min, \quad [5.1]$$

gdzie \max_x i \min_x oznaczają minimalną i maksymalną wartość w sygnale $x(t)$, a \max i \min to nowe, wybrane wartości minimalna i maksymalna. Zazwyczaj przeskalowanie danych wykonywane jest w zakresie od 0 do 1 lub od -1 do 1.

Standaryzacja (*z-score*) przeskalowuje próbki w zakresie rozkładu normalnego (Gaussa) z zerową średnią i jednostkową wariancją, korzystając z poniższego równania:

$$x_{st} = \frac{x - \mu}{\sigma}, \quad [5.2]$$

gdzie μ to wartość oczekiwana (średnia) a σ to odchylenie standardowe obliczone dla sygnału $x(t)$ [341].

5.1.1.3 Usunięcie linii trendu

W sygnale EEG możliwe jest występowanie dryftu, którego źródłem mogą być reakcje występujące na styku elektrody i skóry. Jest on obserwowany jako powoli zmieniający się potencjał linii podstawowej danej elektrody. Zazwyczaj linie trendu są usuwane z sygnału z wykorzystaniem filtrów górnoprzepustowych (ang. *Detrending*). Niestety, te metody usuwania występującej w sygnale linii trendu mogą powodować powstanie w sygnale nowych artefaktów [61].

A. Filtracja górnoprzepustowa

W celu usunięcia linii trendu z sygnału EEG stosowane są filtry górnoprzepustowe, zazwyczaj z częstotliwości odcięcia od 0,1 do 2 Hz, które skutecznie tłumią składową wolnoczęstotliwościową sygnału. Jednak taki sposób usunięcia linii trendu może mieć również wpływ na usunięcie użytecznych niskich składowych częstotliwości sygnału, charakterystycznych dla fal mózgowych z zakresu *delta*, i tym samym zmniejszyć ilość informacji w sygnale [61], [99]. Ponadto tego rodzaju filtry posiadają długą odpowiedź impulsową, co może powodować zniekształcenia.

Aby uniknąć zniekształceń związanych z filtrowaniem, czasem stosowane są filtry zerofazowe (ang. *Zero-Phase Filtering*). Należy jednak być ostrożnym w stosowaniu do sygnału EEG, którego źródłem jest elektryczna aktywność mózgu, filtrów innych niż przyczynowe, ponieważ wpływają one na dane wyjściowe i tym samym mogą mieć wpływ na wydedukowaną sekwencję zdarzeń w mózgu oraz związków przyczynowo-skutkowych pomiędzy nimi [61].

B. Parametryczne metody usuwania linii trendu

Usunięcie linii trendu można uzyskać poprzez dopasowanie do danych pewnej funkcji, np. liniowej lub wielomianu, a następnie odjęcie jej od sygnału. Taki sposób usunięcia wolnozmiennych trendów z sygnału umożliwia ograniczenie zniekształcenia sygnału związanego z ich usunięciem w stosunku do filtracji górnoprzepustowej [61]. Zniekształcenia sygnału po takim usunięciu linii trendu mogą jednak występować, jeżeli w sygnale występują lokalne piki, związane z gwałtownymi zmianami amplitudy, co może powodować tzw. efekt dzwonienia, analogiczny jak skutek filtrowania górnoprzepustowego. Co więcej, występowanie w sygnale gwałtownych zmian amplitudy może mieć wpływ na dopasowanie funkcji odejmowanej i tym samym może powodować niewłaściwe usunięcie linii trendu w częściach sygnału, w których nie występują gwałtowne zmiany amplitudy, i tym samym wprowadzać do sygnału nowy trend, który nie występował w nim pierwotnie. Rozwiązaniem tego problemu może być tzw. odporne usuwanie trendu (ang. *Robust Detrending*), w którym próbki o zbyt dużej amplitudzie nie są brane pod uwagę i dopasowanie funkcji odejmowanej zależy jedynie od poprawnych fragmentów sygnału. Nie redukuje to odchyień od typowej amplitudy sygnału, ale reszta danych pozbawiona jest linii trendu [61].

5.1.1.4 Uśrednianie potencjału odniesienia (ang. *Rereferencing*)

Sygnał EEG z danej lokacji elektrod jest zmierzonym jej potencjałem względem innej elektrody, zwanej elektrodą odniesienia. Sygnał zarejestrowany przez dowolne odprorowadzenie EEG zależy od położenia elektrody odniesienia na czaszce, a ewentualne zakłócenia występujące na elektrodzie odniesienia, np. szum kontaktowy, mają wpływ na wszystkie zarejestrowane sygnały, które są zmierzone względem niej. Dlatego czasem, aby zmniejszyć zależność sygnału od położenia elektrody odniesienia, można zastosować odniesienie do średniej, czyli odejmowanie od każdej elektrody średniej ze wszystkich elektrod lub innej kombinacji liniowej. Choć tym sposobem można

zredukować szum na fizycznej elektrodzie odniesienia, to uśredniony szum z pozostałych elektrod jest wprowadzany do wszystkich kanałów EEG [61]. Uśrednianie potencjału odniesienia jest przykładem filtrowania przestrzennego (ang. *Spatial Filtering*) [61].

5.1.1.5 Usunięcie zakłóceń pochodzących od sieci energetycznej

Zazwyczaj redukcja zakłóceń od sieci energetycznej realizowana jest poprzez zastosowanie filtru pasmowozaporowego dla częstotliwości 50 Hz lub 60 Hz i jego określonej szerokości odcięcia w okolicy wybranej częstotliwości. Należy zauważyć, że wykorzystanie filtru pasmowozaporowego skutecznie usuwa wąskopasmowe zakłócenia z sieci energetycznej, ale może powodować niezamierzone zniekształcenia w składowych sygnału w zakresie w pobliżu częstotliwości odcięcia filtru oraz przejściowe oscylacje w sygnale EEG, które mogą utrudnić interpretację danych. Wykorzystanie filtrów dolnoprzepustowych o częstotliwości niższej niż dolna wartość częstotliwości odcięcia filtru pasmowozaporowego może zminimalizować powstające zniekształcenie, równocześnie powodując zmianę struktury czasowej sygnału EEG lub niewłaściwe oddziaływanie pomiędzy kanałami EEG [148].

Inną metodą usuwania zakłóceń od sieci energetycznej, która pozwala unikać problemów związanych z realizacją filtra pasmowozaporowego, jest metoda polegająca na dokładnym oszacowaniu składowej z sieci energetycznej zawartej w zarejestrowanych sygnałach i następnie odjęciu jej od analizowanego sygnału EEG. Metoda ta wykorzystuje dekompozycję wielostopniową, aby znaleźć składowe szumu z sieci energetycznej w sygnale. Na początku zastosowane jest krótkie okno czasowe przesuwające się po sygnale, w którym przeprowadzana jest transformacja szeregów czasowych w oparciu o temperowanie w celu oszacowania energii widmowej sygnału w każdym paśmie częstotliwości. Następnie wykorzystywane są modele regresyjne po to, aby oszacować amplitudę i fazę zakłócenia sinusoidalnego (np. 50 lub 60 Hz) w dziedzinie częstotliwości oraz *F*-test Thompsona do oceny wielkości oszacowanego zakłócenia. Ostatecznie zrekonstruowana składowa z sieci energetycznej jest odejmowana od oryginalnego sygnału EEG. Cały proces jest powtarzany, aż wielkość amplitudy przy częstotliwości zakłócenia stanie się nieistotna. W ten sposób komponenty harmoniczne można usunąć bez uszkodzenia składowych widmowych tła [148].

5.1.2 Metody przetwarzania artefaktów

Jak to przedstawiono na początku rozdziału, w sygnale EEG występują różnego rodzaju zakłócenia, w tym również artefakty pochodzące z różnych źródeł, które mają wpływ na sygnał i mogą utrudniać jego dalszą analizę. Zmiany w sygnale związane z artefaktami można obserwować zarówno w dziedzinie czasu jak i częstotliwości. Niektóre artefakty mogą występować równocześnie we wszystkich rejestrowanych odprowadzeniach EEG, inne mogą występować lokalnie w tylko jednym z rejestrowanych kanałów. Artefakty mogą mieć różny charakter: mogą pojawiać się jako regularne zdarzenia okresowe, jak np. EKG lub tętno, podczas gdy inne mogą występować nieregularnie. Podczas rejestracji sygnału EEG możliwe jest w pewnym stopniu uniknięcie występowania artefaktów poprzez prawidłowe przeprowadzenie badania oraz przygotowanie rejestratora, np. poprzez poprawne uziemienie, które może zmniejszyć zakłócenia pochodzące z sieci energetycznej. Ponadto w czasie rutynowego badania EEG instruuje się pacjenta, aby pozostał w bezruchu i unikał niepotrzebnych ruchów ciała. Oczywiście, podczas długotrwałej rejestracji sygnału EEG przeprowadzonego podczas snu, niemożliwe jest uniknięcie ruchu pacjenta. Co więcej nie jest możliwe uniknięcie wpływu artefaktów fizjologicznych, które są mimowolne [152].

Metody przetwarzania artefaktów można podzielić na techniki wykrywania artefaktów, usuwania artefaktów lub ich redukcji. Wykrywanie artefaktów jest najważniejszym krokiem w procesie przetwarzania artefaktów. Artefakty bardzo często pokrywają się z sygnałem EEG zarówno w dziedzinie czasu jak i częstotliwości, dlatego zazwyczaj nie jest możliwe zastosowanie prostych metod przetwarzania sygnału, takich jak np. filtracja. Do efektywnego wykrycia artefaktu niezbędna jest znajomość zarówno artefaktu jak i również charakterystyki sygnału EEG [152]. Identyfikacja artefaktu w sygnale EEG polega na wykryciu epoki sygnału zawierającej artefakt lub wykrycie niezależnego komponentu (np. sygnał EKG) w sygnale EEG. Wykrycie artefaktu umożliwia jego dalsze przetworzenie, które może polegać na usunięciu tych fragmentów sygnału lub zastosowanie metod umożliwiających usunięcie zakłóceń z sygnału, bez jego zniekształcenia, i jego wykorzystanie w dalszej analizie. Aktualnie, ze względu na możliwość zastosowania zaawansowanych technik usuwania artefaktów, preferowany jest ten rodzaj analizy zamiast usuwania zakłóconych fragmentów. Mimo to w niektórych zastosowaniach, np. w analizie offline lub podczas uczenia klasyfikatorów, rozsądne może

być usunięcie epok zaburzonych artefaktami [152]. Najważniejszym celem usuwania artefaktów z sygnału jest zminimalizowanie wpływu artefaktów bez zniekształcenia analizowanego sygnału. Metody wykrywania artefaktów można również podzielić na te, które są wykonywane dla wielokanałowych oraz jednokanałowych rejestracji EEG.

5.1.2.1 Metody przetwarzania artefaktów w wielokanałowym EEG

W diagnostyce neurologicznej sygnał EEG jest rejestrowany z wykorzystaniem wielu odprowadzeń, umieszczonych na całej powierzchni głowy. Taki sposób rejestracji umożliwia uzyskanie pełnej informacji o elektrycznej aktywności mózgu i jego pracy w różnych obszarach.

A. Ślepa separacja źródeł

Ślepa separacja źródeł (ang. *Blind Source Separation* (BSS)) jest jedną z powszechnie stosowanych metod detekcji i usuwania artefaktów. Celem BSS jest ekstrakcja nieznanego sygnału źródłowego z sygnału będącego złożeniem wielu innych niezależnych, oraz umożliwienie estymacji tych sygnałów na podstawie żadnej lub bardzo ograniczonej wiedzy na temat ich źródeł i typów, tak aby na wyjściu uzyskać odseparowane niezależne sygnały. Najczęściej przyjmowane w tym podejściu założenie polega na tym, że sygnał (lub sygnały) zarejestrowany jest liniową kombinacją sygnałów źródłowych s i szumu addytywnego o charakterze szumu białego e :

$$x(t) = \mathbf{B} \cdot s(t) + e(t), \quad [5.3]$$

gdzie \mathbf{B} jest macierzą mieszania sygnałów, a celem BSS jest znalezienie oszacowania sygnału źródłowego poprzez oszacowanie macierzy odwrotnej do macierzy \mathbf{B} .

Podstawowym ograniczeniem BSS jest to, że ilość źródeł powinna być równa lub mniejsza niż ilość obserwowanych sygnałów oraz źródła powinny być niezależne (podczas analizy składowych niezależnych) lub maksymalnie nieskorelowane (podczas analiza korelacji kanonicznych). Istnieje kilka metod bazujących na technice BSS stosowanych w wybranych przypadkach.

- 1) Analiza składowych niezależnych (ang. *Independent Component Analysis* (ICA)) jest metodą, w której zakłada się, że wszystkie źródła są liniowo niezależne. W metodzie tej liczba zarejestrowanych kanałów musi być co najmniej równa liczbie niezależnych źródeł sygnału. Idea tej metody jest taka,

że po rozkładzie na sygnały niezależne odrzuca się ten, który jest artefaktem. Wykrywanie i usuwanie artefaktów może być wykonywane w sposób automatycznych poprzez określenie wartości progu odrzucenia komponentu, który jest zakłócony, z wykorzystaniem połączenia ICA z takimi metodami, jak transformacja falkowa (ang. *Wavelet Transform*, WT) lub dekompozycja empiryczna (ang. *Empirical Mode Decomposition* (EMD)) oraz z zastosowaniem klasyfikatora. Dodatkowo wykorzystuje się kanał referencyjny, charakterystyczny dla danego artefaktu w celu oceny, który komponent sygnału powinien zostać usunięty. Złożoność obliczeniowa tej metody jest zbyt duża, aby można ją zastosować do usuwania artefaktów podczas analizy online. Metoda najczęściej jest stosowana do usuwania artefaktów ocznych (EOG) i czasem innych sygnałów fizjologicznych [152].

- 2) Analiza korelacji kanonicznych (ang. *Canonical Correlation Analysis* (CCA)) to metoda umożliwiająca rozdzielenie wielu zmieszanych ze sobą sygnałów (również z zakłóceniami), wykorzystująca statystyki drugiego rzędu do wygenerowania nieskorelowanych komponentów. W metodzie tej możliwa jest ocena autokorelacji poszczególnych komponentów sygnału i tym samym znalezienie składowej o najmniejszej autokorelacji, która wskazuje na komponent z artefaktami. Metoda ta jest automatyczna oraz bardziej wydajna obliczeniowo niż ICA [152].
- 3) Analiza składowych morfologicznych (ang. *Morphological Component Analysis* (MCA)) umożliwia rozkład sygnału na komponenty, które mają różne cechy morfologiczne. Możliwe jest jej stosowanie tylko do niektórych typów artefaktów, których kształt fali lub morfologia są znane i dostępne w bazie danych. Skuteczność tej metody zależy od zgromadzonej bazy danych z wzorcowymi fragmentami sygnału z artefaktami. Zazwyczaj wykorzystywana jest do usuwania artefaktów mięśniowych, EKG, ocznych, związanych z zaciskaniem szczęki, połykaniem lub ruchami brwi [79], [152].

5.1.2.2 Metody przetwarzania artefaktów w jednokanałowym sygnale EEG

Znaczna część metod przetwarzania artefaktów nie może być zastosowana przy jednokanałowym sygnale EEG. Co więcej, niektóre metody wymagają również zarejestrowanego w tym samym czasie referencyjnego sygnału wpływającego, więc mogą

być one wykorzystywane dla danych pochodzących z PSG. Typowo według zaleceń AASM, podczas badania PSG wykonywanego w czasie snu rejestrowane są dwa symetryczne kanały EEG z rekomendowanej i zapasowej lokacji elektrod z odprowadzeń: centralnych (C3-A2, C4-A1), potylicznych (O1-A2, O2-A1) lub czołowych (F4-A1, F3-A2). Inne akceptowalne kanały, które mogą być zarejestrowane to: Fz-Cz, Fpz-A2 i Cz-Oz, C3-A2 [34]. Następnie, do dalszej analizy wykorzystywany jest jeden z nich: rekomendowany lub zapasowy, jeżeli rekomendowany uległ uszkodzeniu. Dlatego w tym podrozdziale zostaną zaprezentowane metody przetwarzania artefaktów, które mogą być stosowane dla jednokanałowego sygnału EEG.

A. Rozkład sygnału oparty na ICA

Opisane wcześniej ICA ma zastosowanie do analizy wielokanałowego sygnału EEG. Istnieją jednak prace, w których zastosowano elementy ICA do analizy jednokanałowego sygnału EEG w celu wyodrębnienia z tego sygnału składowych o różnym pochodzeniu [50], [81], [82], [86], [87], [163], [169], [191], [208]. W metodach analizy jednokanałowego sygnału EEG opartego na ICA zakłada się, że źródła sygnału są stacjonarne i rozłączne w dziedzinie częstotliwości. W związku z tym, że w sygnale EEG występują nieokresowe składowe oraz często artefakty pokrywają się z komponentami sygnału EEG, tradycyjną metodę ICA można stosować tylko w bardzo ograniczony sposób. Istnieją jednak metody będące połączeniem ICA i innych podejść, np. WT lub EMD, które znajdują zastosowanie w usuwaniu artefaktów z jednokanałowego sygnału EEG. W związku z charakterem sygnału EEG oraz artefaktów biologicznych, metody te umożliwiają usunięcie artefaktów tylko w pewnym, ograniczonym zakresie.

- 1) ICA oparte na transformacie falkowej (ang. *WT-based ICA*) polega na dekompozycji analizowanego sygnału na jego składowe (współczynniki szczegółowe i aproksymujące) z wykorzystaniem DWT. Następnie każdy niezależny komponent sygnału jest identyfikowany jako sygnał EEG lub jako artefakt. Jeśli wykryto artefakt, jest on zastępowany przez tablicę zer. Ostatecznie sygnał pozbawiony artefaktów jest uzyskiwany poprzez wykonanie transformacji odwrotnej IDWT.
- 2) ICA oparte na dekompozycji empirycznej (ang. *EMD-based ICA*) polega na rozkładzie sygnału na zbiór funkcji wewnętrznych (ang. *Intrinsic Mode Functions* (IMFs)). Z wykorzystaniem EMD możliwe jest usuwanie artefaktów bez wiedzy o ich charakterze. Efektem jest usunięcie IMFs zawierających artefakty,

rozpoznawanych na podstawie charakterystyki częstotliwościowej, a następnie zsumowanie pozostały w celu otrzymania sygnału pozbawionego zakłóceń [43], [163].

B. Nieujemna faktoryzacja macierzy

Nieujemna faktoryzacja macierzy (ang. *Nonnegative Matrix Factorization* (NMF)) jest skutecznym algorytmem umożliwiającym usuwanie artefaktów z sygnałów jednokanałowych, ponieważ pozwala na znalezienie ukrytych interakcji pomiędzy sygnałem EEG a artefaktami [339]. Metoda polega na utworzeniu macierzy opartej na krótkoczasowej transformacji Fouriera (ang. *Short-Time Fourier Transform* (STFT)), a następnie jej podziale na nieujemne wektory cech sygnału EEG będące zapisem widma mocy lub amplitudy. NMF pozwala na skuteczny rozkład sygnału na niezakłócone EEG i artefakty, o ile znany jest charakter danego zakłócenia [77], [162], [163].

C. Inne metody usuwania artefaktów z jednokanałowego sygnału EEG

Do usuwania artefaktów z jednokanałowego sygnału EEG wykorzystywane są również metody, które mogą być również stosowane do analizy wielokanałowych rejestracji EEG i są to:

- 1) usuwanie wartości odstających z sygnału EEG o zbyt dużej amplitudzie, skuteczne w wykrywaniu mrugnięć oraz ruchu gałek ocznych;
- 2) usunięcie trendu;
- 3) ocena wartości statystycznych w celu poszukiwania artefaktów – zazwyczaj artefakty posiadają nietypowe przebiegi czasowe, np. mogą to być zdarzenia przejściowe i nieoczekiwane. W związku z tym możliwa jest ich identyfikacja na podstawie rozkładu wartości danych z sygnału oraz kurtozy. Ujemne wartości kurtozy mogą wskazywać na obecność artefaktów;
- 4) ocena widma w dziedzinie częstotliwości, które polega na identyfikacji artefaktów na podstawie charakterystycznych wartości częstotliwości, np. ruchu mięśni (20-60 Hz), ruchy gałek ocznych (1-3 Hz) [81], [82].

Niektóre z tych metod zostały bardziej szczegółowo opisane w dalszej części rozdziału.

5.1.2.3 Metody przetwarzania artefaktów wykorzystywane dla wielokanałowego i jednokanałowego sygnału EEG

A. Usunięcie fragmentu sygnału z zakłóceniami

Jednym ze sposobów zmniejszania wpływu artefaktów na dalszą analizę sygnału EEG jest usunięcie fragmentu sygnału lub całej epoki, w którym zostały zidentyfikowane artefakty dowolnego typu. Wadą tej metody jest to, że powoduje ona utratę części danych i wiąże się z możliwością usunięcia ważnych informacji o sygnale EEG. Dawniej była to częściej stosowana metoda przetwarzania artefaktów, jednak aktualnie bardziej popularne są techniki usuwania artefaktów z sygnału zamiast odrzucenia całego fragmentu. Ta metoda może mieć pozytywny wpływ szczególnie podczas analizy offline lub podczas uczenia klasyfikatorów [81], [82], [152].

B. Regresja

Analiza regresji wykorzystuje złożony model liniowy opisujący zależność pomiędzy sygnałem obserwowanym i referencyjnym (sygnałem odniesienia związanym z artefaktem, np. dla artefaktów sercowych, sygnałem referencyjnym jest sygnał EKG). Jest to tradycyjna metoda identyfikacji próbek zawierających artefakty i umożliwiając usunięcie tych spośród nich, które nie należą do modelu. Ten sposób postępowania jest powszechną metodą stosowaną w celu usunięcia takich artefaktów fizjologicznych, jak te pochodzące z sygnału EKG i EOG. Analiza z wykorzystaniem regresji nie przynosi oczekiwanych rezultatów, jeśli nie jest dostępny sygnał referencyjny. Regresja liniowa ma zastosowanie jedynie dla kilku wybranych typów artefaktów ale, zgodnie z literaturą, nie jest preferowaną metodą analizy sygnału EEG, który jest sygnałem nieliniowym i niestacjonarnym [152].

C. Krótkoczasowa transformata Fouriera

STFT jest popularną, czasowo-częstotliwościową metodą analizy, wykorzystywaną do analizy niestacjonarnych szeregów czasowych, w tym również sygnałów biomedycznych, w szczególności sygnału EEG, który charakteryzuje się niestacjonarnymi właściwościami. Oznacza to, że zmiany częstotliwości związane z artefaktami lub innymi zdarzeniami w sygnale mogą zostać zarejestrowane w określonym oknie czasowym. STFT charakteryzuje się jednolitą rozdzielczością czasowo-częstotliwościową dla wszystkich częstotliwości, co nie jest korzystne w przypadku analizy

sygnału EEG, ponieważ – mimo że szerokość pasma może wynosić od 0 do nawet 120 Hz – zazwyczaj analizowany jest zakres częstotliwości do 50 Hz, a większość artefaktów, szczególnie ocznych i ruchowych, pojawia się w zakresie częstotliwości do 10 Hz. W związku z tym korzystniejsza dla analizy jest rozdzielczość niejednorodna, tak aby uzyskać wysoką rozdzielczość w niskich zakresach częstotliwości [152].

D. Transformacja falkowa

Transformacja falkowa (ang. *Wavelet Transform*, WT) umożliwia rozkład sygnału na ważoną sumę falek i funkcji skalujących. Można wyróżnić ciągłą (ang. *Continuous Wavelet Transform* (CWT)) oraz dyskretną transformatę falkową (ang. *Discrete Wavelet Transform* (DWT)), w której sygnał wejściowy jest sygnałem dyskretnym. Efektem DWT jest rozłożenie sygnału na współczynniki szczegółowe i aproksymujące. Następnie, w celu usunięcia zakłóceń z sygnału, dla określonych współczynników stosowany jest próg o pewnej wartości w celu usunięcia z nich artefaktów [7], [152]. Ostatecznie sygnał z usuniętymi artefaktami jest rekonstruowany poprzez zastosowanie odwrotnej transformaty falkowej IDWT, polegającej na dodanie wszystkich współczynników szczegółowych i aproksymujących, wymnożonych przez odpowiednie faleki i funkcje skalujące. Możliwe jest również połączenie WT i transformaty Hilberta w celu usunięcia artefaktów związanych z mruganiem oczami [48]. DWT zostanie omówiona szczegółowiej w Rozdziale 6.1.

E. Dekompozycja empiryczna

Dekompozycja empiryczna (EMD) jest metodą opartą na danych. Polega na rozkładzie sygnału na zbiór funkcji wrodzonych (IMF). Z wykorzystaniem EMD możliwe jest usunięcie artefaktów o wysokich częstotliwościach związanych z zakłóceniami z sieci energetycznej oraz sygnału EMG. EMD znajduje zastosowanie szczególnie wtedy, gdy częstotliwość artefaktów wyraźnie różni się od częstotliwości charakterystycznych dla sygnału [152], [340]. EMD zostanie omówiona szczegółowiej w Rozdziale 6.1.

F. Filtracja adaptacyjna

Filtracja adaptacyjna (ang. *Adaptive Filtering* (AF)) polega na przygotowaniu układu filtrów liniowych, które mogą być modyfikowane z wykorzystaniem wielu parametrów i w ten sposób mogą być dostosowywane do analizowanego sygnału. Wagi filtrów mogą być dostosowywane z wykorzystaniem sprzężenia zwrotnego. Filtracja

adaptacyjna często jest wykorzystywane podczas analizy sygnału EEG pochodzącego od pacjentów z epilepsją. Możliwe jest również połączenie referencyjnego sygnału artefaktu z filtrowaniem adaptacyjnym i w ten sposób uzyskanie sygnału bez zakłóceń. Filtracja adaptacyjna znajduje swoje zastosowanie w usuwaniu artefaktów pochodzących z EKG i EOG [72], [152].

G. Metody Hybrydowe

Metody hybrydowe (ang. *Hybrid Methods*) polegają na połączeniu kilku metod, co umożliwia wykorzystanie ich różnych zalet. Łączy się je w jedną metodę wykrywania i usuwania artefaktów, składającą się z dwóch lub więcej etapów. Wśród metod hybrydowych można wyróżnić następujące połączenia:

- 1) WT i BSS (WT-BSS),
- 2) EMD i BSS (EMD-BSS),
- 3) BSS i maszyny wektorów nośnych (ang. *Support Vector Machine (SVM)*) (BSS-SVM),
- 4) filtrowania opartego na regresji (REG) i BSS (REG-BSS),
- 5) WT i sieci neuronowe (ang. *Artificial Neural Network (ANN)*) (WT-ANN) [152].

H. Ocena cech statystycznych

Możliwe jest obliczenie oraz ocena wartości statystycznych w celu wykrycia artefaktów w sygnale EEG. Następnie określa się próg odrzutu, charakterystyczny dla danego artefaktu. Metody te znajdują zastosowanie w połączeniu z klasyfikatorem lub w metodach opartych na WT, EMD lub ICA. Wśród używanych cech statystycznych można wyróżnić: entropię, kurtozę, wartość maksymalną [152].

5.1.3 Podział sygnału na epoki i klasy

Sygnał EEG, będący zapisem wykonanego badania o określonym czasie, zazwyczaj opisywany jest przez wykwalifikowanych ekspertów którzy zamieszczają synchroniczne adnotacje o wystąpieniu różnego rodzaju zdarzeń oraz klasyfikują fragmenty sygnału odpowiadające określonym stanom pracy mózgu. W badaniach nad snem, w sygnale EEG typowo poszukuje się odpowiedzi odnośnie występowania okresów normalnej aktywności mózgu, okresu snu łącznie z podziałem na fazy snu oraz czasowo występujących zdarzeń bezdechu sennego lub spłycaenia oddychania i wzbudzeń w sygnale EEG.

Typowo, według kryteriów zapisu sygnału EEG zdefiniowanych przez AASM, epoka sygnału EEG to zapis 30-sekundowy sygnału EEG i zazwyczaj dla takich fragmentów sygnału wykonywany jest opis faz snu [17]. Jednak w związku z tym, że niektóre zdarzenia rejestrowane w sygnale EEG mogą mieć krótszy czas trwania niż 30 sekund, aby w prawidłowy sposób oznaczyć ich wystąpienie oraz czas trwania, zazwyczaj są one opisywane z większą rozdzielczością, np. 1 sekundy. Dodatkowe problemy wynikające z podziału danych na epoki mogą wynikać stąd, że często wykorzystywany podział na równomierne odcinki czasu powoduje, że jedna epoka może zawierać fragmenty pochodzące również z innych klas. W przypadku bezdechu, którego czas trwania waha się od kilku do kilkudziesięciu sekund, w epokach mogą być obecne kilku- lub kilkunastosekundowe fragmenty sygnału, zaklasyfikowane do normalnego oddychania. Często w analizie sygnału EEG w badaniach nad snem wyróżnia się następujące zdarzenia związane z opisem struktury snu: fazy snu (REM, NREM1-4), artefakty oraz fragmenty nieokreślone; oraz zdarzeń oddechowych: czas występowania zdarzenia i typ zdarzeń związanych z bezdechem sennym (bezdech: OSA, CSA, MSA i spłycenia oddychania: OSH, CSH i MSH), oddychaniem okresowym, oddechem Cheyensa-Stokesa, zdarzeniami związanymi z czynnością serca: bradykardia i tachykardia [317] oraz z normalnym oddychaniem. Opis zdarzeń w sygnale oraz podział sygnału na epoki i klasy powiązane z typem zdarzeń umożliwiają wykonanie automatycznej analizy sygnału EEG oraz wykrywania zdarzeń w sygnale i klasyfikacji ich typu.

Zadanie wykrywania zdarzeń oddechowych jest problemem detekcji niezrównoważonych klas, w którym jedna klasa, w tym przypadku NORM, jest nadmiernie reprezentowana w zbiorze danych. Uwzględnienie tego faktu jest konieczne, aby zapobiec całkowitemu zignorowaniu jednej, mniej licznej klasy przez klasyfikator i zapobiec sytuacji, w której dokładność odzwierciedla jedynie podstawowy rozkład klas, a nie rzeczywistą wydajność systemu. W związku z tym wykorzystywane są sposoby zrównoważenia klas w zbiorze danych: nadmierne próbkowanie klasy mniejszościowej lub niedomierne próbkowanie klasy większościowej. Obie z tych metod mają wady. Zbytne zwiększenie ilości epok klasy mniejszościowej wykonane poprzez sztuczne namnażanie epok na podstawie małego zbioru może prowadzić do nadmiernego dopasowania modelu. Wśród metod nadpróbkowania można wymienić: losową replikację próbek klasy mniejszościowej oraz syntetyczną technikę nadpróbkowania klasy mniejszościowej

(ang. *Synthetic Minority Over-sampling Technique* (SMOTE)), która ma wiele odmian. Niewykorzystanie w klasyfikacji części epok może skutkować pominięciem danych, które mogą zapewniać istotne różnice pomiędzy analizowanymi klasami [22]. Często wykorzystywaną metodą redukcji klasy większościowej jest zastosowanie losowej eliminacji jej epok, tak aby zrównoważyć ilość cech we wszystkich klasach [22].

5.2 Wybór metod i efekty przetwarzania wstępnego

Wykorzystana baza danych jest zapisem badania PSG, dlatego oprócz sygnału EEG dostępne są również inne sygnały biomedyczne takie jak: EOG, EMG, EKG, przepływ powietrza, ruchy brzucha i klatki piersiowej, saturacja krwi tętniczej, sygnał dźwiękowy chrapania oraz pozycji ciała. Jednak w tej pracy nie będą one wykorzystywane na żadnym z etapów analizy sygnału, również podczas przetwarzania wstępnego, ponieważ ta praca koncentruje się na przetwarzaniu jedynie sygnału EEG.

W pracy zostały wykorzystane tylko całonocne sygnały EEG z jednej, rekomendowanej, centralnej (C3-A2) lokacji elektrod, zarejestrowane z częstotliwością 128 Hz, pochodzące z badań nad bezdechem sennym wykonanych w Sleep Disorders Clinic at St Vincent's University Hospital w Dublin u osób z podejrzeniem zaburzeń oddychania podczas snu. W opisie bazy danych sygnały zostały opisane przez eksperta zgodnie z zasadami opisanymi przez Rechtschaffen'a and Kales'a i wśród adnotacji, oprócz informacji o występowaniu faz snu i bezdechu sennego oraz spłycaenia oddychania, wyszczególnione zostały również fragmenty sygnału, które mogą zawierać artefakty (etykieta 6 w opisie) oraz fragmenty, które nie zostały przyporządkowane do żadnej innej grupy (etykieta 7 w opisie) [120], [317]. Nieokreślone fragmenty sygnału oraz fragmenty z artefaktami zostały usunięte podczas podziału sygnału na 30-sekundowe epoki.

Po wykonanej analizie literatury z zakresu przetwarzania wstępnego, w tym również usuwania artefaktów z sygnału EEG w zadaniu detekcji bezdechu sennego na podstawie tylko pojedynczego sygnału EEG, można wyróżnić kilka wykorzystywanych metod: usuwanie zakłóceń od sieci energetycznej [35], [121], [275], [159], korekcja linii trendu [102], [144], filtracja sygnału z wykorzystaniem filtrów cyfrowych [12], [102], [144], [322], usuwanie szumu białego z wykorzystaniem WT [343], [288] oraz normalizacja sygnału [35], [121], [275]. W pracach dotyczących detekcji bezdechu sennego na podstawie sygnału EEG, w których uwzględniono wykonanie przetwarzania wstępnego,

uzyskano wyniki klasyfikacji od 75% do 97,1% [12], [35], [121], [144], [145], [159], [275], [276], [322], [343].

W tej pracy, wśród metod przetwarzania wstępnego sygnału EEG oraz usuwania artefaktów, zdecydowano się na zastosowanie kilku metod:

- usunięcia wysycień z sygnału EEG,
- przepróbkowanie sygnału,
- usunięcie zakłóceń od sieci energetycznej oraz składowych o wysokich częstotliwościach powyżej 50 Hz,
- standaryzacji sygnału.

Po zapoznaniu się z sygnałami EEG, wykonanie usunięcia wysycień oraz wartości odstających wydaje się konieczne, ponieważ mimo, że w opisie bazy danych zgodnie z adnotacjami powinna znajdować się informacja o fragmentach sygnału nienadających się do analizy lub posiadających artefakty, to tak opisanych fragmentów w bazie danych jest niewiele, a po ich usunięciu w sygnale nadal widoczne są znaczne odchylenia amplitudy oraz wysycenia sygnału. Występowanie wartości odstających oraz wysycień jest często spotykane w zarejestrowanych sygnałach EEG, a ich przyczyną mogą być artefakty mięśniowe związane z poruszaniem się osoby badanej lub przemieszczaniem się elektrod. W związku z tym, że tego rodzaju artefakty są zwykle specyficzne dla konkretnego kanału EEG i nieskorelowane pomiędzy kanałami, w przeciwieństwie do prawdziwej aktywności mózgu, należy zaproponować metodę ich usuwania, która w miarę możliwości uwzględni inne zarejestrowane kanały tego samego sygnału [61]. W związku z tym, że w tej pracy wykorzystywane jest jednokanałowe EEG, drugi zarejestrowany (C4-A1) w badaniu sygnał EEG nie może być brany pod uwagę podczas usuwania fragmentów sygnału C3-A2. Gdyby jednak na dalszych etapach przetwarzania, a w szczególności podczas ekstrakcji cech, wykorzystywano epoki zarejestrowane w tym samym czasie dla obu kanałów EEG, fragmenty jednego sygnału usunięte ze względu na artefakty powinny być również usuwane z kanału drugiego.

W pracach dotyczących detekcji bezdechu sennego na podstawie sygnału EEG, czasem usuwanie zakłóceń pochodzących od sieci energetycznej wykonywane jest poprzez filtrację [35] lub pośrednio poprzez ograniczenie analizowanego pasma częstotliwości do wartości z przedziału od 35 Hz do 45 Hz [12], [31], [35], [102], [144], [145], [201], [275],

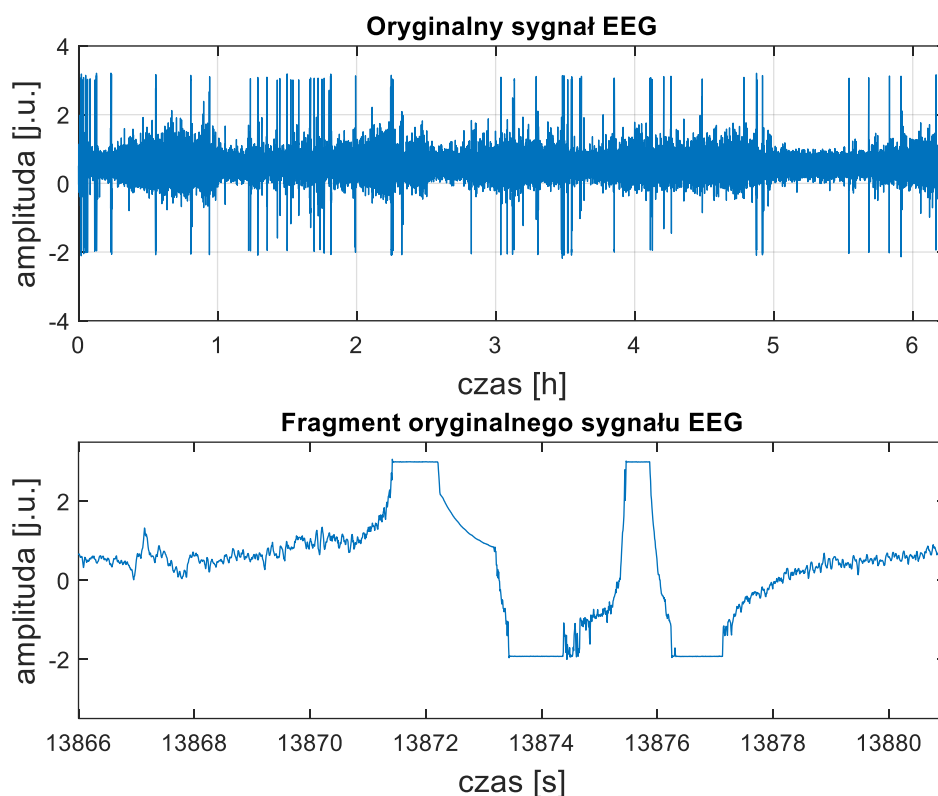
[343]. Takie ograniczenie pasma częstotliwości skutkuje pominięciem informacji zawartych w zakresie wyższych częstotliwości fal gamma. Według Bhattacharjee i in., ograniczenie częstotliwości analizowanych cech do 40 Hz umożliwia uzyskanie dokładności klasyfikacji bezdechu sennego porównywalnych do uzyskanych poprzez ekstrakcję cech wraz z częstotliwościami z zakresu 40-64 Hz [35], [316]. Istnieją również prace, w których badano zmiany mocy sygnału EEG przed, podczas i po epizodach bezdechu sennego, jednak nie zaobserwowano zmian związanych z epizodami bezdechu sennego dla częstotliwości powyżej 30 Hz [29], [53], [71], [88], [327]. Ponadto zrealizowano również badania, w których po wykonaniu selekcji cech umożliwiającej usunięcie cech nieróżnicujących w obrębie prac, uzyskano wektory cech, w których około 20% cech jest z zakresu wysokich częstotliwości między 32-64 Hz [249], [251].

Standaryzacja w obrębie całych zarejestrowanych sygnałów EEG umożliwia ujednolicenie energii sygnałów pochodzących z różnych badań oraz od różnych pacjentów [249], [250], [251]. W związku z tym wykonano standaryzację sygnałów.

5.2.1 Usuwanie artefaktów

5.2.1.1 Usuwanie wysyczeń i nadmiernych amplitud

Usuwanie wysyczeń z całonocnych zapisów sygnału EEG zostało wykonane poprzez automatyczną detekcję wysyczeń i efektów wysyczeń oraz wartości odstających, poprzez usunięcie całych 1-sekundowych fragmentów, w obrębie których zostały wykryte. Wysycenia zaobserwowano jako maksymalną lub minimalną amplitudę sygnału, która nie zmienia się w czasie lub jej zmiany są minimalne. Dodatkowo, w pobliżu wysyczeń występują również znaczne zniekształcenia sygnału o charakterze eksponencjalnym. Zaobserwowane zakłócenia zostały przedstawione na Rysunku 5.1. Wszystkie poniższe rysunki, jeśli nie są opisane inaczej, pochodzą z lokacji C3-A2 i zarejestrowane były podczas badania pacjenta ucdb002.



Rysunku 5.1. Całonocny sygnał EEG oraz jego fragment z lokacji C3-A2 od pacjenta ucdb002 z zaobserwowanymi zakłóceniami.

Zastosowany algorytm umożliwia analizę całego sygnału próbka po próbce i złożony jest z dwóch etapów. Celem pierwszego etapu algorytmu jest wykrycie fragmentów sygnału z wysyceniami lub zniekształceniami będącymi efektami wysyczeń oraz fragmentów o odstających wartościach amplitud. Aby ciąg próbek został uznany za zakłócenie związane z występowaniem wysyczeń, konieczne jest spełnienie trzech warunków:

- bezwzględna średnia różnica pomiędzy próbkami nie może być większa niż $r=0,012$;
- wykryty ciąg próbek musi mieć minimalną długość próbek $n=10$;
- odchylenie standardowe z ciągu wykrytych próbek nie może przekraczać wartości $\sigma =0,015$.

Wymienione wartości progowe zostały ustalone poprzez analizę fragmentów sygnału z wysyceniami, które zostały zidentyfikowane w wyniku analizy wzrokowej, a następnie obliczenie wartości progowych maksymalnych lub minimalnych związanych z wymienionymi wcześniej warunkami.


Następnie, na podstawie wiedzy o wartościach maksymalnych i minimalnych wysyczeń, wykonano detekcję fragmentów sygnału o nadmiernej amplitudzie. W tym celu obliczono średnie wartości dla maksymalnych ujemnych oraz dodatnich wysyczeń, których wartość jest mniejsza niż 80% wartości ujemnej i większa niż 80% wartości dodatniej. Dalej, na podstawie obliczonych średnich wartości ustalono próg, którego przekroczenie wskazuje na detekcję wartości odstającej. Progi dodatni i ujemny zostały ustalone jako:

$$prog_+ = m_+ - (0,05 \cdot m_+) \quad [5.4]$$

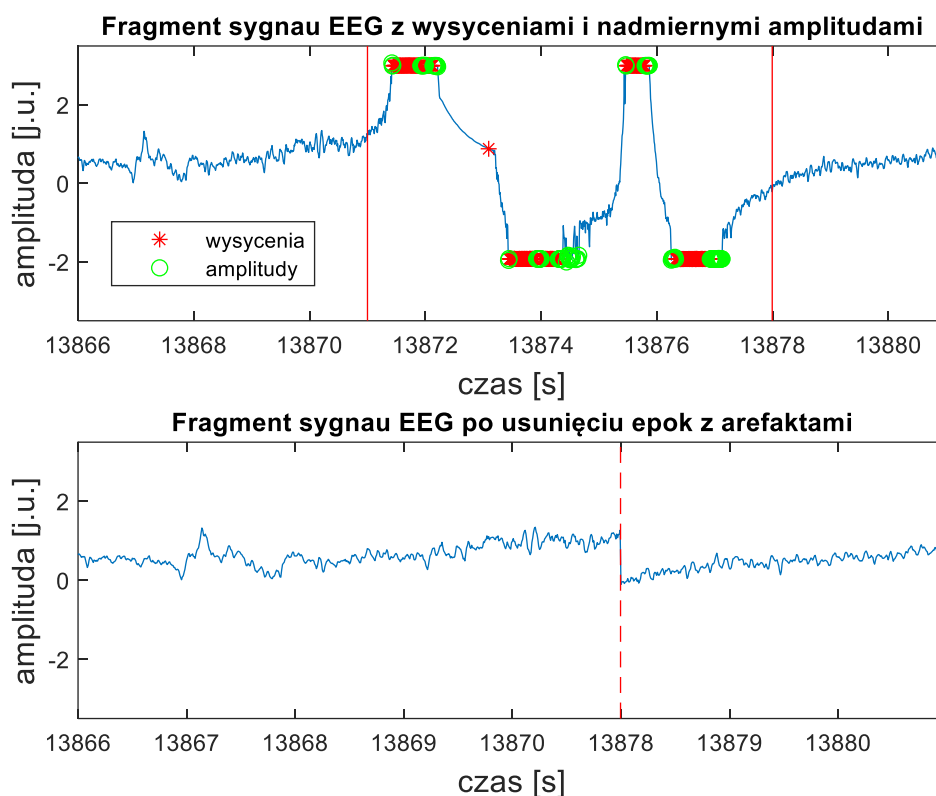
$$prog_- = m_- - (0,05 \cdot m_-) \quad [5.5]$$

gdzie m_+ to średnia z wartości dodatnich, a m_- to średnia z wartości ujemnych.

Na rysunku poniżej przedstawiono cały sygnał (Rysunek 5.2) po detekcji wysyczeń i efektów wysyczeń oraz detekcji próbek o odstających wartościach amplitudy. Natomiast na Rysunku 5.3 przedstawiono jego fragment przed i po usunięciu fragmentów sygnału zawierających artefakty.

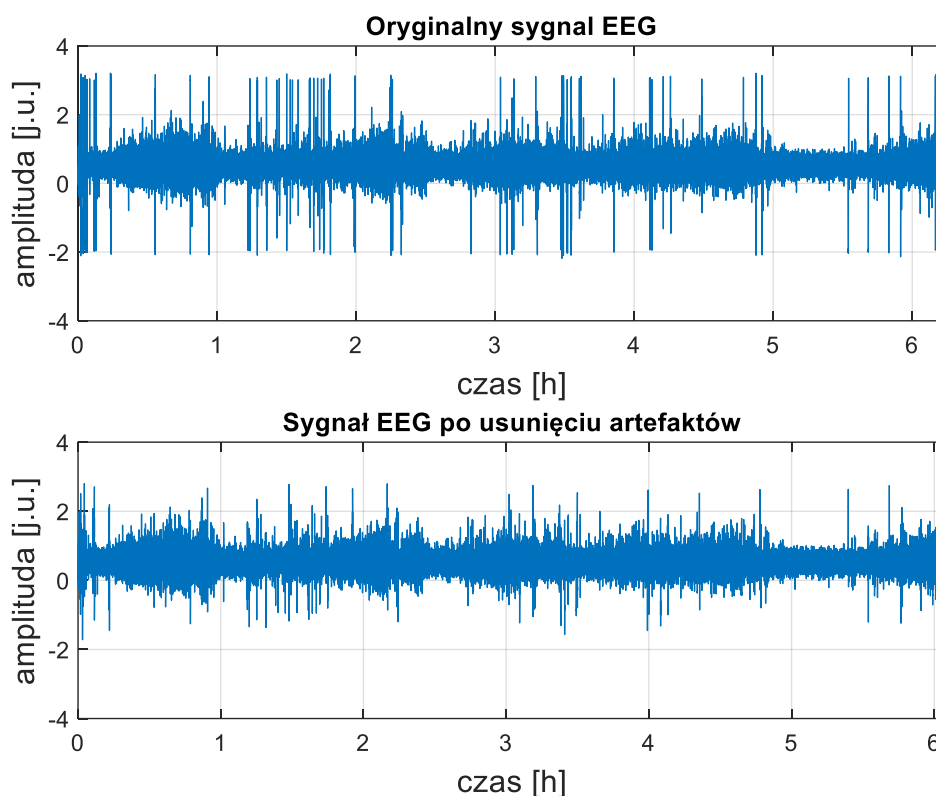


Rysunek 5.2. Całonocny sygnał EEG z lokacji C3-A2 z zaznaczonymi wysyceniami i efektami wysyczeń, oraz wartościami odstającymi.



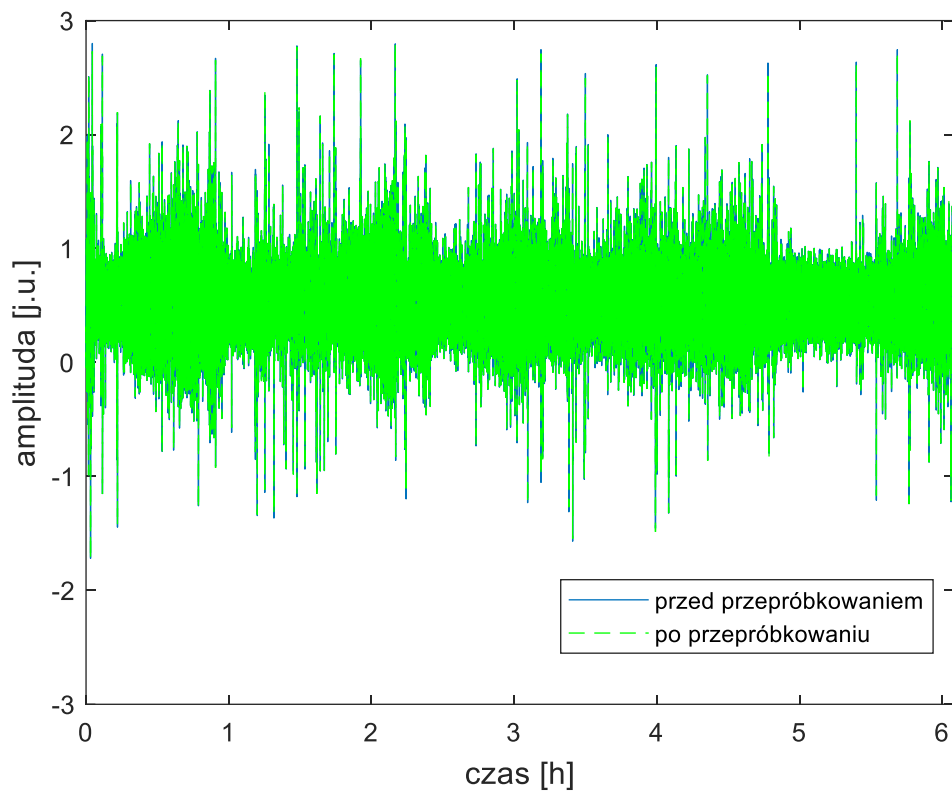
Rysunek 5.3. Fragment sygnału EEG z lokacji C3-A2 z zaznaczonymi wysyceniami, efektami wysycień oraz wartościami odstającymi.

Ponieważ zdarzenia oddechowe występujące w sygnale EEG były opisywane przez eksperta z dokładnością do 1 sekundy [317], w drugim etapie wykonywane jest usuwanie całych 1-sekundowych fragmentów, w których wykryte zostały opisane wcześniej zakłócenia. Podczas sklejania sygnału zapamiętane zostały numery 1-sekundowych fragmentów oraz ich przyporządkowanie do klasy zdarzeń oddechowych. W ten sposób zostały utworzone sygnały bez wysycień oraz próbek o nadmiernej amplitudzie, o takiej samej częstotliwości próbkowania jak w sygnale oryginalnym. Na Rysunku 5.4 został przedstawiony przykładowy cały sygnał przed i po usunięciu zakłóceń.

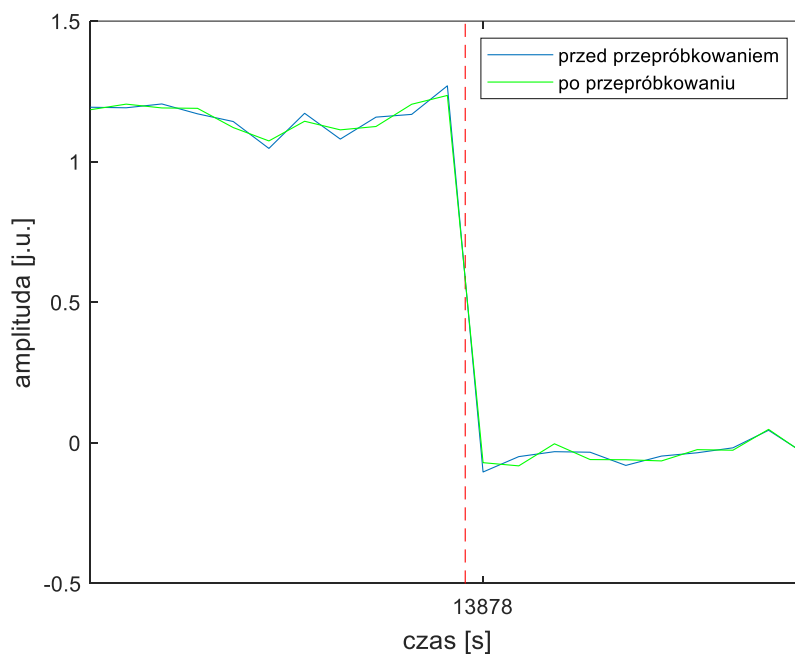


Rysunek 5.4. Całonocny sygnał EEG przed oraz usunięciu artefaktów.

Po usunięciu 1-sekundowych fragmentów z zakłóceniami: wysycień, efektów wysycień, nadmiernych amplitud oraz sklejeniu sygnału, wykonane zostało jego wygładzanie z wykorzystaniem przepróbkowania i filtracji dolnoprzepustowej. Powyższe operacje (ang. *Resampling*) zostały wykonane w celu usunięcia skoków powstałych w miejscach sklejanego, wnoszących fałszywą informację częstotliwościową, i polegają na jego interpolacji z większą częstotliwością (czyli nadpróbkowaniu), zastosowaniu filtra antyaliasingowego, a następnie powrocie do oryginalnej częstotliwości próbkowania. W tym celu zastosowano wbudowaną funkcję `resample` programu Matlab, która przy właściwym ustawieniu jej parametrów umożliwia zarówno zwiększenie jak i zmniejszenie częstotliwości próbkowania oraz dolnoprzepustową filtrację antyaliasingową. Nadpróbkowanie sygnałów zostało wykonane poprzez 10-krotne zwiększenie częstotliwości do 1280 Hz, a następnie powrót do oryginalnej częstotliwości próbkowania 128 Hz z jednoczesną filtracją antyaliasingową (64 Hz) i decymacją (10-krotne zmniejszenie liczby próbek). Na Rysunku 5.5 został przedstawiony całonocny sygnał EEG przed oraz po przepróbkowaniu, a na Rysunku 5.6 fragment z miejsca sklejenia, na którym można zaobserwować wygładzenie miejsca łączenia.



Rysunek 5.5. Całonocny sygnał EEG po usunięciu wyszczeń bez i po przepróbkowaniu.



Rysunek 5.6. Miejsce sklejenia z widocznym powstałym skokiem oraz to samo miejsce po przepróbkowaniu.

5.2.1.2 Usuwanie zakłóceń od sieci energetycznej


W pracach dotyczących detekcji bezdechu sennego na podstawie sygnału EEG usuwanie zakłóceń pochodzących od sieci energetycznej wykonywane jest poprzez filtrację pasmowoprzepustową [36] lub pośrednio filtracją dolnoprzepustową, poprzez ograniczenie analizowanego pasma częstotliwości do wartości górnej z przedziału od 35 Hz do 45 Hz [145], [12], [31], [35], [102], [144], [201], [275], [343]. Takie ograniczenie pasma skutkuje pominięciem informacji zawartych w zakresie wyższych częstotliwości fal gamma. Jednakże według Bhattacharjee i in., ograniczenie częstotliwości analizowanych epok do 40 Hz umożliwia uzyskanie dokładności klasyfikacji bezdechu sennego porównywalną do uzyskanej poprzez ekstrakcję cech wraz z częstotliwościami z zakresu 40-64 Hz [35]. Jednocześnie w efekcie badań własnych, po wykonaniu selekcji cech uzyskano wektory, w których około 20% cech różnicujących bezdech senny jest z zakresu wysokich częstotliwości między 32-64 Hz [249], [251].

Ostatecznie w niniejszej pracy zdecydowano się na porównanie dwóch metod usuwania zakłóceń od sieci energetycznej:

- 1) filtracji dolnoprzepustowej, której częstotliwość graniczną ustalono na poziomie 45 Hz,
- 2) filtracji wycinającej (ang. *notch*) z sygnału zakłóceń 50 Hz pochodzących od sieci energetycznej i usunięciu w dziedzinie częstotliwości składowej 60 Hz o nieznanym źródle, które można obserwować w całym przebiegu niektórych sygnałów EEG.

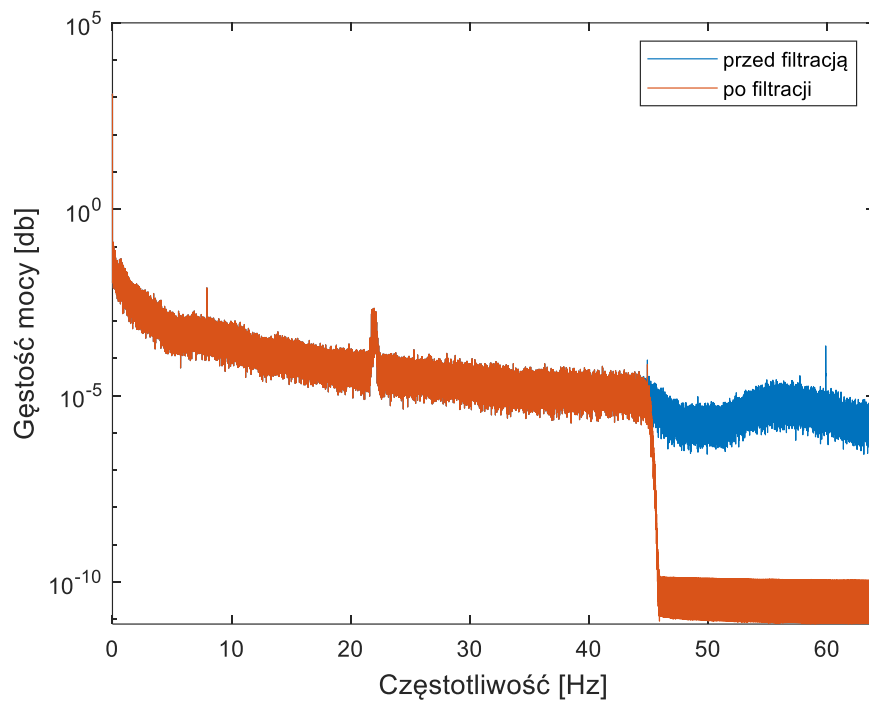
A. Filtracja dolnoprzepustowa

Filtrację wykonano poprzez zaprojektowanie filtra dolnoprzepustowego Czebyszewa typu II rzędu 17 o górnej częstotliwości granicznej 45 Hz. Wybrany typ filtra zapewnia płaską charakterystykę w paśmie przepustowym (brak zniekształceń amplitudowych) i wąskie pasmo przejściowe, którego kosztem jest występowanie tętnień w paśmie tłumionym [299]. Wybrano ten rodzaj filtra cyfrowego, ponieważ był on wykorzystywany w kilku pracach dotyczących analizy sygnału EEG [80], [233]. Odpowiedź częstotliwościowa oraz fazowa zaprojektowanego filtra została przedstawiona na Rysunku 5.7.




Rysunek 5.7. Odpowiedź częstotliwościowa i fazowa filtra dolnoprzepustowy Czebyszewa typu II.

Następnie wykonano filtrację zerofazową sygnału z wykorzystaniem zaprojektowanego filtra w programie Matlab (funkcja `filtfilt`) po to, aby uniknąć zmian fazy składowych i tym samym zmiany kształtu sygnału EEG w czasie. Przykładowa widmowa gęstość mocy przed oraz po wykonaniu filtracji jest zaprezentowana na Rysunku 5.8, na którym można zaobserwować tłumienie częstotliwości powyżej 45 Hz. Sygnał przed oraz po wykonanej filtracji został przedstawiony na Rysunku 5.9.



Rysunek 5.8. Widmowa gęstość mocy sygnału EEG przed oraz po filtracji dolnoprzepustowej




Rysunek 5.9. Sygnał EEG przed i po filtracji dolnoprzepustowej.

B. Filtracja wycinająca

Drugą zastosowaną metodą usuwania zakłóceń od sieci energetycznej była filtracja wycinająca o częstotliwości środkowej 50 Hz (dane zarejestrowano w Irlandii, a częstotliwość sieci energetycznej w EU wynosi 50 Hz). Ponadto, podczas analizy widmowej sygnałów EEG (Rysunek 5.12) zaobserwowano nagły wzrost widmowej gęstości mocy w okolicach 60 Hz nieznanego pochodzenia. Ponieważ wartość mocy dla tej częstotliwości zdecydowanie odbiega od mocy w bliskiej jej okolicy oraz występuje prawie we wszystkich zgromadzonych sygnałach EEG w całym zapisie, można zaklasyfikować ją jako zakłócenie, które należy usunąć z sygnału. W celu usunięcia zakłócenia opisanego powyżej, zastosowano filtrację sygnału w dziedzinie częstotliwości.

a) Filtracja wycinająca 50 Hz


Wpływ zakłóceń od sieci energetycznej można zaobserwować na Rysunku 5.12 jako wzrost amplitudy mocy sygnału w dziedzinie częstotliwości w okolicach wartości 50 Hz. Na Rysunku 5.10 została przedstawiona charakterystyka zaprojektowanego w programie Matlab filtra wycinającego 2 rzędu, który umożliwia tłumienie wybranej częstotliwości o szerokości tłumienia 1 Hz. Następnie wykonana została filtracja zerofazowa z wykorzystaniem współczynników zaprojektowanego filtra. Efekt filtracji w dziedzinie częstotliwości został przedstawiony na Rysunku 5.12.




Rysunek 5.10. Charakterystyka filtra wycinającego 50 Hz typu „notch”.

b) Filtracja zakłócenia o nieznanym pochodzeniu

Na podstawie analizy widmowej sygnału została określona dokładna częstotliwość będąca zakłóceniem o nieznanym źródle o wartości 59,887 Hz. Fragment spektrogramu, będący wynikiem STFT, został przedstawiony na Rysunku 5.11. W celu jej usunięcia została wykonana filtracja sygnału na próbkach w dziedzinie częstotliwości, której celem była korekcja wartości próbek o wartościach amplitudy zdecydowanie odbiegających od pozostałych w wybranym zakresie częstotliwości. Po wykonanej transformacji Fouriera zaproponowany algorytm przeszukiwał próbki w okolicy $59,887 \pm 0,002$ Hz w celu detekcji wartości większych niż wartość średnia $\pm 3 \cdot \sigma$. Jeśli takie próbki zostały zidentyfikowane, zostały zastąpione wartością średnią próbek sąsiednich. Po usunięciu wpływu zakłóceń o nieznanym źródle, wykonano przejście z dziedziny częstotliwości do dziedziny czasowej z wykorzystaniem odwrotnej transformacji Fouriera. Na Rysunku 5.12 przedstawiono widmową gęstość mocy sygnału przed oraz po usunięciu zakłóceń 50 i w pobliżu 60 Hz dla pacjenta ucdb002 (wyraźnie widoczne zakłócenie w pobliżu 60 Hz przed filtracją) oraz ucdb021 (wyraźnie widoczne zakłócenie 50 Hz przed filtracją).




Rysunek 5.11. Fragment spektrogramu z widocznym zakłóceniem w pobliżu częstotliwości 59,88 Hz.



Rysunek 5.12. Widmowa gęstość sygnału pacjenta ucdb002 oraz ucdb021 przed oraz po usunięciu zakłóceń od sieci energetycznej oraz o nieznanym pochodzeniu.

Przebieg sygnału EEG w dziedzinie czasu przed oraz po filtracji obiema metodami przedstawiony został na Rysunku 5.13.



Rysunek 5.13. Sygnał EEG przed oraz po filtracji typu wycinającej z sygnału zakłócenia 50 Hz pochodzące od sieci energetycznej i usunięciu w dziedzinie częstotliwości składowej 60 Hz o nieznanym źródle.

5.2.2 Standaryzacja sygnału

W kilku badaniach dotyczących klasyfikacji bezdechu sennego na podstawie sygnału EEG wykonywana była normalizacja sygnału, będąca ujednoczeniem amplitudy w zakresie $[-1,1]$ [249], [250], [251]. Ponadto w innych pracach, aby ujednoczyć amplitudy, zastosowano przekształcenie ilorazowe, w którym sygnał po usunięciu wartości średniej został podzielony przez wartość maksymalną sygnału [121], [275]. W Bhattacharjee i in. oprócz normalizacji amplitudy wykonano również normalizację energii, jednak nie zostało jednoznacznie określone, jaką metodę zastosowano do tego celu [35].

Zgromadzone w bazie danych sygnały EEG pochodzą z badań wykonanych w różnym czasie oraz u różnych osób, w związku z tym możliwe jest zaobserwowanie różnic w zakresie amplitudy sygnału oraz jego poziomu odniesienia. Na Rysunku 5.16 zaprezentowano kilka sygnałów pochodzących z tej samej lokacji elektrod, ale od różnych pacjentów, na których można zaobserwować różnice w zakresie amplitud sygnałów oraz różny poziom odniesienia.

Różnice w zakresach amplitud występujące w analizowanych sygnałach mają wpływ na wartości mocy sygnału. Ponieważ standaryzacja w obrębie całych zarejestrowanych sygnałów EEG umożliwia ujednoczenie w zakresie średniej mocy sygnałów, pochodzących z różnych badań oraz od różnych pacjentów, zdecydowano się na ten sposób przetwarzania wstępnego. Podstawowymi parametrami opisującymi sygnały jest ich czas trwania oraz moc średnia. Średnią dyskretną moc spróbkowanego sygnału definiuje się zgodnie ze wzorem:


$$\bar{P}_x = \frac{1}{n} \sum_{i=1}^n x_i^2. \quad [5.6]$$

W związku z tym wykonano standaryzację wszystkich zapisów całonocnych zgromadzonych w bazie danych, na których uprzednio zostało wykonane usuwanie wysyczeń i nadmiernych amplitud oraz zakłóceń od sieci energetycznej i o nieznanym pochodzeniu, zgodnie z algorytmami opisanymi w punkcie 5.2.1. W pierwszej kolejności usunięto linie trendu poprzez wykorzystanie funkcji `detrend` programu Matlab, która wykonuje odejmowanie prostej aproksymującej dane (estymowanej z wykorzystaniem metody najmniejszych kwadratów), co daje ujednoczenie poziomu odniesienia różnych sygnałów oraz wyzerowanie wartości średniej $\mu=0$. Następnie wykonano standaryzację poprzez podzielenie wszystkich wartości sygnału przez obliczone odchylenie standardowe σ z całonocnego zapisu:


$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2} \quad \text{gdzie} \quad \mu = 0 \quad [5.7]$$

$$xst = \frac{(x - \mu)}{\sigma}. \quad [5.8]$$

Sygnal EEG po usunięciu wartości odstających i wysyczeń oraz przed i po usunięciu linii trendu oraz standaryzacji został przedstawiony na Rysunku 5.14. Natomiast sygnał po usunięciu wartości odstających i wysyczeń, filtracji (dolnoprzepustowej lub wycinającej 50 Hz) oraz przed i po usunięciu linii trendu i standaryzacji został zaprezentowany na Rysunku 5.15.




Rysunek 5.14. Sygnał EEG bez wysyczeń i przed oraz po usunięciu linii trendu i standaryzacji.



Rysunek 5.15. Sygnał EEG po filtracji dolnoprzepustowej oraz po filtracji wycinającej przed oraz po usunięciu linii trendu i standaryzacji.

Natomiast trzy wybrane sygnały EEG przed oraz po standaryzacji, powodującej ujednolicenie ich średniej mocy, zaprezentowane są na rysunku 5.16.



Rysunek 5.16. Fragment sygnałów EEG z lokacji C3-A2 pochodzące od pacjentów: 2, 10, i 27 po filtracji dolnoprzepustowej przed oraz po standaryzacji.

5.2.3 Podział na epoki i klasy

5.2.3.1 Podział na epoki


Podział całonocnego sygnału EEG na epoki, będące 30-sekundowymi fragmentami sygnału, został wykonany po opisanym wcześniej przetwarzaniu wstępnym. Ponieważ w realizowanym zadaniu istotna jest identyfikacja fragmentów sygnału ze zdarzeniami oddechowymi (bezdech, spłylenie oddychania), podział na epoki został przeprowadzony w oparciu o opis zdarzeń oddechowych sygnału wykonany przez specjalistę, który jest dostępny dla każdego sygnału z bazy danych. Zdarzenia oddechowe zostały podzielone na 7 klas: bezdech oraz spłylenie oddychania: obturacyjne, centralne i mieszane, oraz normalne oddychanie. Podział sygnału na epoki został wykonany poprzez zastosowanie następujących etapów:

1) Identyfikacja zdarzenia oddechowego

W związku z tym, że zdarzenia oddechowe występujące w sygnale mają różny czas trwania (Tabela 5.1), przyjęto, że zdarzenie oddechowe to fragment trwający co najmniej 10 sekund i opisany tą samą klasą, ponieważ większość zdarzeń oddechowych ma dłuższy czas trwania (Rysunek 5.17).

Tabela 5.1. Czas trwania zdarzeń przed oraz po usuwaniu wysycień.

	Statystyka czasu trwania zdarzeń oddechowych [sekundy]			
sygnały	minimum	maximum	mediana	średnia
oryginalne	7	66	18	19,24
bez wysycień	2	41	18	18,07



Rysunek 5.17. Histogram przedstawiający przedziały czasu trwania zdarzeń oddechowych w sygnałach oryginalnych oraz po usunięciu wysycień.

2) Podział zdarzenia na epoki

30-sekundowe epoki zostały opisane na fragmentach sygnału będących zdarzeniami w taki sposób, że jeżeli czas zdarzenia był krótszy niż 30 sekund, zdarzenie oddechowe umieszczono w środku 30 sekundowego przedziału, a jego

reszta została uzupełniona przez sąsiadujące fragmenty sygnału pochodzące z normalnego oddychania. Jeśli zdarzenie oddechowe było dłuższe niż 30 sekund, wybierano z niego fragment 30 sekundowy (pierwsze 30 sekund zdarzenia), który był zapisywany jako jedna epoka.

- 3) Podział fragmentów sygnału z normalnym oddychaniem w okolicy zdarzenia oddechowego na epoki

Fragmenty normalnego oddychania pomiędzy zdarzeniami oddechowymi były dzielone równomiernie na 30-sekundowe epoki.

W każdym przypadku oprócz klasy, do której należy wyekstrahowana epoka sygnału, zapamiętano również numer sygnału oraz numerację sekund z sygnału oryginalnego, tak aby możliwe było późniejsze zidentyfikowanie epoki w całym sygnale EEG.

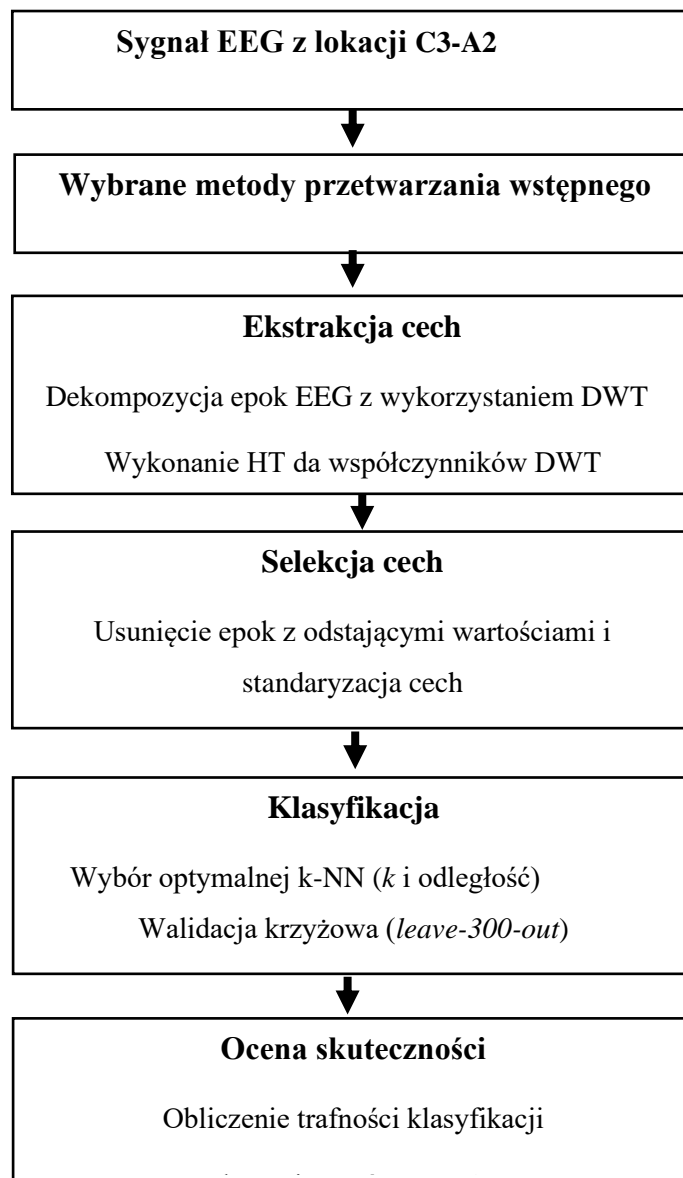
5.2.3.2 Podział na klasy

Po podziale na epoki, zostały one uporządkowane pierwotnie w 7. klasach, odpowiadających normalnemu oddychaniu i dwóm zdarzeniom oddechowym: bezdechom i spłyceniom oddychania trzech różnych typów: obturacyjny, centralny, mieszany. Najczęściej automatyczna detekcja bezdechu odbywa się w oparciu o dwie klasy: normalne oddychanie i bezdech obturacyjny [9], [11], [31], [35], [36], [121], [144], [145], [190], [275], [287], [288], czasem rozróżniane są również zdarzenia typu centralnego, co powoduje podział na 3 klasy [249], [250], [251]. Dlatego uznano, że klasyfikacja będzie odbywała się również w obszarze typu zdarzenia, tak aby sprawdzić, czy możliwe jest rozróżnienie zdarzeń obturacyjnych od centralnych oraz normalnego oddychania jedynie na podstawie sygnału EEG – co jest bezpośrednio związane z celem pracy. W związku z tym epoki ostatecznie zostały podzielone na trzy zbalansowane klasy tak, że ze wstępnie przygotowanej bazy wybrano losowo po 1373 epoki, których liczba odpowiada najmniej liczebnej klasie CSA, i w ten sposób otrzymano klasy: 1-normalne oddychanie (NORM), 2 – bezdech/spłycenie obturacyjne (OSA), 3 – bezdech/spłycenie centralne (CSA). Ilość wszystkich epok w trzech równolicznych klasach wynosi 4119.

5.2.4 Wpływ przetwarzania wstępnego na trafność klasyfikacji bezdechu sennego

Wpływ wykonanych metod przetwarzania wstępnego na klasyfikację bezdechu sennego tylko na podstawie sygnału EEG przetestowano poprzez wykonanie klasyfikacji

z wykorzystaniem tych samych, wybranych metod ekstrakcji i selekcji cech oraz klasyfikatora, które umożliwiły uzyskanie satysfakcjonujących wyników klasyfikacji bezdechu sennego typu centralnego i obturacyjnego na podstawie sygnału EEG i były zaproponowane oraz opisane we wcześniejszych badaniach [249], [250], [251]. Sekwencja przetwarzania sygnałów EEG została przedstawiona na Rysunku 5.18.



Rysunek 5.18. Schemat przedstawiający tor przetwarzania sygnału EEG w celu badania trafności klasyfikacji bezdechu sennego.

Klasyfikacja bezdechu sennego w oparciu o przedstawioną sekwencję przetwarzania została wstępnie wykonana dla sygnałów EEG bez przetwarzania wstępnego i dla tego

przypadku został określony optymalny model klasyfikatora k-NN o parametrze $k=16$ i odległości miejskiej. Następnie poszczególne etapy zostały wykonane również dla sygnałów po usunięciu wysyczeń i nadmiernych amplitud, po filtracji dolnoprzepustowej, po filtracji wycinającej i wcześniej wymienionych sygnałów po standaryzacji.

Porównanie uzyskanych wyników klasyfikacji wykonano poprzez zastosowanie dwustronnego i jednostronnego testu *t*-Studenta dla prób zależnych, co po pierwsze umożliwiło określenie, czy różnica pomiędzy uzyskanymi wynikami jest istotna statystycznie, a po drugie, czy któreś podejście jest lepsze. Początkowo dla każdego analizowanego przypadku wykonano test dwustronny, i jeśli jego wynik wskazywał na różnicę pomiędzy średnimi z populacji, wykonano test jednostronny, dzięki czemu możliwe jest określenie, która ze średnich jest większa. Wyniki klasyfikacji oraz wykonanych testów statystycznych (wraz z wartością prawdopodobieństwa testowego p_t oraz interpretacją testów) przedstawiono w Tabeli 5.2. Testy statystyczne wykonano dla następujących wyników klasyfikacji:

a) Sygnał po usunięciu wysyczeń

Na podstawie wykonanych testów można stwierdzić, że pomiędzy średnimi istnieje statystyczna różnica i średnia trafność klasyfikacji dla sygnału po usunięciu zakłóceń jest mniejsza niż średnia trafność klasyfikacji dla sygnału oryginalnego bez przetwarzania wstępnego.

b) Sygnał bez wysyczeń i po filtracji dolnoprzepustowej

Na podstawie wykonanych testów można stwierdzić, że pomiędzy średnimi istnieje statystyczna różnica i średnia trafność klasyfikacji dla sygnałów po usuwaniu zakłóceń jest większa dla sygnałów po filtracji dolnoprzepustowej niż przed.

c) Sygnał bez wysyczeń i po filtracji wycinającej

Na podstawie wykonanych testów można stwierdzić brak istotnych statystycznie różnic pomiędzy średnią trafnością klasyfikacji dla sygnałów po usunięciu wysyczeń, bez oraz po usuwaniu zakłóceń harmonicznym z wykorzystaniem filtracji wycinającej.

d) Sygnał bez wysyczeń po standaryzacji i filtracji dolnoprzepustowej

Wykonane testy umożliwiają stwierdzenie, że istnieją statystyczne różnice pomiędzy średnią po standaryzacji i filtracji dolnoprzepustowej zarówno w porównaniu do

sygnałów jedynie po filtracji jak i sygnału oryginalnego bez przetwarzania wstępnego. Wynik testu jednostronnego wskazuje, że wartość średnia klasyfikacji dla sygnału bez wysycień i po standaryzacji i filtracji dolnoprzepustowej ograniczającej pasmo przetwarzanych częstotliwości, jest większa od średnich z sygnałów bez przetwarzania oraz po filtracji.

e) Sygnał bez wysycień po standaryzacji i filtracji wycinającej

Testy statystyczne umożliwiają stwierdzenie, że istnieje statystyczna różnica pomiędzy średnimi i średnia dla sygnałów po standaryzacji i filtracji wycinającej jest większa niż dla sygnałów jedynie po filtracji usuwającej zakłócenia harmoniczną. Natomiast nie ma statystycznej różnicy pomiędzy analizowanym przypadkiem a średnią dla sygnałów bez przetwarzania wstępnego.

f) Sygnał bez wysycień i po standaryzacji

Na podstawie wykonanych testów statystycznych można stwierdzić, że istnieje statystyczna różnica pomiędzy średnimi z sygnałów bez wysycień przed i po standaryzacji. Średnia dla sygnałów po standaryzacji jest większa niż przed. Natomiast nie ma istotnie statystycznie różnicy pomiędzy sygnałem bez przetwarzania wstępnego i po wykonaniu usuwania artefaktów.

Tabela 5.2. Podsumowanie wpływu zastosowania wybranych metod przetwarzania wstępnego na trafność klasyfikacji i odchylenie standardowe bezdechu sennego (trafność klasyfikacji bez przetwarzania wstępnego – tylko z podziałem na epoki i klasy – wyniosła 52,36%).

Trafność klasyfikacji bezdechu sennego na podstawie sygnału EEG w obrębie trzech klas: NORM, OSA i CSA									
Zastosowane etapy analizy									
usuwanie wysyczeń	+	+	+	+	+	+	+	+	+
usuwanie nadmiernych amplitud	+	+	+	+	+	+	+	+	+
resampling	+	+	+	+	+	+	+	+	+
filtracja dolnoprzepustowa									
filtracja wycinająca 50 Hz									
standaryzacja w obrębie sygnału									
podział na 30-sekundowe epoki	+	+	+	+	+	+	+	+	+
podział na klasy: NORM, OSA, CSA	+	+	+	+	+	+	+	+	+
ekstrakcja cech: DWT i HT	+	+	+	+	+	+	+	+	+
selekcja cech	+	+	+	+	+	+	+	+	+
klasyfikacja: k-najbliższych sąsiadów (k=1:25)	+	+	+	+	+	+	+	+	+
wyniki klasyfikacji	16								
ilość sąsiadów k	miejska								
odległość									
ilość cech	53	50	51	49	51	52	49	52	49
Trafność ± odchylenie standardowe [%]	52,36±2,95	50,23±3,03	51,39±2,91	50,52±2,88	54,43±2,85	52,37±3,09	52,24±2,40	52,37±3,09	52,24±2,40
	a,e,g,i	a,b,c,h	b,d	c,f	d,e	f,g	h,i	f,g	h,i

Test dwustronny:

- a. istotna statystycznie różnica ($p_t = 1,06 \times 10^{-6}$)
- b. istotna statystycznie różnica ($p_t = 4,9 \times 10^{-3}$)
większa niż przed ($p_t = 0,0025$)
- c. brak istotnej statystycznie różnicy ($p_t = 0,49$)
- d. istotna statystycznie różnica ($p_t = 2,31 \times 10^{-11}$)
- e. istotna statystycznie różnica ($p_t = 8,14 \times 10^{-6}$)
niż oryginalnego ($p_t = 4,07 \times 10^{-6}$)
- f. istotna statystycznie różnica ($p_t = 2,22 \times 10^{-4}$)
- g. brak istotnej statystycznie różnicy ($p_t = 0,65$)
- h. istotna statystycznie różnica ($p_t = 1,51 \times 10^{-7}$)
- i. brak istotnej statystycznie różnicy ($p_t = 0,33$)

Test jednostronny:

- średnia oryginalnego jest większa niż bez wysycień ($p_t = 5,29 \times 10^{-7}$)
- średnia po filtracji dolnoprzepustowej jest —
- średnia po standaryzacji jest większa niż przed ($p_t = 1,16 \times 10^{-11}$)
- średnia po standaryzacji i filtracji jest większa —
- średnia po standaryzacji jest większa niż przed ($p_t = 1,11 \times 10^{-4}$)
-
- średnia po standaryzacji jest większa niż przed ($p_t = 7,56 \times 10^{-8}$)
-

Pomimo, że występowanie wysycień w sygnale można zauważyć poprzez analizę wzrokową, bezpośrednio po ich usunięciu nie zaobserwowano poprawy trafności klasyfikacji bezdechu sennego. Mimo to, usuwanie wysycień wydaje się uzasadnione, ponieważ są to zakłócenia, które ewidentnie nie reprezentują elektrycznej aktywności mózgu i w związku z tym mogą mieć wpływ na interpretację cech sygnału EEG. Ponadto zaobserwowano, że 98,16% wykrytych wysycień pochodzi z próbek sygnałów zaklasyfikowanych do klasy NORM (normalnego oddychania), a 1,84% do klasy OSA (obturacyjny bezdech i spłycenia oddychania). Nie zaobserwowano wysycień w klasie CSA. Co więcej zaobserwowano pozytywny wpływ filtracji dolnoprzepustowej, ograniczającej pasmo częstotliwości do 45 Hz na średnią trafność klasyfikacji. Standaryzacja sygnałów natomiast umożliwia ujednoczenie średniej mocy wszystkich wykorzystanych całonocnych zakresów i nie wpływa negatywnie na trafność klasyfikacji bezdechu sennego, a poprawia jego średnią wartość. W związku z tym w dalszej części pracy usuwanie wysycień oraz nadmiernych amplitud, filtracja dolnoprzepustowa i standaryzacja sygnału zostaną zastosowane jako etapy przetwarzania wstępnego wszystkich sygnałów EEG.

5.3 Podsumowanie

Podstawowym celem przetwarzania wstępnego sygnałów jest usunięcie zakłóceń znajdujących się w sygnałach tak, aby zminimalizować ich wpływ na wynik wykonywanych operacji, oraz przygotowanie sygnałów do dalszej analizy. Istnieje wiele metod przetwarzania wstępnego, możliwych do zastosowania w analizie sygnału EEG. W tej pracy, po inspekcji zgromadzonych sygnałów, zdecydowano się na przeanalizowanie następujących metod przetwarzania wstępnego sygnału EEG:

- usunięcie wysycień z sygnału EEG,
- standaryzacja sygnału,
- usunięcie zakłóceń harmonicznych poprzez filtrację dolnoprzepustową oraz filtrację wycinającą ,
- podział sygnału na 30-sekundowe epoki,
- zaliczenie epok do trzech klas.

Po każdym etapie, w którym zastosowano wybraną metodę przetwarzania wstępnego, przeprowadzono badanie o wpływie na trafność klasyfikacji bezdechu sennego. W tym celu zastosowano sekwencję przetwarzania sygnału EEG zaprezentowaną na Rysunku 5.18. Efektem badań było otrzymanie średnich trafności klasyfikacji dla sygnału oryginalnego oraz po wykonaniu wybranych metod przetwarzania wstępnego, które zaprezentowano w Tabeli 5.1. Aby określić wpływ poszczególnych metod na klasyfikację, porównano uzyskane wartości średniej trafności klasyfikacji poprzez zastosowanie testów statystycznych. Optymalny model klasyfikatora k-NN dla sygnałów EEG z lokacji C3-A2 bez przetwarzania wstępnego określony został dla metryki miejskiej oraz ilości najbliższych sąsiadów $k=16$, dla którego średnia trafność klasyfikacji wynosi 52,36%. Natomiast dla sygnałów EEG po wykonanym przetworzeniu wstępnym średnia trafność dla wybranych parametrów klasyfikatora k-NN, optymalnych dla sygnału oryginalnego, wyniosła 50,23 % dla sygnałów po usunięciu wysycień, 52,24% po dodatkowo wykonanej standaryzacji sygnałów oraz dla sygnałów po filtracji, której celem było usunięcie zakłóceń harmonicznych: 51,39% po filtracji dolnoprzepustowej i 50,52% po filtracji wycinającej oraz 54,43% i 52,37% kolejno dla dwóch metod filtracji po wykonanej standaryzacji.

Wyniki testów statystycznych wykazały, że średnia trafność klasyfikacji dla sygnału oryginalnego jest wyższa od trafności klasyfikacji po usuwaniu wysycień oraz nadmiernych amplitud. Najlepszą klasyfikację 54,43% uzyskano dla sygnałów po usuwaniu wysycień, filtracji dolnoprzepustowej i standaryzacji. Dla tego przypadku wyniki jednostronnego testu statystycznego umożliwiają stwierdzenie, że średnia trafność klasyfikacji dla sygnałów po tym przetworzeniu wstępnym jest wyższa niż dla sygnałów oryginalnych bez przetwarzania. W związku z powyższym zdecydowano się na zastosowanie następujących metod przetwarzania wstępnego: usuwania wysycień oraz nadmiernych amplitud, filtracji dolnoprzepustowej i standaryzacji w dalszej analizie sygnału EEG.

Rozdział 6

Ekstrakcja cech z epok sygnału EEG

Analiza przebiegów czasowych jest często wykonywana z wykorzystaniem ekstrakcji cech wybranego sygnału. Ekstrakcja cech jest etapem analizy sygnałów, który umożliwia uzyskanie zbioru liczb zawierających istotne informacje o sygnale lub jego cechy charakterystyczne, dzięki czemu możliwe jest łatwiejsze interpretowanie sygnału [23]. Jednocześnie celem ekstrakcji cech jest uzyskanie wektora o mniejszym wymiarze niż analizowany sygnał, zawierającego jednak wystarczającą ilość informacji reprezentujących ten sygnał, co umożliwia jego łatwiejszą ocenę i interpretację.

6.1 Metody ekstrakcji cech sygnału EEG stosowane w badaniach nad snem

Istnieje wiele technik stosowanych do analizy sygnału EEG w celu wyodrębnienia jego cech. W niniejszej pracy skoncentrowano się jedynie na analizie metod stosowanych w badaniach nad snem.

Zazwyczaj do opisu fragmentu sygnału EEG wykorzystywanych jest wiele cech, które są komplementarne i całościowo opisują sygnał [216]. W związku z tym, że sygnał EEG można rozłożyć na składowe związane z falami mózgowymi, bardzo często jego analizę rozpoczyna się od dekompozycji na sygnały składowe, a następnie poszukuje się cech skalarnych opisujących uzyskane komponenty. W ogólności techniki ekstrakcji cech można podzielić ze względu na dziedzinę, w której prezentowane są składowe sygnały: czasu, czasu-częstotliwości, czasu-skali i częstotliwości. Dlatego stosowane metody ekstrakcji cech sygnału EEG przedstawiono poniżej z uwzględnieniem dwóch podstawowych etapów: dekompozycji na sygnały składowe oraz obliczania skalarnych cech uzyskanych komponentów.

6.1.1 Metody dekompozycji na sygnały składowe

6.1.1.1 Dekompozycja w dziedzinie czasu

A. Filtracja pasmowoprzepustowa


Filtracja sygnału EEG jest jedną z podstawowych i często stosowanych metod jego analizy [2], [12], [31], [36], [124], [322]. Cechuje się ona prostotą i dużą szybkością, a w efekcie umożliwia zaobserwowanie pewnych wzorców w sygnale EEG. Wprawdzie wykonywana jest narzędziami analizującymi zawartość częstotliwościową sygnału, uzyskane składowe prezentowane są jednak jako przebiegi czasowe. Jej zastosowanie pozwala na ograniczenie wpływu zakłóceń w celu ułatwienia jego interpretacji (Rozdział 5), ale filtracja umożliwia również dekompozycję sygnału na jego składowe o wybranych zakresach częstotliwości, tak aby możliwe było wyodrębnienie różnych rodzajów aktywności sygnału EEG, zazwyczaj związanej z zakresami fal mózgowych [109]. W tabeli poniżej przedstawiono pasma częstotliwości stosowane w literaturze przy dekompozycji epok EEG wykonywanej z wykorzystaniem filtracji pasmowoprzepustowej. W pracach tych wykorzystano jedynie zakresy charakterystyczne dla różnych fal mózgowych.

Tabela 6.1. Zakresy poziomów dekompozycji epok EEG z wykorzystaniem filtracji stosowane w literaturze (wartości w [Hz]).

Fale mózgowie	Almuhammadi i in. 2015 [12]	Bayatfar i in. 2019 [31]	Bhattacharje i in. 2019 [36]	Vimala i in. 2019 [322]	Aboalayon i in. 2014 [2]
Zakresy poziomów dekompozycji z wykorzystaniem filtracji [Hz]					
<i>delta</i>	0-4	0,5-4	0,25-4	2-6	0-4
<i>theta</i>	4-8	4-8	4-8	3-10	4-8
<i>alfa</i>	8-12	8-12	8-12	13-23	8-12
<i>sigma</i>	brak	12-16	12-16	brak	brak
<i>beta</i>	12-30	16-25	16-40	29-41	12-30
<i>gamma</i>	30-125	25-35 35-45	brak	35-78	30-50

W literaturze bardzo często wykorzystywane były filtry pasmowoprzepustowe o nieskończonej odpowiedzi impulsowej (ang. *Infinite Impulse Response (IIR)*) typu Butterwortha [2], [12], [59], [124], [322], ale również inne rodzaje filtrów, w tym o skończonej odpowiedzi impulsowej (ang. *Finite Impulse Response (FIR)*) z oknem Hamminga [31]. Filtracja liniowa umożliwia dekompozycję z wybraną szerokością pasma przepustowego zgodną z definicją pasm fal mózgowych, która nie ulega modyfikacji ze względu na analizowany sygnał [35]. Zastosowanie filtracji umożliwia zaobserwowanie zmian lokalnych, związanych z aktywnością fal mózgowych w zdecydowanie lepszy sposób, niż podczas obserwacji pełnego pasma sygnału [36].

Również połączenie filtrów dolno- i górnoprzepustowego umożliwia zaprojektowanie filtru pasmowoprzepustowego, który tłumí jednocześnie częstotliwości niższe od dolnej i wyższe od górnej częstotliwości granicznej. Ponadto możliwe jest również wykonanie dekompozycji sygnału z wykorzystaniem jego filtracji w dziedzinie częstotliwości na wybraną ilość składowych zgodnie z odpowiadającym im zakresem częstotliwości [9], [29], [39], [42], [91], [92], [105], [121], [124], [179]. Wykonanie dekompozycji sygnału na składowe z wykorzystaniem filtracji pasmowoprzepustowej można też wykonać jako filtrację kaskadową zgodnie z algorytmem Mallata, poprzez zastosowanie filtrów dolno- i górnoprzepustowych, z których pierwszy umożliwia uzyskanie aproksymacji, a drugi przebiegu szczegółowego [149].




Rysunek 6.1. Efekt dekompozycji sygnału EEG z wykorzystaniem filtracji pasmowoprzepustowej [Źródło: [322]].

B. Dekompozycja empiryczna

Dekompozycja empiryczna (ang. *Empirical Mode Decomposition* (EMD)) jest metodą wykorzystywaną do analizy sygnałów nieliniowych i niestacjonarnych, w tym do analizy sygnału EEG. Nie wymaga ona wstępnej wiedzy odnośnie sygnału, w związku z tym może być również wykorzystywana do dekompozycji sygnałów o nieznanym cechach. EMD jest algorytmem iteracyjnym, który rozkłada sygnał na skończoną liczbę nieparametrycznych funkcji wrodzonych (ang. *Intrinsic Mode Functions* (IMF)), posiadających dwie własności: liczba ekstremów jest taka sama jak liczba przejść przez zero (± 1), a ich obwiednie są symetryczne w stosunku do linii zerowej. Z wykorzystaniem EMD sygnał $x(t)$ jest reprezentowany jako:

$$x(t) = \sum_{i=1}^p u_i(t) + r_p(t), \quad [6.1]$$

gdzie p oznacza ilość IMF i zależy od złożoności sygnału, $u_i(t)$ to IMF, a $r_p(t)$ to rezydual. Procedura iteracyjna jest automatycznie przerywana, kiedy u_i lub r_p mają małe wartości lub gdy r_p jest funkcją monotoniczną. Efektem EMD jest dekompozycja sygnału oryginalnego na IMF, których ilość zależy od informacji zawartych w sygnale i dlatego może być różna dla różnych sygnałów [117], [248], [287]. Na Rysunku 6.2 poniżej przedstawiono sześć przykładowych funkcji wrodzonych (od 3 do 8 z 18 IMF) uzyskanych po wykonaniu EMD dla epoki sygnału EEG reprezentującej fazę snu REM [248].



Rysunek 6.2. Funkcje wrodzone (od 3 do 8 z 18 IMF) będące wynikiem EMD dla epoki sygnału EEG reprezentującej fazę snu REM [Źródło: [248]].

C. Dekompozycja wariacyjna


Metoda dekompozycji wariacyjnej (ang. *Variational Mode Decomposition* (VMD)) pozwala na dekompozycję w dziedzinie czasu sygnału niestacjonarnego, w tym również sygnału EEG [35], [151], na dyskretną liczbę funkcji wrodzonych (IMF) o specyficznych właściwościach częstotliwościowych: ograniczonym paśmie częstotliwości, zlokalizowanym wokół adaptacyjnej częstotliwości środkowej, bezpośrednio związanej ze zmienną aktywnością mózgu, obliczoną poprzez rozwiązanie ograniczonego problemu wariacyjnego (znalezienie ekstremum funkcjonału całkowego). Proces dekompozycji epoki sygnału polega na znalezieniu optymalnej liczby IMF oraz ich częstotliwości środkowych. Charakterystyka uzyskanych IMF jest następująca: sygnały sinusoidalne zmodulowane w amplitudzie i częstotliwości, posiadają dodatnie i powoli zmieniające się obwiednie, każdy posiada chwilową częstotliwość, zmieniającą się powoli i skoncentrowaną wokół częstotliwości środkowej. Metoda VMD jest rozwinięciem metody EMD, dzięki której oprócz opisu sygnału za pomocą IMF uzyskuje się również oszacowanie szerokość ich pasma, określającego zakres częstotliwości charakterystyczny dla każdej kolejnej IMF [90]. Metoda VMD, po dekompozycji na składowe IMF, kontynuowana może być w następujących krokach: dla każdej IMF obliczany jest sygnał analityczny przy użyciu transformacji Hilberta (ang. *Hilbert Transform* (HT)) w celu uzyskania jednostronnego spektrum częstotliwości, widmo częstotliwości IMF jest przesuwane poprzez jego przemnożenie przez funkcję eksponentjalną z obliczoną częstotliwością środkową, następnie szerokość pasma jest szacowana na podstawie rozmycia gaussowskiego sygnału po dekompozycji. Aby wykonać dekompozycję sygnału na funkcje wrodzone $u_i(t)$ oraz uzyskać informację o ich częstotliwościach środkowych $\omega_i(t)$ należy rozwiązać ograniczony problem wariacyjny opisany równaniem:

$$\min_{\{u_i\}, \{\omega_i\}} \left\{ \sum_i \left\| \frac{d}{dt} \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_i(t) \right] e^{-j\omega_i t} \right\|_2^2 \right\}, \quad [6.2]$$

$$\text{przy ograniczeniu: } \sum_i u_i(t) = x(t), \quad [6.3]$$

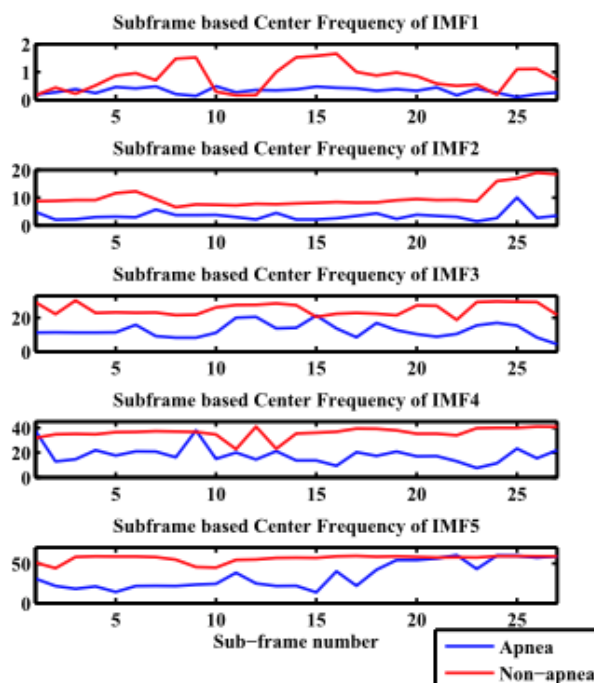
gdzie $\{u_i\} := \{u_1, \dots, u_p\}$ i $\{\omega_i\} := \{\omega_1, \dots, \omega_p\}$ są skrótowym zapisem dla wszystkich zestawów IMF i częstotliwości środkowych, $\delta(t)$ to delta Diraca, $x(t)$ to sygnał oryginalny,

a p jest liczbą poziomów dekompozycji [90], [151]. Efekt VMD można zilustrować za pomocą uzyskanych widm gęstości mocy poszczególnych IMF (Rysunek 6.3).



Rysunek 6.3. Widmowa gęstość mocy dla kolejnych IMF uzyskanych z dekompozycji fragmentu sygnału EEG [Źródło: [35]].

Ponadto, po HT, możliwe jest określenie zmian częstotliwości środkowej dla sygnałów po dekompozycji i analiza jej wartości w poszczególnych epokach sygnału.



Rysunek 6.4. Wykresy zmian środkowej wartości częstotliwości (oś y) IMF5 dla wybranej epoki sygnału EEG normalnego (czerwony) i w trakcie bezdechu (niebieski) [Źródło: [35]].

6.1.1.2 Dekompozycja w dziedzinach czas-częstotliwość i czas-skala

A. Transformacja Hilberta-Huanga

Transformacja Hilberta-Huanga (ang. *Hilbert Huang Transform (HHT)*) jest metodą stosowaną do analizy sygnałów nieliniowych i niestacjonarnych, w tym również sygnału EEG [144], [145], [329]. Metoda ta realizowana jest w dwóch etapach: w pierwszym dekompozycja sygnału jest wykonywana poprzez zastosowanie metody EMD, a w drugim stosowana jest transformacja Hilberta w celu wyznaczenia chwilowych wartości częstotliwości i amplitudy uzyskanych funkcji wrodzonych. Wykonanie całej procedury umożliwia dekompozycję sygnału oraz uzyskanie interpretacji sygnału w dziedzinie czas-częstotliwość. Algorytm HHT można traktować jako rozszerzenie EMD opisanej wyżej, przez zastosowanie transformacji Hilberta [117], [146]. TH jest przekształceniem w dziedzinie czasu, który zwraca sygnał analityczny $X(t)$:

$$X(t) = x(t) + jh(t) = A(t)e^{j\phi t}, \quad [6.4]$$

gdzie $x(t)$ jest rzeczywistym sygnałem, h jego HT, A chwilową wartością amplitudy, a ϕ jest chwilową wartością fazy uzyskanego sygnału X . Z sygnału analitycznego można następnie wykorzystać chwilową wartością amplitudy oraz obliczyć chwilową częstotliwość [117], [146], [249], [250]:

$$f(t) = \frac{1}{2\pi} \frac{d\phi}{dt}. \quad [6.5]$$

Możliwe jest również obliczenie ważonej częstotliwości zgodnie z poniższym wzorem, zaproponowanym przez autora tej pracy w artykule [249]:


$$f_w(t) = \frac{A(t)}{\frac{1}{n} \sum_{t=1}^n A(t)} f(t), \quad [6.6]$$

gdzie n to liczba analizowanych próbek. Częstotliwość ważona lepiej oddaje jej znaczenie w danym fragmencie analizowanego sygnału.

B. Krótkoczasowa transformacja Fouriera

Krótkoczasowa transformacja Fouriera (ang. *Short Time Fourier Transform (STFT)*) jest odmianą tradycyjnej FT w dziedzinie czas-częstotliwość. STFT umożliwia uzyskanie informacji o chwilowej amplitudzie (gęstości mocy) i fazie sygnału zlokalizowanych

w czasie i częstotliwości. Metoda ta polega na zastosowaniu FT w połączeniu z ruchomym oknem o stałej szerokości, przesuwanym po sygnale. Efektem STFT jest spektrogram, dzięki czemu możliwa jest analiza lokalna sygnału i obserwowanie, jakie przedziały częstotliwości dominują w określonych przedziałach czasowych. Wybór szerokości okna ma wpływ na rozdzielczość transformaty: wąskie okno daje lepszą dynamikę w dziedzinie czasu, lecz gorszą rozdzielczość częstotliwościową, natomiast szerokie okno zwiększa rozdzielczość w dziedzinie częstotliwości, ale rozmywa informację w czasie. W związku z tym STFT może być traktowana jako wstęp do dalszej analizy lokalnej sygnału [159], [179], [216].



Rysunek 6.5. Przykładowy spektrogram uzyskany w wyniku STFT dla sygnału EEG z epoki bezdechu i normalnego oddychania [Źródło: [159]].

C. Transformacja falkowa

Transformacja falkowa umożliwia analizę sygnałów niestacjonarnych w dziedzinie czas-skala (jej wyniki można interpretować również w dziedzinie czas-częstotliwość). Najczęściej wykorzystywanym jej rodzajem w analizie sygnału EEG jest dyskretna transformacja falkowa (DWT) [8]. Zasada działania DWT jest podobna do dyskretnej transformacji Fouriera (ang. *Discrete Fourier Transform* (DFT)), jednak zamiast globalnych sinusoid wykorzystuje ona lokalne falki jako funkcje bazowe. Pojedyncza falka jest reprezentowana jako:

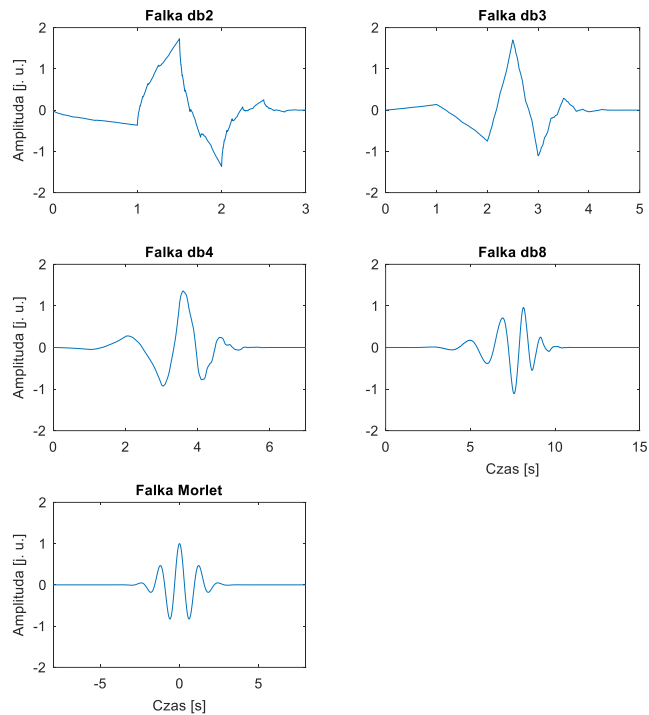
$$\psi_{b,c}(t) = \frac{1}{\sqrt{2^b}} \psi\left(\frac{t - c \cdot 2^b}{2^b}\right), \quad [6.7]$$

gdzie ψ oznacza falkę podstawową, zlokalizowaną w czasie (parametr przesunięcia c) o określonej skali (parametr b) powiązanej z częstotliwością, mającą ograniczony czas


trwania, średnią 0 i energię znormalizowaną do 1. Do dekompozycji sygnału z wykorzystaniem DWT konieczne jest wybranie odpowiedniego typu falki, który powinien być podobny do analizowanego sygnału [93]. Sygnały EEG bardzo często są rozkładane na składowe za pomocą falek typu Daubechies rzędu 2, 3, 4 lub 8 [93], [189], [248], [249], [281], [287], [289], [298], oraz typu Morlet [190]. Kształt tych wybranych typów falek można zaobserwować na Rysunku 6.6. Przy pomocy DWT oryginalny sygnał jest rozkładany przez filtry dolnoprzepustowy i górnoprzepustowy, wykorzystujące falki o odpowiedniej skali, czego efektem jest uzyskanie składowych sygnału wraz ze współczynnikami aproksymacji a i szczegółowymi d , odpowiednimi dla wybranej ilości poziomów dekompozycji. Następnie składnik aproksymujący (tj. o niższej częstotliwości) może być dalej przetwarzany w analogiczny sposób. Ostatecznie sygnał $x(t)$ zostaje rozłożony na ważoną sumę falek ψ i funkcji skalujących φ [93], [248], [249], a uzyskany zbiór współczynników szczegółowych $D_B = \{d_{b,c}\}$ i aproksymujących $A_B = \{a_{b,c}\}$ jest dalej przetwarzany [248], [249]:

$$x(t) = \sum_{b=1}^B \sum_c d_{b,c} \psi_{b,c}(t) + \sum_c a_{b,c} \varphi_{b,c}(t). \quad [6.8]$$

Przykładowa dekompozycja sygnału z wykorzystaniem DWT na współczynniki szczegółowe i aproksymujące została przedstawiona na Rysunku 6.7 [248].




Rysunek 6.6. Falki typu Daubeschies (db2, 3, 4, 8) oraz typu Morlet często wykorzystywane w analizie sygnału EEG z wykorzystaniem DWT.



Rysunek 6.7. Współczynniki szczegółowe i aproksymujące będące wynikiem DWT (falka *db3*) wykonanej dla epoki EEG reprezentującej sen REM [Źródło: [248]].

D. Algorytm poszukiwania dopasowującego

Algorytm poszukiwania dopasowującego (ang. *Matching Pursuit Algorithm* (MP)) jest metodą dekompozycji sygnału, opierającą się na zbiorach funkcji bazowych (zwykle modulowanych sinusoid), zwanych słownikami. Jest on uogólnieniem FT i DWT. Zaletą tej metody jest duży rozmiar słownika, który, w przeciwieństwie do FT (wykorzystującej sinusoidy) oraz DWT (wykorzystującej falki), nie jest ograniczony do jednej formy funkcji bazowych. MP umożliwia czasowo-częstotliwościową dekompozycję sygnału poprzez poszukiwanie kombinacji funkcji zgromadzonych w słowniku najlepiej dopasowanej do analizowanego sygnału. Parametryzacja znalezionej dopasowania w czasie, częstotliwości, amplitudzie i energii powoduje całkowity rozkład sygnału. Rozwiązania wykorzystujące algorytm MP umożliwiają uzyskanie wysokiej rozdzielczości czasowo-częstotliwościowej i w związku z tym dokładny opis zdarzeń przejściowych oraz odpowiedniej charakterystyki niestacjonarności. Potencjalnym błędem związanym z zastosowaniem tej metody jest błąd systematyczny spowodowany strukturą wykorzystywanego słownika oraz wysoki koszt obliczeniowy, który może ograniczyć jej zastosowanie w aplikacjach analizy sygnału w czasie rzeczywistym [216].



Rysunek 6.8. Analiza fragmentu sygnału z napadu epileptycznego z sygnału EEG wykonana z zastosowaniem metody MP [Źródło: [114]].


6.1.1.3 Dekompozycja w dziedzinie częstotliwości

A. Transformacja Fouriera

Transformacja Fouriera (ang. *Fourier Transform* (FT)) jest klasyczną i szeroko opisaną w literaturze metodą przekształcającą sygnał z dziedziny czasu do dziedziny częstotliwości. Takie przekształcenie umożliwia następnie podział sygnału na składowe z uwzględnieniem wybranego zakresu częstotliwości. Najczęściej stosowanym rodzajem FT jest dyskretna transformacja Fouriera, a szczególnie szybka transformacja Fouriera (ang. *Fast Fourier Transform* (FFT)). W literaturze znane są prace, w których wykorzystywane było FFT do przekształcenia sygnału EEG z dziedziny czasu do dziedziny częstotliwości [29], [39], [42], [91], [92], [105], [193].

B. Widmowa gęstość mocy

Widmowa gęstość mocy (ang. *Power Spectral Density* (PSD)) opisuje rozkład gęstości mocy sygnału w dziedzinie częstotliwości. W przeanalizowanych artykułach do obliczania PSD używano metody Welch [28], [88], [248] oraz wielookienkowej metody Thomsona (ang. *Multitaper Spectral Analysis*) [39], [82] z wykorzystaniem szybkiej transformaty Fouriera. Częściej wykorzystywana metoda Welch polega na uśrednianiu widma sygnału z kolejnych, nakładających się przedziałów czasowych, zwracając oszacowanie zwane periodogramem. W celu wykonania dekompozycji sygnału EEG na jego składowe z wykorzystaniem PSD, zakres częstotliwościowy był dzielony na wybraną ilość pasm zgodnie z zakresem częstotliwości fal mózgowych (*delta*, *theta*, *alfa*, *beta*, *gamma*) [4], [5], [48], [71], [88], [248], [255], [257], [271], [280].



Rysunek 6.9. PSD obliczone z 10 s sygnału EEG przed bezdechem (linia przerywana) oraz 10 s po bezdechu (linia ciągła) [Źródło: [88]].

6.1.2 Metody obliczania skalarnych cech sygnałów

Cechy skalarne mogą być wyznaczone dla sygnałów oryginalnych, w tym epok EEG, ale jeżeli zastosowano wcześniej jedną lub kilka metod dekompozycji sygnału, obliczane są dla każdej z uzyskanych składowych.

6.1.2.1 Cechy energetyczne

A. Energia sygnału

Energię E sygnału dyskretnego oblicza się jako sumę kwadratów próbek w wybranym jego fragmencie:

$$E = \sum_{i=1}^n x_i^2, \quad [6.9]$$

gdzie n jest całkowitą liczbą próbek i x_i to wartości kolejnych próbek w epoce sygnału [322]. Dodatkowo, obliczając energię składowych po dekompozycji częstotliwościowej, można określić stosunek między energią całkowitą sygnału, a energią w wybranym zakresie częstotliwości [9], [12], [102], [322].

B. Średnia moc sygnału

Moc sygnału definiuje się jako jego energię odniesioną do jednostki czasu. Z wykorzystaniem opisanej wyżej metody PSD możliwe jest uzyskanie mocy sygnału w określonym paśmie częstotliwości. Ponadto, jeśli obliczoną energię sygnału podzieli się przez czas (lub liczbę próbek), uzyskuje się średnią moc [144], [288]:

$$\bar{P}_x = \frac{1}{n} \sum_{i=1}^n x_i^2 = \frac{1}{n} E. \quad [6.10]$$

C. Parametry Hjortha

Parametry Hjortha umożliwiają scharakteryzowanie dowolnego sygnału i jego pochodnych w dziedzinie czasu, w ten sposób dostarczając informacji o dynamicznych cechach sygnału w czasie. Aby obliczyć parametry Hjortha, konieczne jest obliczenie wariancji analizowanego fragmentu sygnału x_i :

$$\sigma^2 = \text{var}(x_i) \quad [6.11]$$

oraz wariancję jego pierwszej i drugiej pochodnej, oznaczone kolejno jako:

$$\sigma_1^2 = \text{var} \left(\frac{d}{dt} x_i \right) \quad [6.12]$$

$$\text{i } \sigma_2^2 = \text{var} \left(\frac{d^2}{dt^2} x_i \right). \quad [6.13]$$

W efekcie opisywane miary są określone poniższymi wzorami [102], [216], [291]:

- aktywność (ang. *activity* H_A), która jest miarą średniej mocy składowej zmiennej:

$$H_A = \sigma^2, \quad [6.14]$$

- mobilność (ang. *mobility* H_M) będącą oszacowaniem średniej częstotliwości:

$$H_M = \frac{\sigma_1^2}{\sigma^2}, \quad [6.15]$$

- złożoność (ang. *complexity* H_C), która jest oszacowaniem przedziału częstotliwości lub szerokości pasma:

$$H_C = \sqrt{\left(\frac{\sigma_2^2}{\sigma_1^2} \right)^2 - \left(\frac{\sigma_1^2}{\sigma^2} \right)^2}. \quad [6.16]$$

6.1.2.2 Cechy spektralne – harmoniczne parametry Hjortha

Harmoniczne parametry Hjortha są wersją parametrów Hjortha obliczanych w dziedzinie częstotliwości $x(f)$ i pozwalają na analizę konkretnego pasma w widmie sygnału. Ich obliczenie wymaga oszacowania widma mocy epoki sygnału oznaczonego jako P_x . Są one zdefiniowane zgodnie z poniższymi wzorami [102], [291], [306]:

- częstotliwość środkowa f_c

$$f_c = \frac{\sum_{f_L}^{f_H} f P_x(x(f))}{\sum_{f_L}^{f_H} P_x(x(f))}, \quad [6.17]$$

- szerokość pasma f_σ

$$f_\sigma = \left(\frac{\sum_{f_L}^{f_H} (x(f) - f_c) P_x(x(f))}{\sum_{f_L}^{f_H} P_x(x(f))} \right)^{1/2}, \quad [6.18]$$

- wartość widmowej gęstości mocy dla częstotliwości środkowej f_c

$$S_{f_c} = P_x(f_c). \quad [6.19]$$

6.1.2.3 Cechy kształtu i cechy statystyczne

Często używaną cechą kształtu sygnału jest jego amplituda czy ilość przejść przez zero [31]. Cechy statystyczne, nazywane również statystykami chwilowymi, są najprostszymi cechami, które można wyprowadzić jako cechy szeregów czasowych, w tym sygnału EEG, w związku z tym są bardzo często stosowane. Miary statystyczne umożliwiają niezależne traktowanie każdej epoki sygnału i pominięcie korelacji pomiędzy jego poszczególnymi fragmentami [216]. Do najczęściej wyznaczanych cech statystycznych należą: średnia (arytmetyczna i geometryczna) [9], mediana, mody, odchylenie standardowe, wariancja [12], [287], [322], skrośność i kurtoza [216].

6.1.2.4 Cechy dynamiki nieliniowej

A. Entropia sygnału

Entropia sygnału jest miarą uporządkowania, która umożliwia określenie ilościowe (w sensie statystycznym) niepewności lub losowości zmian w sygnale EEG lub jego fragmencie, które w przybliżeniu jest równoważne ilości informacji zawartych w sygnale. Miary entropii w dziedzinie czasu obliczane są przez algorytmy dzielące sygnał na segmenty, które następnie są porównywane pod względem podobieństwa albo bezpośrednio, albo po pewnego rodzaju transformacji sygnału [204]. W literaturze dotyczącej analizy sygnału EEG wykorzystywana była entropia Shannona *EnSh*, którą można wyznaczyć z zastosowaniem poniższego wzoru:

$$EnSh = -\sum_{i=1}^n x_i^2 \log_2(x_i^2), \quad [6.20]$$

[322], [36], [291]. Cecha ta znajduje zastosowanie podczas analizy sygnału EEG w anesteziologii, gdzie zaobserwowano, że sygnał staje się bardziej przewidywalny lub powtarzalny podczas zasypiania. Ponadto stosuje się ją również do klasyfikacji stanów chorobowych, np. schizofrenii [204]

B. Wymiar fraktalny

Wymiar fraktalny (ang. *Fractal Dimension* (FD)) jest miarą złożoności sygnału. Podstawą FD jest idea kwantyfikacji wymiarów fraktali (geometrii, które są podobne

w różnych skalach). Fraktal jest obiektem matematycznym o wymiarze innym niż całkowity, a ich koncepcję można rozszerzyć do analizy szeregów czasowych. W przypadku jednokanałowego sygnału EEG jego wymiar fraktalny może wynosić od 1 do 2. FD umożliwiają detekcję stanów nieustalonych w sygnale EEG, ponieważ można je zastosować do krótkich fragmentów danych [216].

C. Beztrendowa analiza fluktuacji (DFA)

Metodę beztrendowej analizy fluktuacji (ang. *Detrended Fluctuation Analysis* (DFA)) opracowano w celu analizy trendu zmienności danych w pewnej sekwencji zdarzeń, którymi mogą być również epoki sygnału. Matematycznie DFA jest realizowana jako scałkowana suma serii próbek sygnału:

$$y_i = \sum_{i=1}^n \{x_i - \mu\}, \quad [6.21]$$

gdzie \bar{x} jest średnią ze wszystkich fragmentów sygnału x_i . Następnie uzyskany sygnał y_i , po odjęciu wartości średniej, dzieli się na okna czasowe o długości m i dla każdego fragmentu wykonywane jest dopasowanie linii prostej metodą najmniejszych kwadratów, tak aby określić linię trendu. Kolejno zostaje wykonane usunięcie linii trendu poprzez odjęcie lokalnego trendu w każdym fragmencie danych i zmienność średniej kwadratowej wynikowej serii danych wynosi:

$$F_m = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_m)^2}, \quad [6.22]$$

gdzie y_m to lokalny trend, a F_m umożliwia wyznaczenie zależności fluktuacji od rozmiaru okna. Następnie proces ten jest powtarzany dla różnej długości okien i za każdym razem sprawdzana jest wartość współczynnika skalowania. Analiza uzyskanego wykresu umożliwia ocenę zmienności poziomu fluktuacji w czasie [52], [102], [343].

6.2 Wybór metod i efekty ekstrakcji cech

Wśród badań związanych z analizą sygnału EEG w celu detekcji bezdechu sennego często stosowane są metody ekstrakcji cech przebiegające w dwóch etapach, które opisano w poprzednim podrozdziale: dekompozycji na sygnały składowe (wykonana jedno- lub dwuetapowo np. EMD+HT=HHT) i następnie obliczenia skalarnych cech tych składowych. Pozwala to na utworzenie wektora cech opisującego każdą analizowaną epokę

sygnału. W opublikowanych pracach wielokrotnie wykorzystywano filtrację pasmowoprzepustową [9], [12], [31], [121], [124], [145], [275], [322] do dekompozycji sygnału na jego składowe powiązane z pasmem częstotliwości fal mózgowych. Innymi stosowanymi metodami były transformacja Hilberta-Huanga [144], [322], [329], krótkoczasowa transformacja Fouriera [159], dekompozycja wariacyjna [35], dekompozycja empiryczna [287], [329] dyskretna transformacja falkowa [181], [189], [190] oraz jej połączenie z transformata Hilberta [249], [250], [251]. Wśród stosowanych metod obliczania skalarnych cech sygnałów można wyróżnić: cechy statystyczne [9], [12], [31], [287], [322], parametry Hjortha [31], energię sygnału [9], [12], [322] oraz stosunek energii lub mocy sygnałów w wybranym paśmie częstotliwości do całego sygnału [144], [145], [276], [288], ilość przejść przez zero [31], entropię [121], [190], [275], [322], [329] i beztrendową analizę fluktuacji [343].

Najlepsze wyniki detekcji bezdechu sennego (około 90%) uzyskano w pracach, w których jako metody ekstrakcji cech zastosowano połączenie: filtracji pasmowoprzepustowej z obliczeniem: energii oraz wariancji [11], i dodatkowo entropii [124], [322], albo wybranych cech statystycznych: skośności, kurtozy, pierwiastka sumy kwadratów, pierwiastka średniej i współczynnika szczytu oraz ilości przejść przez zero i parametrów Hjortha [31], [124]; transformaty Hilberta-Huanga i proporcji sum sygnałów po dekompozycji do całkowitej sumy sygnału [144], [145]; dekompozycji wariacyjnej oraz entropii, wariancji logarytmicznej i wartości średniej [35]; transformacji falkowej połączonej z wykonaniem dekompozycji empirycznej jedynie dla zakresu fal *delta* i obliczenie cech statystycznych: wariancji i średniej bezwzględnej zmienność IMF [287] oraz krótkoczasowej transformacji Fouriera [159].

Po przeprowadzeniu powyższej analizy, w niniejszej pracy zdecydowano się na przetestowanie metod ekstrakcji cech wykonywanej w dwóch etapach: dekompozycji na sygnały składowe (jedno- i dwuetapowej), a następnie obliczania cech uzyskanych komponentów. Wśród jednoetapowych metod dekompozycji zdecydowano się na wykorzystanie:

- filtracji pasmowoprzepustowej (ang. *Bandpass Filtering* (BPF)),
- dyskretnej transformacji falkowej (DWT),
- dekompozycji empirycznej (EMD),
- dekompozycji wariacyjnej (VMD).

Popularną, dwuetapową metodą dekompozycji sygnału, często wykorzystywaną w analizie sygnału EEG, jest transformacja Hilberta-Huanga (HHT). Wzorując się na HHT zaproponowano dwie dodatkowe, dwuetapowe dekompozycje sygnału z zastosowaniem transformacji Hilberta oraz DWT i VMD. W związku z tym w pracy przetestowane zostały trzy takie metody dekompozycji:

- transformacja Hilberta-Huanga (EMD+HT=HHT),
- dyskretna transformacja falkowa z transformacją Hilberta (DWT+HT),
- dekompozycji wariacyjnej z transformacją Hilberta (VMD+HT).

Wektor cech zostanie utworzony poprzez obliczenie następujących 9 cech skalarnych komponentów sygnału. Opis wykorzystywanych cech skalarnych został, zaprezentowanych w Tabeli 6.2. W związku z tym, że w analizowanych sygnałach EEG nie obserwuje się znacznych wartości składowej stałej, zrezygnowano z obliczania ich wartości średniej. Co więcej, pomimo, że w literaturze często wykorzystywaną cechą była energia sygnału, w tym przypadku nie będzie ona obliczana, ponieważ dla analizowanych sygnałów EEG z pomijalnie małą składową stałą, energia jest prawie równa wariancji.

Tabela 6.2. Opis wybranych cech skalarnych.

Typ cech	Cecha	Opis
cechy statystyczne	S_k	skośność
	K	kurtoza
	Me	mediana
parametry Hjortha	H_A	aktywność (wariancja)
	$\frac{H_A}{\sum_{i=1}^n H_A}$	proporcja wariancji do sumy wariancji wszystkich sygnałów
	H_M	mobilność
	H_C	złożoność
entropia Shanona	$EnSh$	entropia Shanona
cecha kształtu	A	maksymalna amplituda

6.2.1 Dekompozycja sygnału EEG


Dekompozycja została wykonana dla wszystkich danych EEG dostępnych w bazie (opisanej w Rozdziale 4, po wykonaniu następujących etapów przetwarzania wstępnego (opisanych w Rozdziale 5): usunięciu wysycień oraz nadmiernych amplitud, filtracji dolnoprzepustowej, standaryzacji oraz podziale na 30-sekundowe epoki i uporządkowanie ich w trzech klasach: 1 – normalne oddychanie (NORM), 2 – bezdech/spływanie obturacyjne (OSA), 3 – bezdech/spływanie centralne (CSA). Efekty ekstrakcji cech przedstawione na prezentowanych rysunkach zostały wykonane na epoce bezdechu obturacyjnego z klasy OSA, pochodzącej od pacjenta z numerem 7 (plik ucddb007).

6.2.1.1 Filtracja pasmowoprzepustowa

Rozkład sygnału z wykorzystaniem filtracji pasmowoprzepustowej został wykonany poprzez zastosowanie filtrów dolno- i górnoprzepustowych. W związku z tym, że w literaturze wykorzystywane były zarówno filtry IIR [2], [12], [59], [322] jak i FIR [31], zdecydowano się na porównanie tych dwóch rodzajów filtracji. Dlatego filtracja sygnału została wykonana na dwa sposoby z zastosowaniem filtrów:


- a) Czebyszewa typu II o optymalnym rzędzie (FIR) oraz
- b) Butterwortha o rzędzie ograniczonym do 10 (IIR).

Oba filtry mają płaskie pasma przepustowe (dzięki czemu nie powodują modyfikacji amplitudy w tym zakresie), jednak filtr Butterwortha charakteryzuje się szerszym pasmem przejściowym niż filtr Czebyszewa typu II (który był już wcześniej wykorzystywany przy filtracji sygnału wykonywanej podczas przetwarzania wstępnego). Odpowiedzi częstotliwościowe i fazowe obu filtrów dla pierwszego poziomu dekompozycji zostały przedstawione na Rysunku 6.10. Aby ograniczyć szerokość pasma przejściowego, zdecydowano na zastosowanie minimalnego, optymalnego rzędu dla filtra Czebyszewa typu II. Natomiast optymalny rząd dla filtra Butterwortha był wielokrotnie większy niż dla drugiego rodzaju filtracji, dlatego w tym przypadku zdecydowano się na wykorzystanie rzędu filtru ograniczonego do 10.

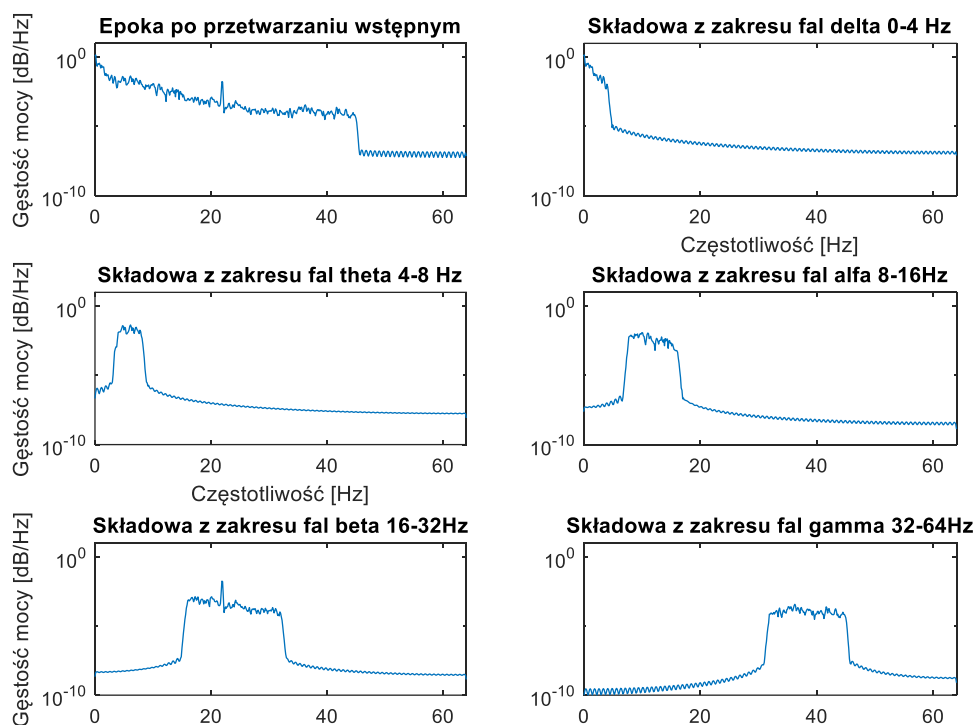


Rysunek 6.10. Odpowiedź częstotliwościowa i fazowa filtrów górnoprzepustowych Czebyszewa typu II i Butterwortha o częstotliwości odcięcia 32 Hz.


Dekompozycja została zaprojektowana zgodnie z drzewem Mallata poprzez kaskadowe połączenie stałofazowych filtrów dolno- i górnoprzepustowych, uwzględniające zakresy częstotliwości charakterystyczne dla kolejnych pięciu fal mózgowych: *gamma* (32-64 Hz), *beta* (16-32 Hz), *alfa* (8-16 Hz), *theta* (4-8 Hz) i *delta* (0-4 Hz). W ten sposób przedziały częstotliwości składowych sygnałów są takie same, jak po wykonaniu 4-poziomowej metody DWT (6.2.1.2). Dekompozycja przykładowej epoki sygnału EEG z wykorzystaniem filtracji pasmowoprzepustowej dla dwóch rodzajów filtracji oraz widmowa gęstość mocy składowych po dekompozycji została przedstawiona na rysunkach poniżej.



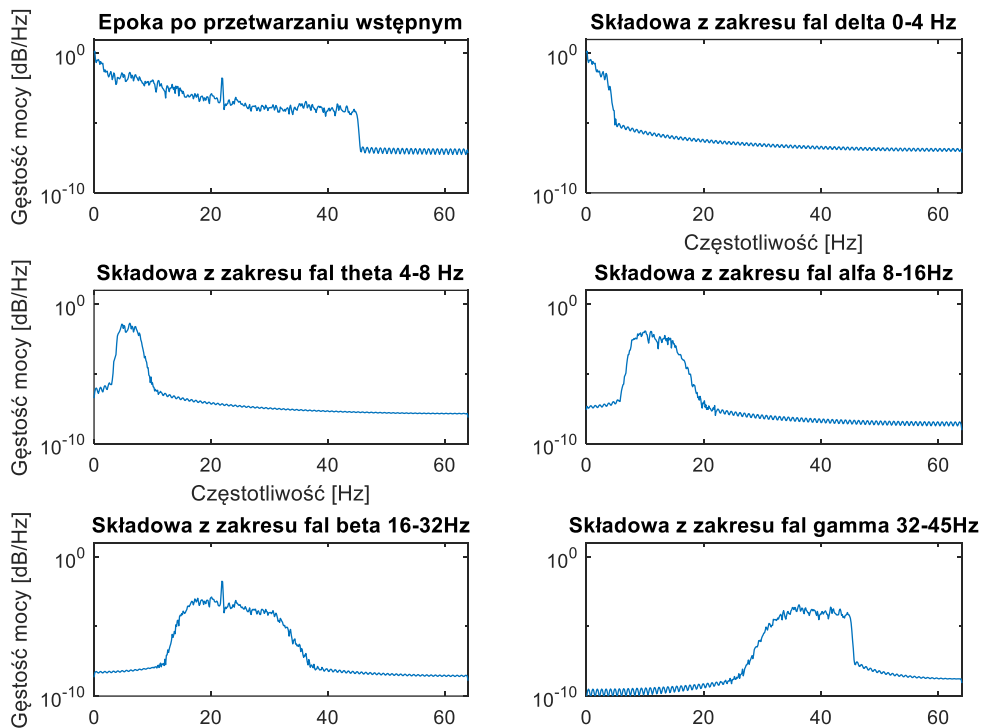
Rysunek 6.11. Dekompozycja sygnału EEG z wykorzystaniem BPF filtrami Czebyszewa typu II dla epoki EEG z klasy OSA.



Rysunek 6.12. Widmowa gęstość mocy 5 sygnałów uzyskanych po BPF filtrami Czebyszewa typu II dla epoki EEG z klasy OSA.



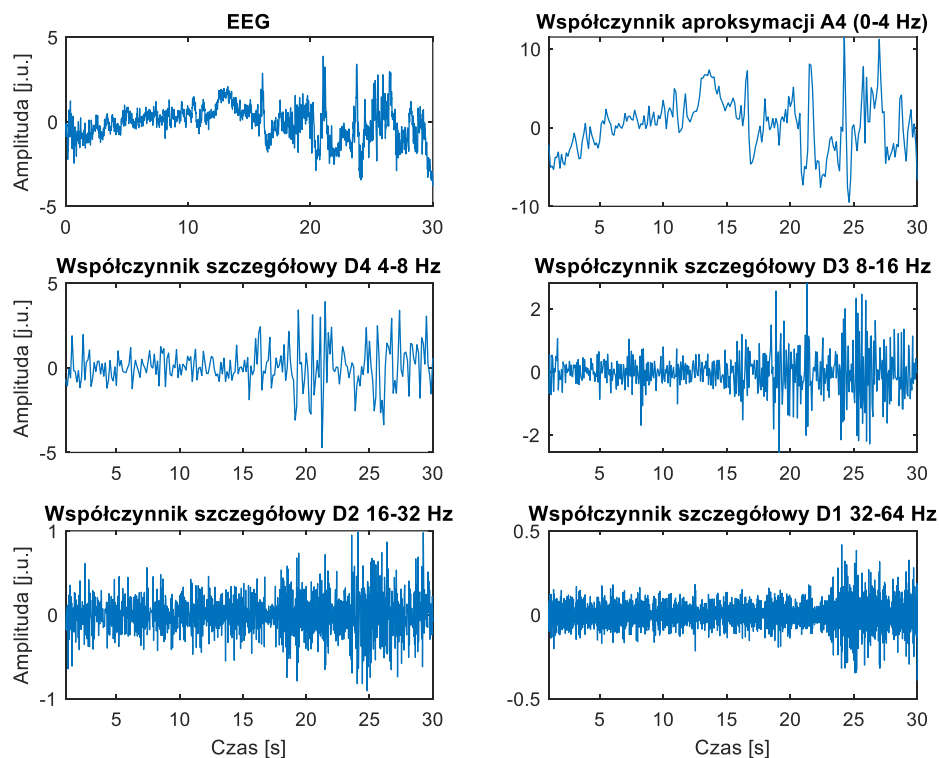
Rysunek 6.13. Dekompozycja sygnału EEG z wykorzystaniem BPF filtrami Butterwortha dla epoki EEG z klasy OSA.



Rysunek 6.14. Widmowa gęstość mocy 5 sygnałów uzyskanych po BPF filtrami Butterwortha dla epoki EEG z klasy OSA.

6.2.1.2 Dyskretna transformacja falkowa

Dekompozycja sygnału z wykorzystaniem DWT wykonana w została w oparciu o falkę Daubechies 3 (*db3*), której kształt jest podobny do fragmentów sygnału EEG i jest często wykorzystywana w jego analizie [188]. Biorąc pod uwagę częstotliwość próbkowania (128 Hz) oraz zakresy częstotliwości fal mózgowych, ilość poziomów dekompozycji została określona na 4. Sygnał rozkładany jest na zbiór współczynników szczegółowych $D_j = \{d_{j,k}\}$ i aproksymujących $A_J = \{a_{J,k}\}$, czego rezultatem jest uzyskanie następujących komponentów: D_1 (32-64 Hz), D_2 (16-32 Hz), D_3 (8-16 Hz), D_4 (4-8 Hz) i A_4 (0-4 Hz), odpowiadających zakresom częstotliwości fal mózgowych odpowiednio: *gamma*, *beta*, *alfa*, *theta* i *delta*. Na Rysunku 6.15 przedstawione są współczynniki szczegółowe i aproksymujące będące wynikiem DWT wykonanej dla epoki EEG reprezentującej klasę OSA.

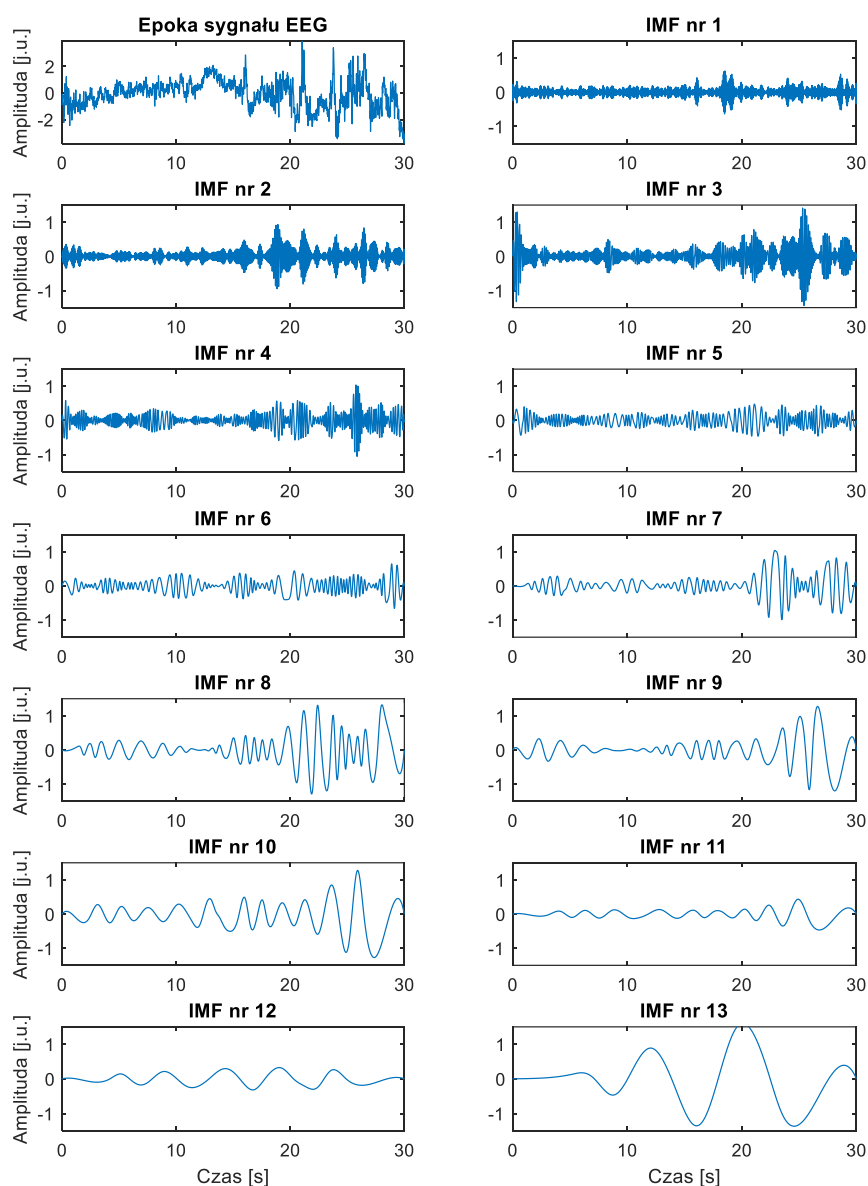


Rysunek 6.15. Współczynniki szczegółowe i aproksymujące będące wynikiem DWT (falka *db3*) wykonanej dla epoki EEG reprezentującej klasę OSA.

6.2.1.3 Dekompozycja empiryczna

Zastosowanie dekompozycji empirycznej umożliwiło rozkład każdej epoki sygnału na skończoną liczbę IMF, których liczba może się różnić w zależności od złożoności analizowanego fragmentu i wyniosła od 13 do 23 IMF.


W związku z tym, aby ujednolicić ilość uzyskanych cech dla wszystkich epok, w dalszej analizie będzie wykorzystywane pierwsze 13 IMF. Przykładowy rozkład sygnału na funkcje wrodzone, uzyskane po wykonaniu EMD dla epoki sygnału reprezentującej klasę OSA przedstawiono na Rysunku 6.16.




Rysunek 6.16. Wybrane funkcje wewnętrzne będące wynikiem dekompozycji metodą EMD dla epoki z klasy OSA sygnału EEG.

6.2.1.4 Dekompozycji wariacyjna

Dekompozycja wariacyjna (VMD) umożliwia rozkład sygnału na skończoną, zwykle niewielką liczbę wąskopasmowych IMF. Każda epoka sygnału została rozłożona na 5 IMF. Częstotliwości środkowe poszczególnych sygnałów z tego samego poziomu dekompozycji różnią się między sobą w pewnym zakresie. Zaobserwowano jednak, że wartości te w pewnym stopniu związane są z zakresami częstotliwości fal mózgowych. Przykładowy rozkład sygnału na 5 IMF, uzyskanych po wykonaniu VMD przedstawiono na Rysunku 6.17. Aby zaobserwować częstotliwościowy charakter IMF, obliczona została też ich widmowa gęstość mocy (Rysunek 6.18).



Rysunek 6.17. Sygnał EEG i funkcje wewnętrzne (IMF1 do IMF5) będące wynikiem VMD dla epoki z klasy OSA sygnału EEG.

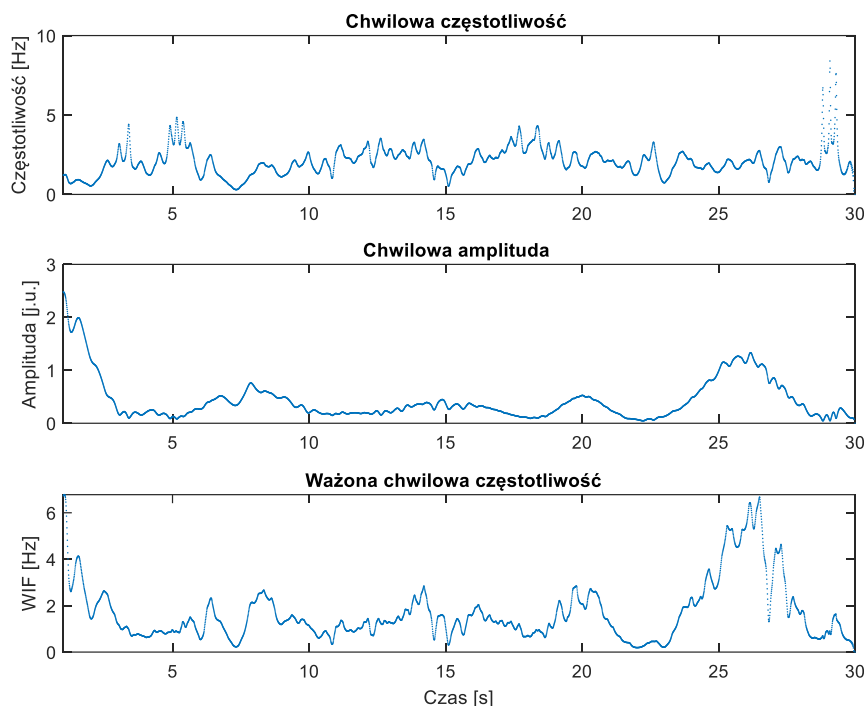


Rysunek 6.18. Widmowa gęstość mocy dla IMF, z poprzedniego rysunku, uzyskanych z dekompozycji fragmentu sygnału EEG.

6.2.1.5 Dwuetapowe metody dekompozycji

A. Transformacja Hilberta-Huanga


W związku z tym, że pierwszym etapem realizacji HHT jest wykonanie EMD, HT obliczono dla IMF będących wynikiem opisanej wcześniej dekompozycji. Ich liczbę ujednociono do 13 dla wszystkich epok. Dla każdej IMF (od 1 do 13) obliczono trzy sygnały: chwilową amplitudę $A(t)$, częstotliwość $f(t)$ oraz ważoną częstotliwość. Przykładowe chwilowe amplitudy, częstotliwości oraz ważne częstotliwości (tylko próbki odpowiadające nieujemnym chwilowym częstotliwościom) uzyskane poprzez obliczenie HT dla IMF6 epoki sygnału EEG są prezentowane na rysunku poniżej.



Rysunek 6.19. Chwilowe amplitudy, częstotliwości oraz ważne częstotliwości będące efektem HT dla IMF6 po dekompozycji metodą EMD dla epoki z klasy OSA sygnału EEG.

B. Dyskretna transformacja falkowa z transformacją Hilberta

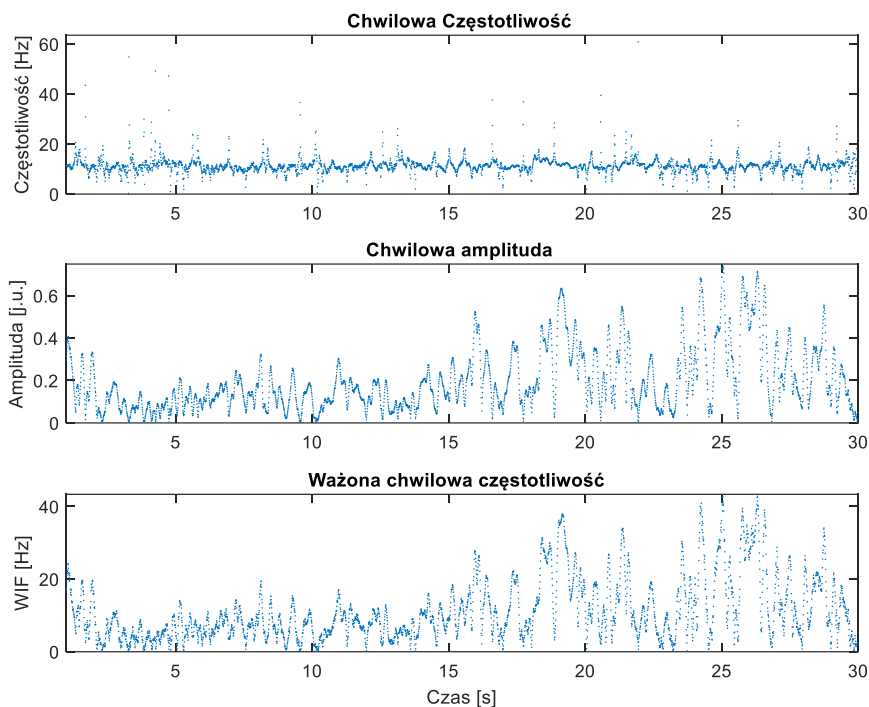
Połączenie DWT i HT jako dwuetapowej metody dekompozycji sygnału EEG zostało początkowo zaproponowane w artykułach [48] i [249]. DWT umożliwia rozkład sygnału na pasma częstotliwości, powiązane z zakresami fal mózgowych, a HT – tak jak w metodzie HHT – umożliwia obserwację chwilowych wartości amplitudy i częstotliwości. Przykładowe chwilowe amplitudy, częstotliwości oraz ważne częstotliwości (tylko próbki odpowiadające nieujemnym chwilowym częstotliwością mieszczącym się w zakresie 8-16 Hz) uzyskane dla szczegółowego współczynnika DWT (D3) zostały przedstawione na rysunku poniżej.



Rysunek 6.20. Chwilowe amplitudy, częstotliwości oraz ważne częstotliwości będące efektem HT dla współczynników D_3 (8-16 Hz).

C. Dekompozycja wariacyjna z transformacją Hilberta

Dwuetapową dekompozycję sygnału z wykorzystaniem VMD i HT wykonano analogicznie jak we wcześniej opisanych dwuetapowych metodach. Dla każdej z pięciu IMF uzyskanych po wykonaniu VMD obliczono transformatę Hilberta. Przykładowe chwilowe amplitudy, częstotliwości oraz ważne częstotliwości (tylko próbki odpowiadające nieujemnym chwilowym częstotliwości) uzyskane poprzez obliczenie HT dla IMF2 epoki sygnału EEG są prezentowane na rysunku poniżej.



Rysunek 6.21. Chwilowe amplitudy, częstotliwości oraz ważne częstotliwości będące efektem HT dla IMF2 po dekompozycji metodą VMD dla epoki z klasy OAH sygnału EEG.

6.2.2 Obliczenie cech skalarnych

Dla sygnałów po dekompozycji uzyskanych poprzez zastosowanie każdej z powyżej opisanych metod (jednoetapowych: BPF, DWT, EMD, VMD i dwuetapowych: EMD+HT=HHT, DWT+HT, VMD+HT) został obliczony dokładnie ten sam zestaw cech skalarnych. Następnie ze wszystkich uzyskanych cech utworzono wektor cech, który charakteryzuje każdą analizowaną epokę EEG. Ponieważ podczas dekompozycji sygnał, w zależności od zastosowanej metody, został rozłożony na różną ilość komponentów, ilość uzyskanych cech dla różnych metod nie jest taka sama. Wielkość wektora cech w zależności od metody dekompozycji została zaprezentowana w Tabeli 6.3.

Tabela 6.3. Wielkość wektora cech w zależności od metody dekompozycji.

Metoda	Ilość sygnałów po dekompozycji		Rozmiar wektora cech
	I etap	II etap	
BPF	5	brak	$5 \cdot 9 = 45$
DWT	5	brak	$5 \cdot 9 = 45$
EMD	13	brak	$13 \cdot 9 = 117$
VMD	5	brak	$5 \cdot 9 = 45$
HHT=EMD+HT	13	3	$13 \cdot 3 \cdot 9 = 351$
DWT+HT	5	3	$5 \cdot 3 \cdot 9 = 135$
VMD+HT	5	3	$5 \cdot 3 \cdot 9 = 135$

6.3 Podsumowanie

Celem ekstrakcji było uzyskanie cech reprezentujących epoki sygnału EEG, zawierające informacje, które je charakteryzują. W tej pracy zdecydowano się na przetestowanie kilku metod dekompozycji sygnałów (jedno- i dwuetapowych), które umożliwiły jego rozkład na składowe. Spośród jednoetapowych metod wykonano:

- filtrację pasmowoprzepustową (BPF),
- dyskretną transformację falkową (DWT),
- dekompozycję empiryczną (EMD),
- dekompozycję wariacyjną (VMD),

natomiast wśród dwuetapowych metod dekompozycji wykorzystano:

- transformację Hilberta-Huanga (EMD+HT=HHT),
- dyskretną transformację falkową z transformacją Hilberta (DWT+HT),
- dekompozycję wariacyjną z transformacją Hilberta (VMD+HT).

Następnie dla każdego z uzyskanych komponentów obliczono zestaw 9 cech skalarnych. Efektem jest opracowanie wektorów cech dla każdej wybranej metody

dekompozycji, tak aby możliwe było dalsze ich przetwarzanie związane z selekcją cech oraz klasyfikacją epok sygnału EEG. Uzyskane wektory różnią się ilością cech (od 45 do 351 cech), co związane jest z różnicą w ilości komponentów uzyskanych poprzez dekompozycję sygnału z zastosowaniem różnych metod.

Po zakończeniu badań nad ekstrakcją i selekcją cech opisanych w niniejszym rozdziale, opublikowany został artykuł Tarana i Bajaja [308], w którym do ekstrakcji cech zastosowano adaptacyjną dekompozycję Hermite'a (ang. *Adaptive Hermite Decomposition* (AHD)) oraz algorytm genetyczny i metodę Fishera podczas selekcji, uzyskano bardzo wysoką dokładność klasyfikacji binarnej (99,53%) i w związku z tym te metody nie zostały przetestowane w niniejszej pracy, jednak warto mieć je na uwadze podczas kontynuacji badań w przyszłości.

Rozdział 7

Selekcja cech charakteryzujących epoki EEG

7.1 Metody selekcji cech

Selekcja cech jest etapem, którego celem jest uzyskanie optymalnego (lub suboptymalnego) podzbioru wyekstrahowanych cech, który umożliwiłby rozróżnienie epok sygnału EEG pomiędzy poszczególnymi klasami oraz określenie związków pomiędzy cechami oraz klasą. Cechy uzyskane po etapie ekstrakcji można podzielić na dwa rodzaje: istotne i nieistotne ze względu na charakter informacyjny, dzięki któremu umożliwiają określenie przynależności epoki do klasy. Cechy nieistotne nie niosą różnicujących informacji, ale przyczyniają się do zwiększenia wymiarowości problemu, co może mieć wpływ na efektywność metod klasyfikacji. W związku z tym selekcję cech można określić jako proces identyfikowania i odrzucenia cech podobnych i nieistotnych, które mogą zmniejszać wydajność klasyfikacji [281], [318]. Jedną z prostszych metod selekcji cech jest ich losowy wybór, który może zwiększyć dokładność klasyfikacji poprzez zmniejszenie wrażliwości na zburzenia w danych oraz możliwą minimalizację korelacji pomiędzy cechami [113]. Natomiast systematyczne podejścia do selekcji cech dzieli się na trzy podstawowe rodzaje: metody filtrów, opakowane i wbudowane.

7.1.1 Filtry

Filtry są metodami selekcji, które umożliwiają wybór cech istotnych na podstawie oceny wartości wybranej miary, obliczonej na podstawie dostępnego wektora cech. Ideą takiej selekcji jest uzyskanie podzbioru optymalnego, który uwzględnia czynniki mające wpływ na analizowany model oraz w efekcie w sposób jednoznaczny umożliwia dyskryminację pomiędzy klasami. W rzeczywistości otrzymanie podzbioru optymalnego, wyznaczonego zgodnie z ideą optymalizacji z ograniczeniami, często jest procesem złożonym obliczeniowo i czasochłonnym. Poszukiwanie podzbioru optymalnego może być realizowane poprzez metodę wszystkich możliwych regresji, w której sprawdzane są efekty uzyskane poprzez wszystkie możliwe kombinacje cech wejściowych.

Alternatywą jest stosowanie selekcji krokowej, która umożliwia uzyskanie suboptymalnego podzbioru cech, będącego pewnym kompromisem, poprzez dodawanie lub pomijanie cechy w każdym kolejnym kroku zgodnie z przyjętym kryterium [227].

Filtry można podzielić ze względu na rodzaj stosowanej miary, np. informacji, statystyczne, odległości, zależności, spójności, podobieństwa. Wykorzystanie tych metod umożliwia uzyskanie wyselekcjonowanego wektora cech, który można zastosować jako wejście dowolnego algorytmu klasyfikacji [318]. Poniżej zamieszczono krótkie opisy poszczególnych filtrów stosowanych w analizach całonocnego EEG.

7.1.1.1 Algorytm ReliefF

Algorytm ReliefF jest najbardziej popularną odmianą algorytmów typu Relief, będących rankingowymi algorytmami selekcji cech, często wykorzystywanymi w zadaniu klasyfikacji binarnej. Metody typu Relief są podobne do metody k najbliższych sąsiadów i jej podstawowa wersja polega na znalezieniu najbliższego sąsiada dla każdego punktu z tej samej i z innej klasy [16], [237], [318]. Algorytm ReliefF umożliwia selekcję dla większej ilości klas niż dwie. Dla losowo wybranego punktu z wektora cech poszukuje k najbliższych sąsiadów z tej samej oraz z innych klas. Następnie wyróżniane są te cechy, których wartości są odpowiednio różne dla różnych klas, a odrzucane te, których wartości są różne dla sąsiadów z tej samej klasy [62], [237], [266], [281]. W efekcie algorytm umożliwia określenie stopnia, w którym cechy skalarne umożliwiają rozróżnienie pomiędzy klasami [16], [280], [281].

7.1.1.2 Ocena cech za pomocą testu t -Studenta

Test t -Studenta zazwyczaj jest stosowany do oceny statystycznej istotności różnicy pomiędzy wartościami średnimi z dwóch grup. W ten sposób może znaleźć zastosowanie w selekcji cech poprzez określenie, czy średnia wartość wybranej cechy różni się istotnie pomiędzy klasami. W praktycznym zastosowaniu poszukuje się cech, dla których wartość prawdopodobieństwa popełnienia błędu pierwszego rodzaju (odrzućcia hipotezy o równości średnich, mimo że jest prawdziwa) p_t , będąca wynikiem przeprowadzonego testu, jest mała (np. $p_t < 0,05$) [281], [313].

7.1.1.3 Analiza wariancji

Jednoczynnikowa analiza wariancji (ang. *One-Way Analysis of Variance (ANOVA)*) umożliwia ustalenie, czy istnieją statystycznie znaczące różnice między średnimi danej

cechy w klasach poprzez badanie wpływu zmiennych niezależnych (klasa) na jedną zmienną zależną (wartość średnia cechy w klasie). W metodzie tej testowana jest hipoteza, że średnie danej cechy we wszystkich analizowanych klasach są równe wobec hipotezy alternatywnej, w której średnia z co najmniej jednej klasy różni się od innych [97], [130], [131], [132], [187], [228], [249]. ANOVA może być wykorzystywana dla większej ilości klas niż dwie i polega na porównaniu wariancji całkowitej (dla wszystkich klas) z wariancjami wewnątrz klas. Duża różnica między całkowitą wariancją w porównaniu z wariancją w którejś z klas oznacza, że cecha ma wpływ na rozróżnienie klas.

7.1.1.4 Metoda Fishera

Metodę Fishera bezpośrednio stosuje się dla dwóch klas, natomiast dla wielu klas należy albo rozpatrywać klasy parami, albo pojedynczą klasę przeciw innym [237], [281]. Metoda polega na obliczeniu współczynnika Fishera na podstawie średnich i wariancji z dwóch rozpatrywanych klas. Jego wartość umożliwia ocenę różnorodności wybranej cechy pomiędzy dwiema rozpatrywanymi klasami [239]. Współczynnik Fishera oblicza się dla każdej cechy, a następnie, na podstawie jego wartości średniej, określana jest wartość progowa, pozwalająca na wyróżnienie tych cech, których wartość współczynnika Fishera jest większa od wartości progowej [281]. Wysoka wartość współczynnika Fishera wskazuje na dużą zdolność dyskryminacyjną danej cechy [129], [174], [281], [308].

7.1.1.5 Liniowa analiza dyskryminacyjna

Liniowa analiza dyskryminacyjna (ang. *Linear Discriminant Analysis (LDA)*) jest uogólnieniem liniowej dyskryminacji Fishera [110], metody stosowanej w statystyce i rozpoznawaniu wzorców, która jako metoda selekcji cech umożliwia znaczną redukcję ich liczby poprzez przekształcenie oryginalnego zbioru cech w nowy, będący złożeniem cech oryginalnych i wektora wag. Nowy wektor cech jest nową, liniową kombinacją cech oryginalnych [175]. Metoda może być stosowana dla wielu klas [18], [175], [195].

7.1.1.6 Analiza korelacji liniowej

Analiza korelacji liniowej w zadaniu selekcji cech wykonywana jest w celu wyboru cech najmniej skorelowanych z pozostałymi i może być wykonywana poprzez zastosowanie analizy regresji liniowej. Metoda może być stosowana dla dużej ilości cech oraz dla większej ilości klas niż dwie, i wtedy nazywana jest analizą regresji wielokrotnej (ang. *Multivariate Regression Analysis (MRA)*). Pozwala ona na ilościowe określenie

stopnia, w jakim analizowana cecha (zmienna zależna) zależy liniowo od pozostałych cech poprzez znalezienie liniowego modelu tej zależności. Następnie ocena uzyskiwanych modeli regresji liniowej wykonywana jest poprzez zastosowanie współczynnika determinacji R^2 . Dla cechy silnie zależnej liniowo od pozostałych wartość R^2 jest duża (można ją stosować w progowaniu) [44], [249], [264].

7.1.1.7 Szybki filtr oparty na korelacji

Szybki filtr oparty na korelacji (ang. *Fast Correlation-Based Filter* (FCBF)) jest metodą bazującą na współczynnikach korelacji, w której selekcja cech wykonywana jest w oparciu o kryterium niepewności symetrycznej (ang. *Symmetrical Uncertainty* (SU)), będącej stosunkiem zawartości informacyjnej, która określa ilość informacji uzyskanej poprzez wykorzystanie entropii cechy, do sumy entropii. Początkowo w metodzie FCBF obliczane są SU dla każdej analizowanej cechy i ocenia się, czy ich wartość przekracza wartość progową. Następnie analizuje się powstały zbiór cech i usuwane są ewentualne cechy, określone jako nadmiarowe [125], [126], [281], [283], [328], [345].

7.1.1.8 Algorytm MRMR

Algorytm minimalnej redundancji – maksymalnej istotności (ang. *Minimal Redundancy Maximal Relevance* (MRMR)) jest metodą, która umożliwia selekcję cech minimalizując ich redundancję. Metoda bazuje na zagadnieniach z teorii informacji dotyczących określenia zależności pomiędzy cechami. Funkcja informacji wzajemnej umożliwia szybkie obliczenie nieliniowych podobieństw między cechami i w metodzie MRMR wykorzystywana jest w celu redukcji ilości cech przy jednoczesnej maksymalnej informacji zawartej w wybranym zbiorze cech [281]. Alternatywną metodą obliczenia korelacji z klasą i między klasami do informacji wzajemnej jest obliczenie statystyki F oraz współczynnika korelacji Pearsona. Następnie wykonywana jest maksymalizacja funkcji celu, będącej miarą istotności. Podsumowując, celem algorytmu MRMR jest znalezienie optymalnego zestawu cech o maksymalnej istotności i jednocześnie minimalizacja ich redundancji [31], [217], [236], [256], [280].

7.1.1.9 Analiza składowych głównych

Analiza składowych głównych (ang. *Principle Component Analysis* (PCA)) jest statystyczną metodą analizy czynnikowej, której celem w selekcji cech jest wyznaczenie nieskorelowanych cech (będących składowymi głównymi) o możliwie największych

uporządkowanych malejąco wariancjach, które wynikają z ich potencjalnego zróżnicowania obserwacji pomiędzy klasami. PCA polega na liniowym przekształceniu przestrzeni oryginalnych cech w inną przestrzeń składowych głównych, które wyznaczają kierunki największej zmienności. W efekcie metoda umożliwia zmniejszenie ilości cech poprzez wybór pierwszych kolejnych składowych głównych [195], [248].

7.1.1.10 Selekcja krokowa

Metoda selekcji krokowej, nazywana również regresją krokową, jest rodzajem analizy regresji i nie jest bezpośrednio związana z żadnym filtrem cech. Procedura jest stosowana wtedy, gdy elementarne działanie w filtrze charakteryzuje tylko jedną cechę (do zostawienia albo do odrzucenia) i w następnym kroku konieczne jest przejście do analizy kolejnej cechy. Metody selekcji krokowej umożliwiają uzyskanie suboptymalnego podzbioru cech poprzez dodawanie lub odrzucanie analizowanej cechy w kolejnych krokach algorytmu zgodnie z przyjętym kryterium. W podejściu tym wyróżnia się selekcję wstępującą (ang. *Sequential Forward Selection* (SFS)) oraz eliminację wsteczną (ang. *Sequential Backward Selection* (SBS)) [231]. Różnica między metodami polega na tym, że w oparciu o wartość miary przydatności cechy i określony próg, cecha jest dodawana (selekcji wstępującej) albo usuwana (eliminacji wstecznej) [318]. Metoda selekcji krokowej jest stosowana np. podczas wykonywania analizy regresji liniowej (MRA) lub analizy wariancji (ANOVA).

7.1.2 Metody opakowane

Metody opakowane (ang. *Wrapper Methods*) wykorzystują algorytmy uczenia indukcyjnego do oceny potencjalnego wektora cech. Ten typ metod jest czasochłonny w związku z tym, że wymagają wielokrotnego uczenia algorytmu klasyfikacji i sprawdzania jego dokładności, co daje sprzężenie zwrotne pomiędzy algorytmem selekcji cech a klasyfikatorem. W przypadku dużej ilości potencjalnych cech, zadania takie są trudne do rozwiązania w racjonalnym czasie. W metodach opakowanych miarą oceny wybranego wektora cech jest uzyskany wynik klasyfikacji i dlatego wykorzystywane są wybrane metody walidacji. Co więcej, uzyskany w ten sposób wynik selekcji cech dotyczy tylko wybranej metody i może nie być optymalny dla innych automatycznych metod klasyfikacji [16], [63]. Najczęściej metody opakowane stosuje się w połączeniu z filtrami. Filtry wykorzystywane są do selekcji cech, a optymalizacja ich hiperparametrów

wykonywana jest na podstawie metody opakowującej – np. wybór ilości pierwszych składowych głównych po PCA lub wykorzystanie selekcji krokowej w połączeniu z kryterium w postaci dokładności klasyfikacji na każdym etapie modyfikacji wektora cech – znanych jako algorytmy zmiennego przeszukiwania w przód lub w tył (ang. *Sequential Floating Forward Selection* (SFFS) oraz *Sequential Floating Backward Selection* (SFBS)) [16], [63], [112], [231].

7.1.3 Metody wbudowane

Metody wbudowane (ang. *Embedded Methods*) umożliwiają selekcję cech na etapie uczenia algorytmu decyzyjnego, podczas którego dokonywana jest ich ocena wbudowana w algorytm [318]. W związku z tym są to metody dostosowane do wybranego klasyfikatora. Wśród algorytmów klasyfikacji, w których podczas procesu uczenia równocześnie wykonywana jest selekcja cech, można wyróżnić drzewa decyzyjne oraz metody liniowe z regularyzacją: metodę LASSO (ang. *Least Absolute Shrinkage and Selection Operator*) i sieci elastyczne (ang. *Elastic Net*) [318]. Ponadto klasyfikatory oparte o uczenie głębokim w czasie uczenia wykonują jednocześnie ekstrakcję i selekcję najlepszych cech [6], [19], [295], [314].

7.2 Wybór metody selekcji cech

Selekcję cech po etapie ekstrakcji wykonano w niewielu badaniach nad detekcją bezdechu sennego tylko na podstawie sygnału EEG tak, aby zmniejszyć rozmiar wektora cech skalarnych [31], [249], [308]. W pracach, w których ją zastosowano, wykorzystano algorytm MRMR [31], metodę Fishera [308] oraz połączenie analizy wariancji i regresji liniowej [249]. W pozostałych pracach wymiar wektora cech nie był redukowany ani nie było wykonywane sprawdzenie zdolności dyskryminacyjnych obliczonych cech skalarnych, jednak ich ilość była niewielka. Wysoką dokładność (około 90%) klasyfikacji bezdechu sennego uzyskano zarówno w pracach, w których wykonano selekcję cech [31], [308] jak i w tych, w których jej nie przeprowadzono [12], [35], [144], [145], [287], [322].

W niniejszej pracy zdecydowano się na porównanie trzech metod selekcji cech polegających na ich filtracji:

- algorytmu MRMR umożliwiającego wybór takiego zestawu cech, który zawiera maksymalną informację o różnicach pomiędzy klasami,

oraz połączenia dwóch metod, gdzie pierwsza umożliwia odrzucenie cech nie różnicujących między klasami, a druga eliminację cech zależnych liniowo metodą eliminacji wstecznej:

- algorytmu ReliefF i regresji liniowej (MRA),
- analizy wariancji i regresji liniowej (MRA).

Wstępna analiza wybranych metod selekcji cech wraz z oceną trafności klasyfikacji z wykorzystaniem klasyfikatora typu k-NN zostanie wykonana dla jednego zbioru cech o największej ich ilości (351), uzyskanego po ekstrakcji metodą HHT. Następnie wybrane podejście, które umożliwi uzyskanie największej dokładności klasyfikacji bezdechu sennego, zostanie zastosowane dla pozostałych zbiorów cech. Po uzyskaniu wyselekcjonowanych podzbiorów cech dla każdej metody ekstrakcji, zostaną one połączone w jeden zbiór i ponownie nastąpi selekcja cech z wykorzystaniem wybranej wcześniej metody.

7.2.1 Selekcja cech metodą MRMR

Selekcja cech wykonana metodą MRMR umożliwia uszeregowanie cech od najbardziej do najmniej istotnej dla klasyfikacji w obrębie analizowanych klas oraz znalezienie zestawu cech, który najlepiej reprezentuje epoki w obrębie analizowanego problemu klasyfikacyjnego. Algorytm określa zróżnicowanie cech w klasach na podstawie informacji wzajemnej. Uzyskany ranking cech jest wykonany na podstawie wartości ilorazu informacji wzajemnej (ang. *Mutual Information Quotient*, MIQ_x):

$$MIQ_x = \frac{V_x}{W_x}, \quad [7.1]$$


gdzie V_x jest współczynnikiem znaczenia cechy W_i w analizowanym zbiorze W , wskazującym na jej znaczenie w odniesieniu do etykiet klas y :

$$V_x = I(W_i, y), \quad [7.2]$$

a W_x to współczynnik nadmiarowości zbioru W :

$$W_x = \frac{1}{|n_w|} \sum_{z \in W} I(W_i, W_j), \quad [7.3]$$


Gdzie W_i to aktualnie oceniana cecha, a W_j kolejna, najistotniejsza cecha zbioru W , n_w jest ilością cech w ich zbiorze W , a I informacją wzajemną. W efekcie cechy ze zbioru wejściowego są uporządkowane według ważności zgodnie z wartością uzyskanego wyniku ilorazu informacji wzajemnej, od maksymalnej do minimalnej. Duża wartość ilorazu wskazuje na istotność cechy. Co więcej, duży spadek wartości wyniku po danej cesze dodatkowo podkreśla pewność jej wyboru jako predyktora, mającego duży wpływ na rozróżnienie klas. Wykres na Rysunku 7.1 przedstawia cechy po ekstrakcji metodą HHT uszeregowane zgodnie z ich ważnością (od najbardziej istotnej do najmniej) na podstawie wyniku algorytmu MRMR.



Rysunek 7.1. Ranking cech będący wynikiem algorytmu MRMR.

Następnie, na podstawie wartości wyjściowych i Rysunku 7.1, wybrano próg o wartości 0,015, będący znaczącym spadkiem wartości wyjściowej dla kolejnej cechy, oraz próg 0, i dla wynikających stąd zestawów cech przetestowano trafność klasyfikacji. Najwyższą trafność klasyfikacji 67,85% metodą k-NN uzyskano dla zbioru 323 cech (z 351), których

wartości MIQ_x były większe od 0. Na rysunku poniżej przedstawiono pierwsze 10 najbardziej istotnych cech dla klasyfikacji w obrębie wybranych klas.



Rysunek 7.2. Pierwsze 10 cech najistotniejszych cech według rankingu metodą MRMR.

7.2.2 Selekcja cech metodą ANOVA i MRA

Analiza wariancji (ANOVA) umożliwia określenie, czy obserwowana zmienność cechy jest powiązana z jej przyporządkowaniem do klasy. W związku z tym została wykorzystana do odrzucenia tych cech, które nie są różnicujące w obrębie klas z poziomem istotności $p = 0,05$ [286]. Następnie dla wektora cech uzyskanych po ANOVA została przeprowadzona eliminacja wsteczna z wykorzystaniem regresji liniowej (MRA). Metoda MRA umożliwiła odrzucenie cech, które były prawie liniowo zależne od innych, z zastosowaniem skorygowanego współczynnika determinacji $\bar{R}^2 > 0,95$:


$$\bar{R}^2 = 1 - (1 - R^2) \frac{n_w - 1}{n_w - r - 1}, \quad [7.4]$$

gdzie n_w jest liczbą wszystkich cech, a r jest całkowitą liczbą zmiennych objaśniających w modelu. Analiza wariancji dała niewielką redukcję cech z 351 do 329, natomiast po dodatkowym wykonaniu MRA ilość cech po selekcji wyniosła 217.


7.2.3 Selekcja cech metodą ReliefF i MRA

Selekcja cech metodą ReliefF umożliwia uzyskanie rankingu cech w kolejności od najbardziej do najmniej różnicujących. Metoda ReliefF jest podobna do algorytmu k-NN i polega na znalezieniu najbliższego sąsiada dla każdego punktu z tej samej oraz innej cechy i ocenę ich wartości. Algorytm promuje te cechy, których wartości są różne dla sąsiadów z różnych klas oraz karze te, których wartości są różne dla sąsiadów z tej samej klasy. W efekcie umożliwia uzyskanie rankingu cech, uporządkowanych w kolejności według ich ważności powiązanej z wagami cech, które mogą przyjmować wartość od -1 do 1. Duże, dodatnie wagi przypisane są do cech najbardziej różnicujących klasy. Ranking cech oraz ich wagi zwykle zależą od hiperparametrów algorytmu, którymi są: ilość sąsiadów k oraz wartość progu odrzucenia cech th związanego z wartością wag. W związku z tym, aby wyniki algorytmu były reprezentatywne, selekcję cech metodą ReliefF wykonano dla różnych wartości k oraz th . Wartość testowanych th została określona na podstawie wykresu rankingu cech uzyskanego dla $k=10$, będącego zazwyczaj domyślną wartością tego parametru. Zgodnie z literaturą, wzrost ilości sąsiadów, jeśli jest zbyt duży, może wiązać się z nieznanieniem przez algorytm najważniejszych cech, natomiast dla $k=1$ oszacowanie może być niewiarygodne, szczególnie w przypadku danych zaszumionych [176], [268]. Dlatego aby sprawdzić, jaka wartość k w przedziale od 3 do 300 [266] oraz różnych wartości th (0,40; 0,30; 0,20; 0,180; 0,150; 0,10; 0,080; 0,050; 0,030; 0,020; 0,0150; 0,010; 0,0050; 0), dobranych na podstawie rankingu cech dla $k=10$, umożliwia uzyskanie najwyższej trafności klasyfikacji dla różnej ilości sąsiadów, wykonano klasyfikację metodą k-NN analogicznie, jak przy ocenie metod przetwarzania wstępnego (Rozdział 5) i wybrane zostały te parametry: $k=6$ i $th=0,005$, dla których średnia wartość klasyfikacji jest największa i wyniosła 68,65%, a ilość cech po selekcji to 292.

Ponieważ algorytm ReliefF określa jedynie, które cechy najlepiej różnicują klasy, w drugim etapie dodatkowo wykorzystano regresję liniową analogicznie, jak przy selekcji metodą ANOVA i MRA. Porównano też wyniki selekcji cech tylko dla metody ReliefF oraz jej połączenia z MRA dla progu skorygowanego współczynnika determinacji o wartości $\bar{R}^2 = 0,97$. Analiza regresji umożliwiła dla tej metody dodatkową redukcję cech z 292 do 238, a trafność klasyfikacji zmniejszyła się do 66,79%. Na rysunkach poniżej przedstawiono ranking cech dla HHT uzyskany na podstawie metody ReliefF oraz pierwsze 10 najbardziej istotnych cech dla klasyfikacji w obrębie wybranych klas.



Rysunek 7.3. Ranking cech będący wynikiem algorytmu ReliefF.



Rysunek 7.4. Pierwsze 10 cech o najwyższych wartościach wag uzyskanych na podstawie metody ReliefF.

7.2.4 Wyniki selekcji cech wybranymi metodami

Dla każdej z wybranych metod selekcji cech została wykonana ocena trafności klasyfikacji z wykorzystaniem metody k-NN (analogicznie jak w Rozdziale 5). Optymalny model klasyfikatora k-NN został określony dla sygnału EEG po przetwarzaniu wstępnym oraz ekstrakcji cech wykonanej metodą HHT dla parametru $k=17$ i odległości miejskiej. Następnie z wykorzystaniem klasyfikatora wykonano ocenę trafności dla sygnału po selekcji cech trzema wybranymi metodami

Porównanie wyników klasyfikacji wykonano poprzez zastosowanie testu *t*-Studenta dla prób zależnych. Początkowo wykonano dwustronny test do weryfikacji hipotezy zerowej o równości i alternatywnej o różnicy w wartości średniej trafności klasyfikacji dla cech po selekcji różnymi metodami (analogicznie jak w Rozdziale 5). Wynik testu umożliwił określenie, czy selekcja cech zwiększa trafność klasyfikacji (czy różnica pomiędzy średnimi jest istotna statystycznie). Testy dwustronne wykonano porównując średnią trafność klasyfikacji dla cech bez selekcji i każdej z 5 metod selekcji cech (a, b, c, d, e). Następnie, jeśli wynik testu dwustronnego wskazywał na istotną statystycznie różnicę pomiędzy średnimi, wykonano test jednostronny (c, e, f), dzięki czemu możliwe było określenie, która ze średnich trafności klasyfikacji jest większa. Wyniki klasyfikacji oraz wykonanych testów statystycznych (wraz z wartością p_i) przedstawiono w Tabeli 7.1.

Tabela 7.1. Porównanie trafności klasyfikacji epok sygnału EEG metodą k-NN przed i po ekstrakcji cech metodą HHT dla wybranych metod selekcji cech.

	Bez selekcji	MRMR	ANOVA	ANOVA+MRA	ReliefF	ReliefF+MRA
Trafność klasyfikacji [%]	68,04±2,25 a,b,c,d,e	67,85±2,32 a	68,08±2,27 b	66,52±2,32 c	68,65±2,34 d	66,79±2,48 e
Ilość cech	351	323	329	217	292	238

Wyniki testów statystycznych

Test dwustronny:

a. brak istotnej statystycznie różnicy ($p_i = 0,58$)

b. brak istotnej statystycznie różnicy ($p_i = 0,91$)

c. istotna statystycznie różnica ($p_i = 4,4 \times 10^{-6}$)

d. brak istotnej statystycznie różnicy ($p_i = 0,059$)

e. istotna statystycznie różnica ($p_i = 5,8 \times 10^{-7}$)

Test jednostronny:

—

—

średnia bez selekcji jest większa niż po ($p_i = 2,2 \times 10^{-6}$)

—

średnia bez selekcji jest większa niż po ($p_i = 2,9 \times 10^{-7}$)


Celem wykonanych testów statystycznych był wybór metody selekcji cech, która będzie wykorzystana do redukcji zbioru cech dla wszystkich opracowanych metod ich ekstrakcji. Wykonane testy dwustronne wskazały na istotną statystycznie różnicę pomiędzy średnią trafnością cech bez oraz po selekcji dla dwóch metod: ANOVA+MRA i ReliefF+MRA (c, e), a dla metod ANOVA, MRMR oraz ReliefF (a, b, d) wynik testu nie umożliwił odrzucenia hipotezy zerowej o równości średnich z populacji. Następnie wyniki wykonanych testów jednostronnych pomiędzy cechami bez selekcji i po selekcji metodami dwuetapowymi (c, e) wskazują, że średnia trafność klasyfikacji dla cech bez selekcji jest większa niż po jej wykonaniu. Największą redukcję ilości cech uzyskano po selekcji połączonymi metodami ANOVA i MRA do 217 cech. Uzyskane pogorszenie trafności klasyfikacji po wprowadzeniu drugiego etapu selekcji wykorzystującej MRA (b-c, d-e) może być związane ze sposobem działania k-NN, co należałoby dodatkowo zbadać (wykracza to jednak poza zakres tej pracy). Porównując Rysunki 7.2 i 7.4 przedstawiające 10 pierwszych cech z ich rankingu będącego wynikiem metody MRMR oraz ReliefF można zauważyć, że zestaw początkowych cech, które mają największy wpływ na rozróżnienie pomiędzy trzema klasami (NORM, OSA i CSA) różni się w zależności od wybranego algorytmu selekcji. Ostatecznie, metoda ReliefF umożliwiła redukcję cech większą niż z zastosowaniem metody MRMR, nie pogarszając trafności klasyfikacji oraz znaczne skrócenie czasu obliczeń ze względu na znaczną redukcję ich liczby z 351 do 292. Z tych powodów została ona wybrana jako metoda selekcji cech dla wszystkich opisanych w Rozdziale 6 metod ekstrakcji.

7.3 Selekcja cech wybraną metodą


Dla każdej z metod ekstrakcji cech sygnałów EEG wybranych w Rozdziale 6 wykonano selekcję cech metodą ReliefF, która została wybrana w poprzednim podrozdziale. Ponieważ wartości wag zależą od analizowanych cech oraz hiperparametrów k i th , dla każdego zbioru cech suboptymalne wartości tych hiperparametrów zostały wybrane optymalizując wynik klasyfikacji. Ostatecznie wybrane zbiory cech są tymi, które umożliwiły uzyskanie największej trafności klasyfikacji w obrębie trzech analizowanych klas.

Dla każdego z analizowanych zbiorów, selekcję cech wykonano zgodnie z metodyką opisaną poniżej. Wartości th zostały określone na podstawie uzyskanych wykresów (Rysunek 7.5) rankingu cech dla $k=10$ (wartości często przyjmowanej jako domyślną)


[176], [268]. Testowane progi odrzucenia zostały dobrane na podstawie znaczącego spadku wartości wagi dla kolejnej cechy w rankingu. Następnie przetestowano zbiory cech uzyskane zgodnie ze wszystkimi wybranymi th również dla innych wartości najbliższych sąsiadów, od 3 aż do połowy wielkości wektora cech opisującego jedną epokę.




a) BPFButt




b) BPFCheb




c) DWT




d) EMD




e) VMD



f) HHT



g) DWT+HT



h) VMD+HT

Rysunek 7.5. Ranking cech uzyskany metodą ReliefF o parametrze $k=10$ dla wszystkich metod ekstrakcji cech.

Ocena każdego potencjalnego zbioru cech została wykonana z zastosowaniem metody k -NN o ilości sąsiadów $k=17$, będącą optymalnym klasyfikatorem dla zbioru cech po ekstrakcji metodą HHT bez selekcji cech. Wybrane parametry metody ReliefF, umożliwiające uzyskanie najwyższej trafności klasyfikacji oraz uzyskaną zredukowaną ilość cech w zbiorach po selekcji przedstawiono w Tabeli 7.2.

Tabela 7.2. Trafność klasyfikacji bez i po selekcji cech oraz dobrane parametry k i th metody ReliefF.


Metoda	Bez selekcji		Po selekcji		Parametry ReliefF	
	Trafność klasyfikacji [%]	Ilość cech	Trafność klasyfikacji [%]	Ilość cech	k	th
BPFButt	51,27±2,86	45	59,77±2,62	7	3	0,0100
BPFChab	49,51±2,64	45	61,71±2,41	11	4	0,0080
DWT	47,14±2,72	45	60,69±2,64	18	5	0,0050
EMD	46,03±2,97	117	56,61±2,78	48	3	0,0015
VMD	49,96±2,95	45	53,41±2,43	39	17	0,0010
HHT	68,04±2,25	351	68,65±2,34	292	6	0,0050
DWT+HT	54,49±2,54	135	57,37±2,65	105	3	0,0030
VMD+HT	54,12±2,97	135	57,14±2,66	7	3	0,0105

Można ponadto zaobserwować, że selekcja cech zwiększyła średnią trafność klasyfikacji w każdym przypadku.

Uzyskane w wyniku selekcji podzbiory cech, suboptymalne w obrębie każdej metody ekstrakcji, połączono w jeden zbiór. Aby ograniczyć ilość podobnych cech w zbiorze całościowym, z dwóch podzbiorów po ekstrakcji cech metodą filtracji pasmowoprzepustowej z zastosowaniem filtrów Czebyszewa typu II i Butterwortha, wybrano tylko jeden. W tym celu wykonano dwustronny test *t*-Studenta weryfikujący hipotezę zerową o równości średnich z tych zbiorów po selekcji. Ponieważ wynik testu dwustronnego ($p_t = 1,62 \times 10^{-7}$) umożliwił odrzucenie hipotezy zerowej na rzecz alternatywnej o różności średnich, wykonano również test jednostronny, którego wynik ($p_t = 8,1 \times 10^{-8}$) wskazuje, że średnia trafność klasyfikacji jest statystycznie większa dla podzbioru uzyskanego po ekstrakcji filtrami Czebyszewa (BPFChieb). Po połączeniu wszystkich podzbiorów: BPFChieb, DWT, EMD, VMD, HHT, DWT+HT i VMD+HT, zbiór całościowy składa się z 520 cech. Kolejno wykonano selekcję cech z uzyskanego zbioru z wykorzystaniem metody ReliefF, analogicznie jak poprzednio dla różnych wartości *th* (0,4; 0,35; 0,3; 0,25; 0,15; 0,09; 0,05; 0,04; 0,02; 0,015; 0,013; 0,012; 0,01; 0,006; 0,005; 0,0045; 0,004; 0,0035; 0,003; 0,0025; 0,002; 0,0015; 0,001; 0,0005; 0) i *k* (od 3 do 53). Uzyskany w ten sposób ranking cech, którego efektem był brak poprawy, ale również brak pogorszenia trafności klasyfikacji przy równoczesnej redukcji ilości cech, przedstawiono na Rysunku 7.6. Wykonana selekcja cech umożliwiła redukcję do 500 cech (Tabela 7.3).

Tabela 7.3. Najwyższa trafność klasyfikacji i odchylenie standardowe bez i po selekcji cech ze zbioru całościowego oraz dobrane parametry *k* i *th* metody ReliefF.

Metoda	Bez selekcji		Po selekcji		Parametry ReliefF	
	Trafność klasyfikacji [%]	Ilość cech	Trafność klasyfikacji [%]	Ilość cech	<i>k</i>	<i>th</i>
Zbiór całościowy	72,91±1,92	520	72,92±1,92	500	32	0,0015



Rysunek 7.6. Ranking cech uzyskany metodą ReliefF o parametrze $k=32$ dla całościowego zbioru cech.

Następnie, aby wybrany zbiór cech składał się z jak najmniejszej ich ilości przy jednocześnie maksymalnie dużym potencjale różnicującym, co może mieć pozytywny wpływ na efektywność klasyfikatorów w późniejszej ich analizie wykonanej w Rozdziale 8, dla każdego kolejnego uzyskanego na tym etapie badań podzbioru cech wykonano dwustronny test t -Studenta sprawdzający równość średniej trafności klasyfikacji w porównaniu z najlepszym uzyskanym wynikiem ($k=32$, $th=0,0015$). W Tabeli 7.4 przedstawiono wybrane wyniki selekcji metodą ReliefF, dla których wynik testu statystycznego nie umożliwił odrzucenia hipotezy o równości średnich. W wyniku tej analizy wybrano ten podzbiór cech, o hiperparametrach metody $k=48$ i $th=0,0060$, który dla k -NN umożliwia statystycznie równie dobrą trafność klasyfikacji, a posiada najmniej cech (387). Będzie on dalej wykorzystywany do porównywania metod klasyfikacji.

Tabela 7.4. Porównanie średniej trafności klasyfikacji po selekcji cech ze zbioru całościowego metodą ReliefF dla wybranych przypadków.

Trafność klasyfikacji [%]	Ilość cech	Parametry ReliefF		Wyniki testu t-Studenta	
		<i>k</i>	<i>th</i>	<i>h</i>	<i>p_t</i>
72,92±1,92	500	32	0,0015	-	-
72,92±1,92	489	37	0,0020	0	0,99
72,92±1,90	501	24	0,0015	0	0,99
72,92±1,93	491	8	0,0025	0	0,98
72,92±1,93	492	24	0,0020	0	0,98
72,91±1,93	478	15	0,0030	0	0,97
72,91±1,93	484	32	0,0025	0	0,97
72,91±1,93	499	8	0,0020	0	0,97
72,91±1,92	507	49	0,0010	0	0,97
72,91±1,92	512	51	0,0005	0	0,97
72,91±1,92	516	3	0	0	0,97
72,91±1,93	476	23	0,0030	0	0,96
72,91±1,93	478	47	0,0025	0	0,96
72,90±2,02	417	9	0,0060	0	0,94
72,90±2,02	420	53	0,0050	0	0,93
72,89±1,94	476	4	0,0035	0	0,92
72,89±2,03	417	7	0,0060	0	0,92
72,89±2,03	413	10	0,0060	0	0,91
72,86±2,02	419	6	0,0060	0	0,83
72,86±2,02	425	44	0,0050	0	0,82
72,85±2,01	430	30	0,0050	0	0,81
72,85±2,02	427	36	0,0050	0	0,81
72,84±2,02	434	22	0,0050	0	0,78
72,65±2,12	421	5	0,0060	0	0,34
72,56±2,17	390	50	0,0060	0	0,22
72,56±2,17	387	48	0,0060	0	0,21
72,55±2,18	410	14	0,0060	0	0,21
72,55±2,18	408	15	0,0060	0	0,21

W Tabeli 7.5 przedstawiono porównanie ilości cech w zbiorze całościowym przed i po powyższej selekcji, pochodzących z poszczególnych metod ekstrakcji: BPFChEb, DWT, EMD, VMD, HHT, DWT+HT i VMD+HT. Zbiór cech przed selekcją składał się z 520 cech, w których największy był udział cech po ekstrakcji HHT (56,15%) oraz DWT+HT (20,19%). Po selekcji do 387 cech również te dwie metody ekstrakcji są dominujące, przy czym procentowy udział HHT w całym zbiorze się zwiększył (do 66,41%), a DWT+HT zmniejszył (do 14,99%). Sprawdzone również, jaki procent cech ze zbioru całościowego przeszedł etap selekcji w poszczególnych grupach zwianych z ich ekstrakcją. Dla wszystkich podzbiorów, oprócz BPF oraz VMD+HT, ilość cech uległa redukcji. W efekcie, w zbiorze po selekcji, uwzględnionych jest ponad 88% i 83% cech z pierwotnych zbiorów kolejno dla DWT i HHT, 55% dla DWT+HT i 45% oraz 42% kolejno dla EMD i VMD.

Tabela 7.5. Ilość cech w zbiorach całościowym i po selekcji, w grupach pochodzących z poszczególnych metod ekstrakcji.

Zbiór całościowy cech (przed selekcją)			Zbiór cech po selekcji		
Metoda ekstrakcji	Ilość cech	Udział w zbiorze [%]	Ilość cech	Udział w zbiorze [%]	Udział w zbiorze względem zbioru przed selekcją [%]
BPFChEb	11	2,12	11	2,84	100
DWT	18	4,46	15	3,88	83,33
EMD	48	9,23	22	5,68	45,83
VMD	39	7,50	17	4,39	42,59
HHT	292	56,15	257	66,41	88,01
DWT+HT	105	20,19	58	14,99	55,24
VMD+HT	7	1,35	7	1,81	100
Suma cech	520		387		74,42

7.4 Podsumowanie

Celem niniejszego rozdziału było uzyskanie suboptymalnego podzbioru cech o charakterze różnicującym pomiędzy trzema analizowanymi klasami. Wybór metody selekcji został wykonany poprzez porównanie następujących metod: algorytmu MRMR, algorytmu ReliefF, analizy wariancji i połączenia algorytmu ReliefF oraz analizy wariancji z regresją liniową, dla jednego zbioru cech po ekstrakcji metodą HHT. W efekcie najlepszą metodą okazał się algorytm ReliefF. Ostatecznie podzbiory cech wyselekcjonowane dla różnych metod ekstrakcji zostały połączone w zbiór całościowy o wymiarze 520 cech. Dla tego zbioru ponownie została wykonana selekcja cech metodą ReliefF, której wynikiem jest końcowy zbiór złożony z 387 cech, z których większość uzyskano wykonując ekstrakcję metodą HHT (66,41%) oraz DWT+HT (14,99%). Zostanie on wykorzystany do badania i optymalizacji klasyfikatorów w Rozdziale 8.

Rozdział 8

Algorytmy rozpoznawania bezdechu na podstawie epok EEG

8.1 Metody klasyfikacji epok EEG

Mimo, że w praktyce klinicznej ocena wzrokowa sygnału wykonywana przez ekspertów nadal jest obowiązującym standardem, to jest ona kosztownym oraz długotrwałym procesem. Automatyzacja procesu decyzyjnego z wykorzystaniem metod sztucznej inteligencji, w tym uczenia maszynowego, może pozwolić na przyśpieszenie procesu diagnostycznego oraz rozwój wiedzy odnośnie analizy sygnału EEG [143]. W zadaniu automatycznej detekcji zdarzeń, klasyfikacja jest etapem analizy, którego efektem jest rozróżnienie epok, czyli fragmentów sygnału, w odniesieniu do klas. Klasycznie, przed etapem klasyfikacji z wykorzystaniem metod uczenia maszynowego, zarejestrowany sygnał EEG podlega przetwarzaniu z zastosowaniem etapów opisanych we wcześniejszych rozdziałach: przetwarzania wstępnego, ekstrakcji oraz selekcji cech. Natomiast, gdy jako klasyfikator wykorzystuje metody uczenia głębokiego (ang. *Deep Learning*), możliwe jest wykorzystanie sygnałów nieprzetworzonych [74]. Ponadto metody klasyfikacji mogą działać z nauczycielem lub bez niego. Zakres niniejszej pracy obejmuje podejście klasyczne i wykorzystanie klasyfikatorów z nauczycielem.

Techniki klasyfikacji wykorzystywane aktualnie do automatycznego rozpoznawania epok sygnału EEG w zakresie analizy faz snu i bezdechu sennego można podzielić na: sztuczne sieci neuronowe, klasyfikatory statystyczne, klasyfikatory rozmyte, klasyfikatory mieszane oraz uczenie głębokie [216].

8.1.1 Klasyfikatory statystyczne

Klasyfikatory statystyczne w większości opierają się na modelach probabilistycznych (wyjątkiem jest SVM) i po podziale przestrzeni cech na różne klasy umożliwiają klasyfikację np. na podstawie prawdopodobieństwa przynależności wektora cech do danej klasy [216].

8.1.1.1 K-najbliższych sąsiadów

Metoda k-najbliższych sąsiadów (ang. *k-Nearest Neighbor* (k-NN)) jest nieliniowym klasyfikatorem nieparametrycznym, opartym na uczeniu przez analogię. Umożliwia przyporządkowanie nowego elementu do klasy na podstawie wiedzy o przyporządkowaniu do danej klasy jego najbliższych sąsiadów. W związku z tym, dwoma elementami, dzięki którym możliwa jest optymalizacja k-NN, są: liczba najbliższych sąsiadów oraz zastosowana metryka, na podstawie której obliczana jest odległość między elementami. Metryki szczegółowo omówiono w Rozdziale 8.3.2. Dodatkowo decyzja o przynależności nowego elementu do klasy podejmowana jest zgodnie z wybranym systemem głosowania: większościowym lub opartym na podobieństwach lub odległości. System głosowania umożliwia podjęcie decyzji o przynależności elementu do klasy i może być realizowany na podstawie zliczenia przynależności sąsiadów nowego elementu do danej klasy (system większościowy) albo poprzez zastosowanie ważonego algorytmu k-NN, w którym głosy związane z sąsiadami są ważone za pomocą funkcji podobieństwa (system oparty na podobieństwach) lub odległości danych uczących od testujących (system oparty na odległości) [83], [171], [250], [322], [323], [332].

8.1.1.2 Analiza dyskryminacyjna

Analiza dyskryminacyjna (ang. *Linear Discriminant Analysis* (LDA)) jest formą klasyfikatora liniowego, który umożliwia podział przestrzeni cech na klasy z wykorzystaniem hiperpłaszczyzn istniejących w wymiarze o jeden niższym niż przestrzeń cech. Klasyczna analiza dyskryminacyjna ma ograniczone zastosowanie jedynie do problemów, w których klasy można rozdzielić liniowo. Rozszerzeniem LDA jest kwadratowa analiza dyskryminacyjna (ang. *Quadratic Discriminant Analysis* (QDA)), w której hiperpowierzchnia rozdzielająca klasy przyjmuje postać kwadratową, czyli okręgu, elipsy, paraboli lub hiperboli [12], [216].

8.1.1.3 Naiwny klasyfikator bayesowski

Naiwny klasyfikator bayesowski (ang. *Naive Bayes Classifier* (NB)) jest klasyfikatorem statystycznym, opartym na twierdzeniu Bayesa dotyczącym prawdopodobieństwa warunkowego zdarzeń. Klasyfikacja z wykorzystaniem NB polega na przewidywaniu prawdopodobieństwa przynależności danych do klas i w efekcie przypisanie epok do właściwej klasy. Założeniem klasyfikatora bayesowskiego jest warunkowa niezależność klas, która oznacza, że wartość każdej cechy jest niezależna od

pozostałych cech opisujących epokę. Metoda ta jest klasyfikatorem, który może być z powodzeniem stosowany do dużych baz danych [12].

8.1.1.4 Modele Markova

Modele Markova (ang. *Markov Models* (MM)) to metoda stochastyczna, która umożliwia opisanie systemu na podstawie jego możliwych stanów oraz prawdopodobnych przejść pomiędzy nimi. Jeśli kolejne stany systemu są deterministyczne, czyli każde przejście pomiędzy stanami prowadzi do określonych wyników, to układ może być reprezentowany poprzez model Markova. Natomiast kiedy nie jest możliwa bezpośrednia obserwacja stanów modelu, wtedy do jego opisu wykorzystywane są ukryte modele Markova (ang. *Hidden Markov Models* (HMM)), które rozszerzają koncepcję MM. HMM można zastosować do klasyfikacji sygnałów niestacjonarnych oraz podzielonych na epoki – po wykonaniu ekstrakcji cech. Implementacja HMM zależy od obserwowanych stanów. Klasyfikacja z wykorzystaniem HMM jest wykonywana poprzez identyfikację najbardziej prawdopodobnej sekwencji stanów związanej z obserwacją stanów w wektorach cech [216].

8.1.1.5 Maszyna wektorów nośnych

Maszyna wektorów nośnych (ang. *Support Vector Machine* (SVM)) jest nadzorowanym algorytmem uczenia się, który umożliwia utworzenie przestrzeni decyzyjnej, będącej również hiperpłaszczyzną, która umożliwi podział przestrzeni na klasy oraz minimalizację błędu klasyfikacji poprzez uzyskanie maksymalnej geometrycznej odległości pomiędzy nimi [73], [301], [343]. Ideą klasyfikacji metodą SVM jest znalezienie hiperpłaszczyzny rozdzielającej klasy z maksymalnym marginesem lub, w przypadku nieliniowym, uczynienie tego po transformacji danych wejściowych z wykorzystaniem funkcji jądra (ang. *Kernels*) w przestrzeń, w której analizowane klasy są już separowalne liniowo [206]. Wśród wykorzystywanych w SVM typów funkcji jądra wyróżnia się: liniowe, nieliniowe, wielomianowe, sigmoidalne oraz radialne funkcje bazowe (ang. *Radial Basic Functions* (RBF)) [322]. SVM oprócz klasyfikacji binarnej umożliwia również detekcję w obrębie większej ilości klas niż dwie, poprzez zastosowanie zestawu hiperpłaszczyzn [12], [302].

8.1.2 Sztuczne sieci neuronowe

Sztuczne sieci neuronowe (ang. *Artificial Neural Network* (ANN)) to modele matematyczne znajdujące zastosowanie w wielu dziedzinach, których struktura i działanie

są inspirowane interakcjami neuronów w układzie nerwowym. ANN mogą być trenowane na podstawie zgromadzonych danych i na tej podstawie nauczyć się rozpoznawać wzorce, klasyfikować dane i prognozować przyszłe zdarzenia. Stosowane techniki sieci neuronowych można podzielić na dwa typy: sieci klasyczne, zbudowane z maksymalnie dwóch lub trzech warstw neuronów oraz sieci z uczeniem głębokim, które składają się z wielu warstw neuronów [216], [220]. Uczenie sieci neuronowej może być wykonywane na dwa sposoby: nadzorowane (z nauczycielem) oraz nienadzorowane (bez nauczyciela). Wykazano, że jednokierunkowa sieć neuronowa z jedną warstwą ukrytą o skończonej liczbie neuronów z radialną funkcją aktywacji lub z dwiema warstwami ukrytymi i sigmoidalną funkcją aktywacji mogą dowolnie dobrze aproksymować dowolne odwzorowanie (przy założeniu braku błędów w danych oraz ich wystarczającej ilości) [76], [140]. Zaproponowana przez Hintona i in. koncepcja uczenia głębokiego [138] umożliwiła skuteczne uczenie wielowarstwowych sieci neuronowych poprzez wykorzystanie zdolności ANN do reprezentowania istoty oryginalnych danych na podstawie cech wydobywanych w procesie uczenia. Następnie idea głębokiego uczenia ANN została rozwinięta o wielowarstwowy algorytm wstępnego uczenia nienadzorowanego, który wykazuje dużą zdolność rozwiązywania złożonych problemów [136], [138], [331].

8.1.2.1 Sieci klasyczne

Istnieje wiele różnych typów ANN o różnych architekturach oraz algorytmach uczących. Jako sieć klasyczną można rozumieć podstawową strukturę, którą jest perceptron, składający się z trzech warstw przetwarzania: wejściowej, jednej warstwy ukrytej i wyjściowej. Jego modyfikację do sieci wielowarstwowej, z większą ilością warstw ukrytych, nazywana się perceptronem wielowarstwowym (ang. *Multilayer Perceptron* (MLP)). Ogólnie perceptron i jego modyfikację do sieci wielowarstwowej nazywa się jednokierunkowymi sieciami neuronowymi (ang. *Feedforward Neural Network* (FFNN)) [271].

Podstawowym elementem struktury sieci neuronowych są sztuczne neurony, których złożenie tworzy warstwę. Neurony liniowo łączą swoje ważone wejścia i generują wartość wyjściową bazując na nieliniowej funkcji aktywacji. Hiperparametrami ANN umożliwiającymi optymalizację, oprócz ilości warstw oraz neuronów w warstwach, są wagi, według, których skalowane są dane wejściowe w warstwach, zastosowane funkcje aktywacji oraz reguła uczenia się.. Dodatkowo na wejściu neuronu

może występować próg (ang. *Bias*), będący dodatkowym wejściem o stałej wartości [219], [222], [271]. Głównym celem uczenia ANN jest osiągnięcie możliwie najmniejszego błędu klasyfikacji, który jest definiowany jako różnica między wynikami pożądanymi a rzeczywistymi. Początkowo wartości wag są inicjowane losowo, a wartość progów ustalana jest jako 1. Następnie ich ostateczne wartości określone są podczas uczenia ANN w procesie adaptacyjnej aktualizacji wag w odpowiedzi na dane wejściowe, w celu uzyskania znanej prawidłowej odpowiedzi sieci. Wśród popularnych funkcji aktywacji wymienić można liniową, sigmoidalną, skoku jednostkowego oraz hiperboliczną. Typ funkcji aktywacji w warstwie wyjściowej determinuje zakres danych wyjściowych sieci neuronowej [271].

W sieciach klasycznych często wykorzystywane jest uczenie z nauczycielem, polegające na wprowadzeniu informacji o przyporządkowaniu danych wejściowych do klas, wykonanej przez eksperta. W tym przypadku dane wejściowe korelowane są z wyjściem, korygowane są parametry sieci oraz obliczany jest błąd klasyfikacji, i jeśli spełnione są określone warunki, to proces uczenia zostaje zatrzymany. Po wykonanym procesie uczenia sieć neuronowa jest przygotowana do oceny nowych, nieznanych danych. W ten sposób proces uczenia ANN polega na rozwiązaniu problemu optymalizacyjnego, który można sprowadzić do minimalizacji funkcji wielu zmiennych [271]. Uczenie sieci neuronowej jest realizowane z zastosowaniem algorytmu uczącego, którego wybór zależy od wielu czynników, w tym m. in. złożoności problemu, architektury sieci oraz typu rozwiązywanego problemu: rozpoznawania wzorców lub regresji. Jednym z najbardziej popularnych algorytmów uczących, wykorzystywanych w sieciach FFNN, jest algorytm propagacji wstecznej [66].

8.1.2.2 Sieci Kohena

Mapy samoorganizujące się (ang. *Self-Organising Maps (SOM)*), nazywane również sieciami Kohena, są opartymi na sieciach neuronowych metodami klasteryzacji wykorzystywanymi do analizy oraz wizualizacji wielowymiarowych danych. SOM realizujące problem klasyfikacyjny nie potrzebują wcześniejszej wiedzy o liczbie klas, ale mogą realizować klasyfikację danych poprzez maksymalną separację cech wejściowych podczas nienadzorowanego uczenia, którego efektem jest rozdzielenie danych wejściowych na klasy. Metoda ta umożliwia uzyskanie zadowalających wyników również

przy stosunkowo niewielkim zbiorze danych oraz detekcja klas z ich wykorzystaniem może być szybsza niż z zastosowaniem sieci klasycznych [216], [271].

8.1.2.3 Sieci z uczeniem głębokim

Jako sieci z uczeniem głębokim (ang. *Deep Learning Network* (DLN)) określane są sieci neuronowe o wielu warstwach ukrytych, choć w ten sposób określa się również sieci już o minimum dwóch warstwach ukrytych [74]. Najbardziej popularną architekturą sieci z uczeniem głębokim, oprócz MLP, jest konwolucyjna sieć neuronowa (ang. *Convolutional Neural Network* (CNN)). Wśród innych popularnych architektur wyróżnia się sieci głębokiego zaufania (ang. *Deep Belief Network* (DBN)), które są złożeniem wielu ograniczonych maszyn Boltzmana (ang. *Restricted Boltzmann Machine* (RBM)), rekurencyjne sieci neuronowe (ang. *Recurrent Neural Network* (RNN)) oraz wielowarstwowe autoenkodery (ang. *Stacked Autoencoders* (SA)). DLN były wykorzystywane w analizie sygnału EEG pochodzącego z badań nad snem oraz innych zastosowań w tym: rozpoznawania emocji, do oceny wpływu pracy umysłowej, detekcji napadów padaczkowych i innych. W sieciach głębokich jako wejście może być podawany wektor cech, wartości sygnału lub obraz i od rodzaju tych danych zależy dalszy proces uczenia sieci. Wykorzystanie DLN do analizy sygnały EEG zostało opisane w Craik i in. [74] i nie będzie szerzej opisane w tej pracy.

8.1.3 Klasyfikatory rozmyte i mieszane

Klasyfikatory rozmyte (ang. *Fuzzy Classifiers* (FC)) oparte są na idei zbiorów rozmytych [337], będących próbą matematycznego opisu niejednoznacznych klas, czyli takich, które nie mają ściśle określonej granicy. Ten rodzaj klasyfikacji umożliwia rozpoznawanie wzorców, w tym rzeczywistych danych, w których granice pomiędzy podgrupami mogą nie być dobrze zdefiniowane [116], [216]. Logika rozmyta znajduje swoje zastosowanie przede wszystkim w zagadnieniach lingwistycznych i detekcji słów, które charakteryzują się z jednej strony precyzją w oczekiwanych rezultatach, a z drugiej nieprecyzyjnością. Ogólnie, implementacja klasyfikatora opartego na logice rozmytej obejmuje następujące kroki: przetwarzanie wstępne, rozmycie, utworzenie bazy reguł, wyostrenie i przetwarzanie końcowe [218].

Często klasyfikatory rozmyte są łączone z innymi metodami klasyfikacji. Takie połączenie dwóch lub więcej metod klasyfikacji nazywane jest klasyfikatorami mieszanymi (ang. *Combined Classifiers* (CC)), które, mimo większej złożoności

obliczeniowej, mają tendencję do uzyskiwania dokładniejszych wyników klasyfikacji. Często stosowane są do analiz offline, w których szybkość wykonywanych obliczeń nie ma aż tak dużego znaczenia. Powszechnie stosowanym klasyfikatorem mieszanym jest klasyfikator neurorozmyty [216].

8.1.3.1 Klasyfikator wzmacniający z pod- lub nadpróbkiowaniem

Klasyfikator wzmacniający z losowym podpróbkiowaniem (ang. *Random Undersampling Boosting* (RUSBoost)) jest hybrydowym modelem klasyfikacji dobrze dostosowanym do problemów, w których występuje nierównowaga danych w klasach. Algorytm wykorzystuje losowe podpróbkiowanie (RUS), które umożliwia usuwanie epoki z klasy, która jest najbardziej liczna, aż do momentu uzyskania równowagi w liczności klas oraz standardową metodę wzmocnienia klasyfikatorów (ang. *Boosting*), którą jest algorytm AdaBoost (umożliwiają uzyskanie na podstawie prostych i mało złożonych klasyfikatorów wysokiego wyniku skuteczności klasyfikacji [207]). Algorytm RUSBoost jest bardzo zbliżony do algorytmu SMOTEBoost, będącego metodą nadpróbkiowania opartą na algorytmie SMOTE (ang. *Synthetic Minority Oversampling Technique* (SMOTE)). Metoda ta wykorzystuje k-NN do utworzenia syntetycznych przykładów dla klasy, która jest reprezentowana przez mniejszą ilość danych niż pozostałe [319].

8.1.4 Ocena jakości klasyfikatora

Ocena jakości klasyfikatora wykonywana jest poprzez utworzenie tablicy pomyłek. Tablica pomyłek może dotyczyć zarówno klasyfikacji binarnej (Tabela 8.1) jak i wieloetykietowej (Tabela 8.2). Przy klasyfikacji binarnej rozpatrywane są dwie klasy: wyróżniona i odniesienia. Wyróżnia się następujące podstawowe elementy tablicy pomyłek:

- wyniki prawdziwie dodatnie (ang. *True Positive* (TP)) – prawidłowo zaklasyfikowana klasa wyróżniona jako wyróżniona,
- wyniki prawdziwie ujemne (ang. *True Negative* (TN)) – prawidłowo zaklasyfikowana klasa odniesienia jako odniesienia,
- wyniki fałszywie dodatnie (ang. *False Positive* (FP)) – nieprawidłowo zaklasyfikowana klasa odniesienia jako wyróżniona (błąd pierwszego rodzaju),
- wyniki fałszywie ujemne (ang. *False Negative* (FN)) – nieprawidłowo zaklasyfikowana klasa wyróżniona jako odniesienia (błąd drugiego rodzaju).

Tabela 8.1. Tablica pomyłek dla klasyfikacji binarnej.

		Stan rzeczywisty	
		Klasa wyróżniona	Klasa odniesienia
Wynik klasyfikacji	Klasa wyróżniona	TP	FP
	Klasa odniesienia	FN	TN

Na podstawie tablicy pomyłek możliwe jest obliczenie miar wydajności modelu, które pozwalają na ocenę klasyfikacji. Wśród najczęściej stosowanych miar dla klasyfikacji binarnej wyróżnia się [294]:

- dokładność (ang. *Accuracy* (A_c)), dla klasyfikacji binarnej równoważna z trafnością – procentowa ilość elementów poprawnie zaklasyfikowanych przez klasyfikator, określana również jako prawdopodobieństwo prawidłowej klasyfikacji:

$$A_c = \frac{TP + TN}{n}, \quad [8.1]$$

gdzie n to ilość epok we wszystkich klasach;

- współczynnik błędu (ang. *Missclassification Ratio* lub *Error Rate* (E_r)) – informuje, jaka część przewidywań modelu była błędna, a więc jest dopełnieniem dokładności:

$$E_r = \frac{FP + FN}{n}; \quad [8.2]$$

- precyzja (ang. *Precision*) – określa stosunek elementów poprawnie sklasyfikowanych do wyróżnionej klasy w proporcji do wszystkich epok, które zostały zaklasyfikowane jako ta klasa:

$$P = \frac{TP}{TP + FP}; \quad [8.3]$$

- czułość (ang. *Sensitivity* lub *Recall*) – określa, jaka część elementów została poprawnie sklasyfikowana do wyróżnionej klasy w stosunku do wszystkich elementów należących do tej klasy. W przypadku klasyfikacji binarnej czułość można interpretować jako prawdopodobieństwo wykrycia choroby u osoby chorej:

$$R = \frac{TP}{TP + FN}; \quad [8.4]$$

- swoistość (ang. *Specificity*) – należy ją interpretować jako prawdopodobieństwo zaklasyfikowania elementu do klasy odniesienia w stosunku do wszystkich elementów z tej klasy:

$$S = \frac{TN}{TN + FP}; \quad [8.5]$$

- miara Fishera (ang. *F-Score*) – łączy precyzję i czułość za pomocą średniej harmonicznej i umożliwia ocenę balansu pomiędzy tymi miarami:

$$F_{\beta} = \frac{(\beta^2 + 1) \cdot TP}{(\beta^2 + 1)TP + \beta^2 FN + FP}, \quad [8.6]$$

natomiast dla optymalnej i często stosowanej wartości $\beta=1$ miara ta oznaczana jest jako F_1 :

$$F_1 = \frac{2TP}{2TP + FN + FP} = \frac{2 \cdot P \cdot S}{P + S}; \quad [8.7]$$

- pole pod krzywą ROC (ang. *Area Under the Curve (AUC)*) – umożliwia ocenę zdolności klasyfikatora do unikania fałszywej klasyfikacji:

$$AUC = \frac{1}{2} \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right). \quad [8.8]$$

Tabela 8.2. Tablica pomyłek dla klasyfikacji wieloetykietowej (l klas)

		Stan rzeczywisty		
		Klasa $c_1 \dots c_{k-1}$	Klasa c_k	Klasa $c_{k+1} \dots c_l$
Wynik klasyfikacji	$c_{k+1} \dots c_l$	TN	FN	TN
	c_k	FP	TP	FP
	$c_1 \dots c_{k-1}$	TN	FN	TN

Zazwyczaj w klasyfikacji wieloetykietowej nie określa się klas jako wyróżnionych i odniesienia, natomiast miary TP, TN, FP i FN liczone są dla każdej klasy osobno, analogicznie jak w prezentowanej Tabeli 8.2. W ten sposób możliwe jest obliczenie powyższych miar dla każdej klasy analogicznie jak dla klasyfikacji binarnej, poprzez określenie jednej klasy jako wyróżnionej, a reszty jako klas odniesienia. Najbardziej podstawową miarą oceny klasyfikacji wieloetykietowej jest:

- trafność:

$$T_r = \frac{\sum_i^l TP_i}{n} \quad [8.9]$$

która określa ilości poprawnych klasyfikacji w każdej z klas w stosunku do n – całkowitej ilości epok w całym zbiorze danych. Ponadto możliwe jest obliczenie uśrednionych miary oceny jakości klasyfikacji zgodnie z poniższymi wzorami na dwa sposoby [294]. W pierwszym jest nią średnią tych samych miar, obliczonych dla poszczególnych klas (ang. *Macro-Averaging*):

- dokładność:

$$A_M = \frac{1}{l} \sum_i^l \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} = \frac{1}{l} \sum_i^l \frac{TP_i + TN_i}{n} = \frac{1}{l \cdot n} \sum_i^l (TP_i + TN_i) = A_\mu \quad [8.10]$$

- precyzja:

$$P_M = \frac{1}{l} \sum_i^l \frac{TP_i}{TP_i + FP_i} \quad [8.11]$$

gdzie l to liczba klas,

- czułość:

$$R_M = \frac{1}{l} \sum_i^l \frac{TP_i}{TP_i + FN_i}, \quad [8.12]$$

- miara F1:

$$F1_M = \frac{2 \cdot P_M \cdot R_M}{P_M + R_M}, \quad [8.13]$$

W drugim sposobie uśredniania sumowane są odpowiednie metryki z tablic pomyłek wszystkich klas l , a następnie obliczane są miary wydajności (ang. *Micro-Averaging*) [294]:

- dokładność:

$$A_\mu = \frac{\sum_i^l (TP_i + TN_i)}{\sum_i^l (TP_i + TN_i + FP_i + FN_i)} = \frac{\sum_i^l (TP_i + TN_i)}{l \cdot n} = A_M \quad [8.14]$$

- precyzja

$$P_\mu = \frac{\sum_i^l TP_i}{\sum_i^l (TP_i + FP_i)}, \quad [8.15]$$

- czułość:

$$R_\mu = \frac{\sum_i^l TP_i}{\sum_i^l (TP_i + FN_i)}, \quad [8.16]$$

- miara F1:

$$F1_\mu = \frac{2 \cdot P_\mu \cdot R_\mu}{P_\mu + R_\mu}, \quad [8.17]$$

W niniejszej pracy testowane będą modele klasyfikacji wieloetykietowej w obrębie trzech klas: NORM, OSA i CSA. Ocena wydajności kolejnych modeli klasyfikatora zostanie wykonywana poprzez zastosowanie 32-krotnej walidacji krzyżowej, opisanej szczegółowo w Rozdziale 8.3.1. Miarą, na podstawie której będą optymalizowane wybrane klasyfikatory, jest uśredniona dokładność klasyfikacji, oznaczana jako A_c , wybrana jako najbardziej ogólna, gdyż powyżej wykazano, że $A_M = A_\mu$. W ten sposób każdy klasyfikator, dla określonej wartości jego hiperparametru, będzie reprezentowany poprzez średnią dokładność klasyfikacji, obliczoną na podstawie tablicy pomyłek. W związku z tym, że każda epoka podczas walidacji skróśnej tylko raz trafia do zbioru testowego, zsumowane metryki tablic pomyłek ze wszystkich k zbiorów testowych walidacji skróśnej przedstawione będą w formie jednej, zbiorczej tablicy pomyłek, na podstawie której obliczone zostaną miary oceny jakości modelu: A_c , P_μ , oraz R_μ . Ponadto dla każdej z klas zostaną obliczone miary A_c , P i R , aby ocenić klasyfikację modelu w obrębie danej klasy.

8.2 Wybór klasyfikatora

Opisane w poprzednim podrozdziale metody klasyfikacji były stosowane w analizie sygnału EEG pochodzącego z badań nad snem. Wśród metod klasyfikacji stosowanych w zagadnieniu detekcji bezdechu sennego (głównie w badaniach nad bezdechem obturacyjnym) tylko na podstawie sygnału EEG stosowano: maszynę wektorów nośnych (SVM) [12], [124], [174], [181], [190], [287], [288], [308], [322], [343], metodę k -najbliższych sąsiadów (k -NN) [9], [35], [36], [121], [124], [190], [275], [276], [288], [322], sztuczne sieci neuronowe (ANN) [12], [188], [189], [308], [322], [324], konwolucyjne sieci neuronowe (CNN) [159], liniową analizę dyskryminacyjną (LDA) [12], [190], naiwny klasyfikator bayesowski (NB) [11], drzewa decyzyjne [124] i klasyfikator wzmacniający z losowym podpróbkiowaniem (ang. *Random Undersampling Boosting* (RUSBoost)), będący kombinacją klasyfikatorów wzmacniających potencjał uczenia się [31]. W innych badaniach sygnału EEG zarejestrowanego podczas snu, w tym w zadaniu rozpoznawania jego faz, kompleksów K i wzbudzeń, stosowane były również modele Markova, sieci neuronowe nienadzorowane (sieci Kohena), klasyfikator rozmyty, algorytm k -średnich i klasyfikator neurorozmyty [216].

Według najlepszej wiedzy autora, wszystkie znane prace dotyczące jednokanałowego EEG i badań nad bezdechem sennym dotyczyły klasyfikacji w obrębie dwóch klas, w celu rozróżnienia bezdechu obturacyjnego i normalnego [9], [35], [36],

[124], [159], [188], [249], [250], [251], [275], [276], [288], [308], [329], [342] lub rozróżnienia pacjentów z bezdechem i osób zdrowych [12], [31], [190], [181], [322], [343]. Oprócz prac autora dysertacji, [249], [250], [251], znane jest jedno badanie dotyczące analizy sygnału EEG, w których klasyfikacja bezdechu była wykonywana również w celu rozróżnienia jego typu, a więc była wykonana w obrębie trzech lub więcej klas, które opisano szerzej w podsumowaniu rozdziału [342].

Wysoką dokładność klasyfikacji bezdechu (między 85-99%) w obrębie dwóch klas uzyskano z zastosowaniem SVM [12], [124], [288], [322], [343], k-NN [121], [124], [275], [276], [288], [322], ANN [12], [322], CNN [159], LDA [11], i NB [12].

W celu zbadania efektywności klasyfikacji w obrębie trzech klas (NORM, OSA i CSA), wykorzystane zostaną metody wybrane na podstawie powyższej analizy:

- sztuczne sieci neuronowe (klasyczne, typu FFNN),
- metoda k-najbliższych sąsiadów (kNN),
- maszyna wektorów nośnych (SVM).

Klasyfikacja zostanie wykonana na danych wejściowych ze zbioru cech uzyskanego w wyniku ich ekstrakcji i selekcji (Rozdział 6 i 7). Dla każdego klasyfikatora zostanie dobrana optymalna jego struktura lub hiperparametry. Ocena klasyfikacji zostanie wykonana poprzez obliczenie tablicy pomyłek oraz A_c , P_μ i R_μ .

8.3 Rozpoznawanie epok EEG wybranymi klasyfikatorami

8.3.1 Ocena wydajności modeli klasyfikatorów

Ocena wydajności kolejnych modeli klasyfikatorów została wykonywana poprzez zastosowanie walidacji krzyżowej, która umożliwia wielokrotne sprawdzanie odpowiedzi klasyfikatora dla danych, na których nie był on uczony. Jest to istotne, ponieważ dokładność klasyfikacji modelu może zależeć od danych, które były wykorzystane podczas jego uczenia. Walidacja krzyżowa polega na podzieleniu zbioru danych na n podzbiorów, o mniej więcej równej ilości elementów, a następnie używaniu po kolei każdego z nich jako testujący wobec połączonych $n-1$ podzbiorów jako uczący. Następnie dla każdego uczenia i testowania modelu obliczana jest dokładność klasyfikacji, co na koniec umożliwia uzyskanie średniej wartości dokładności klasyfikacji wraz z jej odchyleniem standardowym.

W pracy wykorzystana została 32-krotna walidacja krzyżowa. Uzyskane podzbiory mają mniej więcej równą liczebność, po 128 lub 129 epok w każdym. Jest to dość duża liczba elementów, która jest kompromisem umożliwiającym uzyskanie dostatecznie dobrego uśrednienia statystycznego uzyskanych wyników poprzez 32-krotne testowanie modelu oraz znacznym skróceniem czasu obliczeń (w porównaniu do walidacji metodą *leave-one-out*) [75]. Następnie, jako podstawowy wskaźnik wydajności klasyfikatora o określonych hiperparametrach, wykorzystywana jest średnia dokładność i odchylenie standardowe klasyfikacji dla danych walidacyjnych. Uzyskane wyniki są zapamiętywane i następnie możliwe jest określenie optymalnych hiperparametrów modelu, które umożliwiają uzyskanie maksymalnej dokładności klasyfikacji.

8.3.2 Metoda k-najbliższych sąsiadów (k-NN)

Wybór ustawień k-NN, dzięki którym możliwe jest uzyskanie jak najlepszych wyników automatycznej klasyfikacji epok EEG w obrębie analizowanych klas, został przeprowadzony na podstawie optymalizacji enumeracyjnej o dwóch stopniach swobody. Optymalna metryka oraz liczba najbliższych sąsiadów (k od 3 do 150) były poszukiwane dla większościowej metody zaliczania do klasy.

Dodatkowym czynnikiem metody k-NN związanym z predykcją jest sposób rozstrzygnięcia przyporządkowania danych testowych do klasy, gdy ilość najbliższych sąsiadów z kilku klas jest taka sama. Wśród algorytmów rozstrzygnięcia remisu są: najmniejszy – wybiera tę klasę, która ma najmniejszy indeks; losowy – stosuje losowanie wśród klas, dla których ilość sąsiadów jest równa; lub najbliższy – wybiera tę klasę, której sąsiad jest najbliższym elementu. W związku z tym, wykonano porównanie wpływu typu algorytmu rozstrzygnięcia na średnią dokładność klasyfikacji dla jednej wybranej metryki (miejskiej). Ponieważ nie zaobserwowano różnicy w dokładności klasyfikacji, poszukiwanie suboptymalnych wartości ustawień k-NN zostało wykonane tylko dla sposobu przyporządkowania związanego z najbliższą odległością sąsiada od nowych danych.

Wśród metryk obliczania odległości pomiędzy elementami, gdzie W_i to element klasyfikowany reprezentowany przez wektor cech W , a T_i to element należący do zbioru uczącego, również reprezentowany przez wektor cech T , przetestowano klasyfikację dla 10 podstawowych metryk zdefiniowanych według poniższych wzorów, gdzie n jest wymiarem wektora cech [232], [246]:

- Minkowskiego (podczas klasyfikacji zastosowano wartość $p_i=3$):

$$d_M = \sqrt[p_i]{\sum_{i=1}^n |W_i - T_i|^{p_i}}, \quad [8.18]$$

- Czebyszewa, która jest równoznaczna z odległością Minkowskiego dla $p_i=\infty$:

$$d_C = \max_i \{|W_i - T_i|\}, \quad [8.19]$$

- miejskiej, będącą odległością Minkowskiego dla $p_i=1$:

$$d_m = \sum_{i=1}^n |W_i - T_i|, \quad [8.20]$$

- euklidesowej, która jest równoznaczna z odległością Minkowskiego dla $p_i=2$:

$$d_E = \sqrt{\sum_{i=1}^n |W_i - T_i|^2}, \quad [8.21]$$

- euklidesowej standaryzowanej, gdzie każda odległość między elementami wektorów W i T jest skalowana przez odchylenie standardowe danej cechy σ_c :

$$d_{ES} = \sqrt{\sum_{i=1}^n \left| \frac{W_i - T_i}{\sigma_c} \right|^2}, \quad [8.22]$$

- kosinusowej:

$$d_c = \left(1 - \frac{\sum_{i=1}^n W_i T_i}{\sqrt{\sum_{i=1}^n W_i^2} \sqrt{\sum_{i=1}^n T_i^2}} \right), \quad [8.23]$$

- korelacyjnej:

$$d_k = 1 - \frac{(W - \bar{W})(T - \bar{T})'}{\sqrt{(W - \bar{W})(W - \bar{W})'} \sqrt{(T - \bar{T})(T - \bar{T})'}}, \quad [8.24]$$

Gdzie \bar{W} i \bar{T} to wartości średnie,

- Spearmana [54]:

$$d_s = 1 - \frac{(r_w - \bar{r}_w)(r_t - \bar{r}_t)'}{\sqrt{(r_w - \bar{r}_w)(r_w - \bar{r}_w)'} \sqrt{(r_t - \bar{r}_t)(r_t - \bar{r}_t)'}}, \quad [8.25]$$

gdzie r_w i r_t są wektorami rang powiązanych z wektorami W i T ,


- Hamminga, która jest obliczana jako odsetek różniących się danych:

$$d_H = \sum_{i=1}^n 1_{w_i \neq t_i}, \quad [8.26]$$

- Jaccarda, obliczana jako procent niezerowych różniących się danych:


$$d_J = \frac{\sum_{i=1}^n (W_i - T_i)^2}{\sum_{i=1}^n W_i^2 + \sum_{i=1}^n T_i^2 - \sum_{i=1}^n W_i T_i} \quad [8.27]$$

Efekt przykładowej klasyfikacji z wykorzystaniem k-NN z metryką euklidesową i $k = 10$ dla trzech klas został przedstawiony na Rysunku 8.1. Kolorami zaznaczano elementy, należące do trzech różnych klas. Znakiem X został oznaczony nowy element, a okręgami jego najbliżsi sąsiedzi.



Rysunek 8.1. Efekt przykładowej klasyfikacji z wykorzystaniem k-NN z metryką euklidesową i $k = 10$ dla trzech klas [Źródło: [69]].

Wyniki poszukiwania optymalnych parametrów modelu k-NN dla 10 metryk obliczania odległości i ilości k od 3 do 150, z zastosowaniem 32-krotnej walidacji krzyżowej, przedstawiono na poniższym rysunku (Rysunek 8.2). Maksymalne wyniki średniej dokładności klasyfikacji wraz z odchyleniem standardowym oraz ilość k dla każdej z testowanych metryk przedstawiono w Tabeli 8.3.



Rysunek 8.2. Średnia dokładność klasyfikacji dla 10 metryk obliczania odległości i ilości k od 3 do 150.

Wśród uzyskanych wyników jest kilka podobnych (dla metryk: korelacyjnej, kosinusowej, miejskiej i euklidesowej standaryzowanej) o tej samej jakości statystycznej i ostatecznie jako suboptymalne hiperparametry k -NN wybrano metrykę euklidesową standaryzowaną i 47 najbliższych sąsiadów (w tabeli zaznaczone na niebiesko), która umożliwiła uzyskanie najwyższej dokładności klasyfikacji o średniej wartości 82,29%. W Tabeli 8.4 zaprezentowano tablicę pomyłek dla wybranego modelu k -NN. Dokładność klasyfikacji normalnego oddychania (NORM) wyniosła 100%, natomiast rozpoznanie typu bezdechu ponad 78% dla klasy OSA i 41% dla klasy CSA, co oznacza, że znaczna część epok tej klasy została zaklasyfikowana niewłaściwie, ale zgodnie z tablicą pomyłek wszystkie błędnie zaklasyfikowane epoki trafiły do klasy OSA.

Tabela 8.3. Najlepsza średnia dokładność klasyfikacji metodą k-NN dla wybranych metryk obliczania odległości oraz ilości najbliższych sąsiadów k .

Metryka odległości	Dokładność klasyfikacji A_c [%]	k
Hamminga	75,06	39
Jaccarda	75,06	39
Spearmana	79,56	127
Czebyszewa	81,53	34
Minkowskiego	81,66	25
euklidesowa	81,78	23
korelacyjna	82,00	7
kosinusowa	82,03	7
miejaska	82,05	20
euklidesowa standaryzowana	82,29	47

Tabela 8.4. Tablica pomyłek oraz ocena klasyfikacji wybranych modelu k-NN dla $k = 47$ i metryki euklidesowej standaryzowanej.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1373	0	0	100,00	100,00	100,00	82,29	73,44	73,44
OSA	0	1084	805	73,44	57,38	78,95			
CSA	0	289	568	73,44	66,28	41,37			

8.3.3 Maszyna wektorów nośnych (SVM)

Standardowa SVM jest klasyfikatorem binarnym, natomiast możliwe jest z jej zastosowaniem rozwiązanie problemu z wieloma klasami poprzez zastosowanie klasyfikacji, będącej serią połączonych problemów binarnych. Podstawowym parametrem SVM jest funkcja jądra, która umożliwia odwzorowanie zbioru uczącego w nową przestrzeń, często o większej liczbie wymiarów niż cech, która umożliwiłaby łatwiejsze rozdzielanie klas. Celem SVM jest potencjalne uproszczenie złożonych, nieliniowych granic pomiędzy klasami do liniowych w przestrzeni o większej liczbie wymiarów.

Poszukiwanie optymalnej struktury SVM wykonano dla trzech najbardziej popularnych funkcji jądra (k_l , k_g i k_p), gdzie W to wektor cech, a Y to wektor normalny do

hiperpłaszczyzny dającej maksymalny margines przy rozdzieleniu klas po transformacji [274], [301]:

- liniowej:

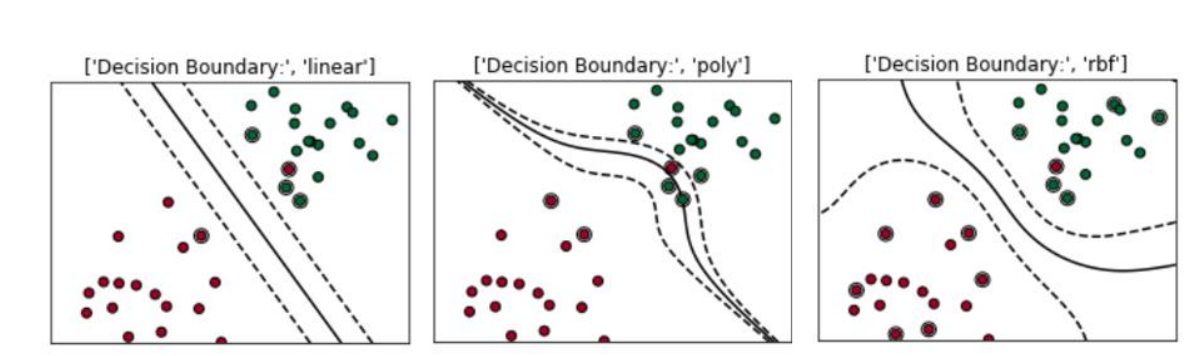
$$k_l = W^T Y, \quad [8.28]$$

- radialnej:

$$k_g = \exp \left\{ -\frac{\|W - Y\|^2}{2\sigma^2} \right\}, \quad [8.29]$$

- wielomianowej, gdzie p_w to stopień wielomianu:

$$k_p = (W^T Y + 1)^{p_w}. \quad [8.30]$$



Rysunek 8.3. Granica pomiędzy klasami dla funkcji jądra: liniowej, wielomianowej i radialnej w oryginalnej przestrzeni cech [źródło: [56]]. Linia ciągła wskazuje granicę decyzyjną pomiędzy klasami, a przerywana margines.

Dla każdej z wybranych funkcji jądra przetestowano klasyfikację dla generalizującego parametru C (ang. *Box Constrain*), który umożliwia kontrolę poprawnej i błędnej klasyfikacji w celu uniknięcia nadmiernego dopasowania modelu do danych (przeuczenia modelu) poprzez ograniczenie liczby wektorów nośnych. Natomiast dla jądra radialnego dodatkowym parametrem jest skala jądra (ang. *Kernel Scale*), która jest równoznaczna z wartością $2\sigma^2$ z jądra k_g . Dodatkowym parametrem dla funkcji wielomianowej jest rząd wielomianu p_w . Co więcej, przed wykonaniem klasyfikacji epoki zostały ustandaryzowane w celu uniknięcia ich wrażliwości na różnicę w skalach wartości poszczególnych cech [111]. Standaryzacja zbioru została wykonana poprzez odjęcie od zbiorów poszczególnych cech odpowiadającej im ważonej średniej oraz podzielenie przez

ważone odchylenie standardowe, zgodnie z poniższym wzorem, tak aby dana cecha ze wszystkich klas miała zerową średnią ważoną i ważone odchylenie standardowe równe 1:

$$W_w = \frac{W - \mu_w}{\sigma_w}, \quad [8.31]$$

gdzie μ_w to ważona średnia, a σ_w to ważone odchylenie standardowe, gdzie wagi zależą od ilości elementów w klasie, a W_w to zbiór po standaryzacji. W przypadku zbalansowanych klas (jak w tej pracy) wagi te nie mają znaczenia [111].

Klasyfikacja bezdechu w obrębie trzech klas została wykonana poprzez zastosowanie klasyfikacji wieloetykietowej, która dla SVM polega na rozłożeniu problemu na kilka klasyfikacji binarnych, gdzie ilość klasyfikatorów binarnych zależy od sposobu redukcji klasyfikacji do serii problemów binarnych poprzez zastosowanie wybranej strategii. Np. *One-vs-One* – w pojedynczym klasyfikatorze jedna klasa jest wyróżniona, druga odniesienia, a pozostałe są ignorowane, czyli nie uczestniczą w klasyfikacji, lub *One-vs-All* – dla binarnej SVM jedna klasa jest wyróżniona, a pozostałe odniesienia, a w klasyfikacji wykorzystane jest tyle klasyfikatorów binarnych ile klas, aby każda z nich w jednym była klasą wyróżnioną,


Optymalizacja trójetykietowej klasyfikacji z wykorzystaniem SVM z zastosowaniem serii klasyfikacji binarnych została wykonana z zastosowaniem funkcji `fitcecoc` programu Matlab poprzez poszukiwanie jej hiperparametrów, umożliwiających uzyskanie najwyższej dokładności klasyfikacji.

Ponieważ we wcześniejszych badaniach nie stwierdzono przewagi jednej z możliwych funkcji jądra, a wydajność SVM dla konkretnego zadania może różnić się w zależności od jej wyboru [168], w pracy przetestowano 3 funkcje jądra: liniową, radialną i wielomianową dla $p_w=2$ i $p_w=3$. Optymalne wartości parametru C oraz skali jądra (dla funkcji radialnej) były poszukiwane w dwóch krokach, początkowo spośród następujących wartości zgrubnych: 10^{-5} , 10^{-4} , 10^{-3} , 10^{-2} , 10^{-1} , 1, 10, 10^2 , 10^3 , 10^4 , 10^5 , 10^6 , 10^7 , a następnie z mniejszym krokiem w pobliżu tych wartości, które umożliwiły uzyskanie maksymalnej dokładności klasyfikacji, poprzez pomnożenie ich przez następujące parametry skalujące: 0,2; 0,4; 0,6; 0,8; 1; 2; 4; 6; 8. Wyniki klasyfikacji dla różnych funkcji jądra i ich parametrów zostały przedstawione w Tabeli 8.5 oraz na Rysunkach 8.4, 8.5 i 8.6. W związku z tym, że dla parametru $p_w=3$ dokładność klasyfikacji jest bardzo niska, nie


sprawdzano zdolności klasyfikacyjnych dla większych wartości parametru p_w . Poszukiwanie suboptymalnej wartości parametru $2\sigma^2$ dla funkcji radialnej wykonane było w zakresie od 10^{-5} do 10^7 (wyniki na Rysunku 8.4), natomiast w Tabeli 8.5. zaprezentowana została średnia dokładność klasyfikacji dla dwóch wartości skali jądra (10 i 100), ponieważ dla wartości 10 jako pierwszej zaobserwowano dokładność klasyfikacji około 60%, a dla wartości większych od 100 średnia dokładność jest większa od 70%. Najwyższe dokładności klasyfikacji dla poszczególnych funkcji zostały w tabeli zaznaczone na niebiesko. Po analizie powyższych wartości, ponowne, dokładniejsze poszukiwanie suboptymalnych parametrów zostało wykonane dla funkcji radialnej dla wartości C od 0,2 do 80 i skali jądra od 2 do 80 (wyniki optymalizacji są przedstawione na Rysunku 8.5) oraz dla funkcji wielomianowej o $p_w=2$ dla wartości C (2^{-6} , 4^{-6} , 6^{-6} , 8^{-6} , 1^{-5} , 6^{-6})

Tabela 8.5. Dokładność klasyfikacji z wykorzystaniem trójetykietowej SVM dla różnych funkcji jądra i różnych wartości parametru C .


Parametr C	Średnia dokładność A_c [%]				
	Funkcja jądra				
	liniowa	radialna $2\sigma^2=10$	radialna $2\sigma^2=100$	wielomianowa $p_w=2$	wielomianowa $p_w=3$
10^{-5}	79,74	66,45	77,09	82,81	58,08
10^{-4}	81,37	72,34	74,72	82,69	58,08
10^{-3}	81,71	71,80	71,32	81,67	58,08
10^{-2}	82,03	71,83	71,75	81,67	58,08
10^{-1}	81,62	76,49	81,03	81,67	58,08
1	81,48	82,60	81,53	81,67	58,08
10	81,62	82,08	81,97	81,67	58,08
10^2	78,03	82,08	82,31	81,67	58,08
10^3	78,58	82,08	82,52	81,67	58,08
10^4	78,58	82,08	82,01	81,67	58,08
10^5	78,58	82,08	81,69	81,67	58,08
10^6	78,58	82,08	81,69	81,67	58,08
10^7	78,58	82,08	81,69	81,67	58,08




Rysunek 8.4. Średnia dokładność trójetykietowej SVM dla funkcji radialnej, różnych wartości parametru C oraz skali jądra.



Rysunek 8.5. Średnia dokładność trójetykietowej SVM dla funkcji radialnej dla różnych wartości parametru C oraz skali jądra wokół modelu o maksymalnej dokładności klasyfikacji ze wstępnej optymalizacji.



Rysunek 8.6. Średnia dokładność trójetykietowej SVM dla funkcji liniowej i wielomianowej $p_w=2$ dla różnych wartości parametru C .



Rysunek 8.7. Średnia dokładność trójetykietowej SVM dla wielomianowej $p_w=2$ dla różnych wartości parametru C wokół modelu o maksymalnej dokładności klasyfikacji ze wstępnej optymalizacji.

Wysoką dokładność klasyfikacji wynoszącą powyżej 70% uzyskano dla każdej z testowanych funkcji jądra. W Tabeli 8.6 i 8.7 przedstawiono tablicę pomyłek i obliczone miary wydajności dla wybranych modeli trójetykietowej SVM z funkcją radialną i wielomianową. Najwyższą całkowitą dokładność klasyfikacji o wartości 83,26% uzyskano stosując SVM z radialną funkcją bazową i $2\sigma^2 = 40$ i parametrze $C = 20$ oraz 83,05% dla funkcji wielomianowej o $p_w = 2$ i $C = 2^{-5}$.

Tabela 8.6. Tablica pomyłek oraz ocena klasyfikacji wybranego modelu SVM dla funkcji radialnej i $C = 20$ oraz $2\sigma^2 = 40$.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1372	0	0	99,98	100,00	99,93	83,26	74,90	74,90
OSA	0	859	519	74,92	62,34	62,56			
CSA	1	514	854	74,90	62,38	62,20			

Tabela 8.7. Tablica pomyłek oraz ocena klasyfikacji wybranego modelu SVM dla funkcji wielomianowej o $p_w = 2$ i $C = 2^{-5}$.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1371	0	0	99,95	100,00	99,85	83,05	74,58	74,58
OSA	1	895	567	74,61	61,18	65,19			
CSA	1	478	806	74,61	62,72	58,70			

8.3.4 Jednokierunkowe sztuczne sieci neuronowe

Typem sieci neuronowych często wykorzystywanym do analizy sygnału EEG pochodzącego z badań nad snem, w tym również diagnostyki bezdechu sennego, jest jednokierunkowa sieć neuronowa (FFNN), nazywana również złożonym perceptronem [10], [12], [188], [322]. Poszukiwanie optymalnej struktury oraz hiperparametrów sieci neuronowej można podzielić na następujące etapy: wybór architektury (czyli ilości warstw ukrytych oraz liczby neuronów w warstwach), algorytmu uczącego, funkcji aktywacji neuronów i ilości epok uczenia oraz metody obliczania błędu sieci neuronowej [271].

W badaniach nad sygnałem EEG w czasie snu, w których wykorzystano do rozwiązania zadania klasyfikacji sieć neuronową, najczęściej wykorzystywane było nadzorowane uczenie z algorytmem propagacji wstecznej, polegającym na obliczeniu gradientu funkcji strat w celu przeprowadzenia optymalizacji wag sieci we wszystkich warstwach. Obliczanie nowych, skorygowanych wartości wag realizowane jest w kierunku ujemnego gradientu funkcji strat od warstwy wyjściowej do wejściowej [271], [305]. Wśród typów algorytmu propagacji wstecznej wykorzystanych w badaniach nad sygnałem EEG można wyróżnić: metodę największego spadku (ang. *Gradient Steepest Descent* (GD)) [188], metodę skalowanego gradientu sprzężonego (ang. *Scaled Conjugate Gradient* (SCG)) [258] i algorytm Levenberga-Marquardta (LM) [10].

W celu wyboru algorytmu uczenia sieci neuronowej wykorzystanego do poszukiwania optymalnej struktury sieci wykonano porównanie wyników uczenia sieci z zastosowaniem trzech algorytmów uczących: GD (funkcja `traingd`), SCG (funkcja `trainscg`) oraz LM (funkcja `trainlm`) o początkowej wartości parametru regularyzacji $\lambda=0,001$. W tym celu porównano czas uczenia i średnią dokładność A_c algorytmów, oraz sprawdzono wartość wyjściową parametru λ metody LM. Uczenie sieci wybranymi algorytmami zostało wykonane dla struktury sieci neuronowej o dwóch warstwach ukrytych o 17+7 neuronach i logarytmiczno-sigmoidalnej funkcji aktywacji (log-sig) oraz warstwy wyjściowej z liniową funkcją aktywacji, która była wybrana jako suboptymalna we wcześniejszej pracy autora nad detekcją bezdechu sennego na podstawie EEG [249] oraz funkcją softmax, która jest również często wykorzystywana funkcją aktywacji warstwy wyjściowej. Wektor cech, wcześniej podzielony na 32 podzbiory do walidacji krzyżowej, został wykorzystany do utworzenia wstępnego zbioru uczącego, walidacyjnego i testującego w przybliżonych proporcjach: 0,7:0,15:0,15. Odpowiada to ilości połączonych podzbiorów: 22:5:5 oraz liczbie epok 2837, 642 i 640 kolejno w zbiorze uczącym, walidacyjnym i testującym. Wyniki średniej dokładności dla zbioru testowego to 66,7%, 72,5% i 75%, a czas uczenia wyniósł ponad 16 s, 1 s i 659 s kolejno dla GD, SCG i LM dla funkcji liniowej w warstwie wyjściowej. Natomiast dla funkcji softmax w warstwie wyjściowej uzyskano 67,3%, 73,7% i 76% dokładności, a czas uczenia wyniósł ponad 15 s, 1 s i 713 s, odpowiednio dla GD, SCG i LM.


Następnie poszukiwanie suboptymalnej architektury sieci neuronowej zostało wykonane z zastosowaniem algorytmu uczącego SCG, ponieważ dla tego algorytmu czas

uczenia sieci był około 700 razy krótszy niż dla innych algorytmów uczących, a dokładność klasyfikacji niższa niż dla LM. Poszukiwanie suboptymalnej architektury sieci zostało wykonane dla jednej warstwy ukrytej z funkcją radialną oraz dwóch warstw ukrytych z log-sigmoidalnymi funkcjami aktywacji [249], które zgodnie z teorią są wystarczające, po spełnieniu koniecznych warunków, aby aproksymować dowolne odwzorowanie [76]. Natomiast w warstwie wyjściowej wykorzystano funkcję softmax, która umożliwia oszacować prawdopodobieństwa przynależności do klas. Wybór ilości neuronów w warstwach ukrytych zrealizowano etapami. W I etapie ilość neuronów w obu warstwach była zmieniana jednocześnie od 10 do 100 z krokiem co 10. Następnie w okolicy tej liczby neuronów w warstwach ukrytych (± 10 neuronów), dla których uzyskano wysoki wynik dokładności, ilość neuronów była zwiększana z krokiem co 1. Liczba neuronów w warstwie wejściowej odpowiada ilości cech, a w wyjściowej ilości klas. Zabezpieczenie przed przeuczeniem sieci zostało osiągnięte z zastosowaniem 32-krotnej walidacji krzyżowej dla tego samego podziału danych na zbiór uczący i testujący jak dla metod k-NN i SVM, z tym, że za każdym razem ze zbioru uczącego był wybrany jeden podzbiór, o kolejnym indeksie w stosunku do aktualnego zbioru testującego, jako walidacyjny. Wagi i progi sieci neuronowej były inicjalizowane losowo przed każdym uczeniem sieci. W związku z tym, że na podstawie wcześniej wykonanych testów, spodziewana dokładność sieci wynosi ponad 75%, w każdym kroku inicjalizacja wag i progów była wykonywana tyle razy, aż uzyskano dokładność klasyfikacji większą od 75% (z dodatkowym warunkiem, że ilość inicjalizacji nie przekroczy 30).


A. Sieć jednowarstwowa

Wyniki I etapu poszukiwania optymalnej struktury sieci jednowarstwowej: średnia dokładność klasyfikacji oraz średni błąd średniokwadratowy dla zbiorów walidacyjnych zostały zaprezentowane na Rysunku 8.8. Najwyższą średnią dokładność klasyfikacji 81,50% oraz najniższy średni błąd $MSE_{V_{st}}=0,106$ dla zbioru walidacyjnego uzyskano dla sieci o 10 neuronach w warstwie ukrytej. W związku z tym poszukiwanie optymalnej struktury zostało powtórzone dla 1 do 20 neuronów w warstwie ukrytej z krokiem co 1, a wyniki zaprezentowano na Rysunku 8.9. Najwyższą średnią dokładność klasyfikacji 81,36% uzyskano ponownie dla sieci o 10 neuronach. W związku z tym dla tej struktury sieci zostało wykonane uczenie z zastosowaniem dwóch pozostałych algorytmów uczących: GD i LM z analogicznym powtarzaniem inicjalizacji wag. Struktura optymalnej


sieci jest przedstawiona na Rysunku 8.10, a tablice pomyłek wraz z obliczonymi miarami oceny klasyfikacji dla trzech algorytmów uczących zostały zaprezentowane w Tabelach 8.8, 8.9 i 8.10.



Rysunek 8.8. Średnia dokładność trójetykietowej, jednowarstwowej sieci neuronowej o radialnej funkcji aktywacji w warstwach ukrytych, funkcji softmax w warstwie wyjściowej oraz dla algorytmu uczącego SCG.



Rysunek 8.9. Średnia dokładność trójetykietowej, jednowarstwowej sieci neuronowej o radialnej funkcji aktywacji, neuronów w warstwach ukrytych od 1-20, funkcji softmax w warstwie wyjściowej oraz dla algorytmu uczącego SCG.



Rysunek 8.10. Suboptymalna architektura sieci neuronowej o 10 neuronach w warstwie ukrytej.

Tabela 8.8. Tablica pomyłek oraz ocena klasyfikacji dla modelu ANN o 10 neuronach w warstwie ukrytej, radialnej funkcji aktywacji, z uczeniem SCG.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1373	0	0	100,00	100,00	100,00	81,50	72,25	72,25
OSA	0	860	630	72,25	57,72	62,64			
CSA	0	513	743	72,25	59,16	54,12			

Tabela 8.9. Tablica pomyłek oraz ocena klasyfikacji modelu ANN o 10 neuronach w warstwie ukrytej, radialnej funkcji aktywacji i z uczeniem GD.


Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1373	0	0	100,00	100,00	100,00	80,79	71,18	71,18
OSA	0	856	670	71,18	56,09	62,35			
CSA	0	517	703	71,18	57,62	51,20			

Tabela 8.10. Tablica pomyłek oraz ocena klasyfikacji modelu ANN o 10 neuronach w warstwie ukrytej, radialnej funkcji aktywacji i z uczeniem LM.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1365	17	15	99,03	97,71	99,42	80,17	70,26	70,26
OSA	6	764	593	70,67	56,05	55,64			
CSA	2	592	765	70,82	56,29	55,72			


B. Sieć dwuwarstwowa

Wyniki I etapu poszukiwania optymalnej struktury sieci dwuwarstwowej: średnią dokładność klasyfikacji oraz średni błąd średniokwadratowy dla zbiorów walidacyjnych zostały zaprezentowane na Rysunku 8.11. Najwyższą średnią dokładność klasyfikacji 81,16% oraz najniższy średni błąd $MSE_{Vsr}=0,105$ uzyskano dla sieci o 20 neuronach w dwóch warstwach ukrytych.




Rysunek 8.11. Średnia dokładność trójetykietowej, dwuwarstwowej sieci neuronowej o log-sig funkcji aktywacji w warstwach ukrytych, funkcji softmax w warstwie wyjściowej oraz dla algorytmu uczącego SCG.

W związku z tym poszukiwanie optymalnej ilości neuronów w warstwach ukrytych zostało powtórzone od 10 do 30 neuronów z krokiem co 1, a wyniki zaprezentowano na Rysunku 8.12. Najwyższą średnią dokładność klasyfikacji 81,36% uzyskano dla sieci o 14+14 neuronach w warstwach ukrytych. W związku z tym dla tej struktury sieci zostało wykonane uczenie z zastosowaniem dwóch pozostałych algorytmów uczących GD i LM, z analogicznym powtarzaniem inicjalizacji wag. Struktura optymalnej sieci jest przedstawiona na Rysunku 8.13, a tablice pomyłek wraz z obliczonymi miarami oceny klasyfikacji dla trzech algorytmów uczących zostały zaprezentowane w Tabelach 8.11, 8.12 i 8.13.



Rysunek 8.12. Średnia dokładność trójetykietowej, dwuwarstwowej sieci neuronowej o log-sig funkcji aktywacji, od 10-30 neuronów w warstwach ukrytych, funkcji softmax w warstwie wyjściowej oraz dla algorytmu uczonego SCG.



Rysunek 8.13. Suboptymalna architektura sieci neuronowej o 14+14 neuronach w dwóch warstwach ukrytych.

Tabela 8.11. Tablica pomyłek oraz ocena klasyfikacji modelu ANN o 14+14 neuronach w warstwach ukrytych i z uczeniem SCG.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1373	0	0	100,00	100,00	100,00	81,35	72,03	72,03
OSA	0	882	661	72,03	57,16	64,24			
CSA	0	491	712	72,03	59,19	51,86			

Tabela 8.12. Tablica pomyłek oraz ocena klasyfikacji modelu ANN o 14+14 neuronach w warstwach ukrytych i z uczeniem GD.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1373	0	0	100,00	100,00	100,00	80,56	70,84	70,84
OSA	0	846	674	70,84	55,66	61,62			
CSA	0	527	699	70,84	57,01	50,91			

Tabela 8.13. Tablica pomyłek oraz ocena klasyfikacji modelu ANN o 14+14 neuronach w warstwach ukrytych i z uczeniem LM.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_{sr}	P_μ	R_μ
NORM	1373	0	0	100,00	100,00	100,00	82,25	73,37	73,37
OSA	0	807	531	73,37	60,31	58,78			
CSA	0	566	842	73,37	59,80	61,33			

C. Sieć wielowarstwowa (MLP)

Jedną z architektur sieci z uczeniem głębokim jest sieć typu wielowarstwowy perceptron (MLP), składającej się z większej ilości warstw ukrytych niż dwie. Dwuwarstwową sieć o 14+14 neuronach rozszerzono do sieci z trzema, czterema i pięcioma warstwami ukrytymi o tej samej liczbie neuronów (14). Uczenie sieci zostało wykonane z wykorzystaniem algorytmu uczącego LM, który dotąd dał najwyższą dokładność. Uzyskana średnia dokładność klasyfikacji dla sieci wielowarstwowej była niższa niż dla dwuwarstwowej architektury. Wyniki klasyfikacji zostały przedstawione w Tabeli 8.14, 8.15 i 8.16.

Tabela 8.14. Tablica pomyłek oraz ocena klasyfikacji modelu ANN o 14+14+14 neuronach w warstwach ukrytych i z uczeniem LM.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1373	1	0	99,98	99,93	100,00	81,79	72,69	72,69
OSA	0	813	565	72,69	59,00	59,21			
CSA	0	559	808	72,71	59,11	58,85			

Tabela 8.15. Tablica pomyłek oraz ocena klasyfikacji modelu ANN o 14+14+14+14 neuronach w warstwach ukrytych i z uczeniem LM.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1373	0	0	100,00	100,00	100,00	81,71	72,57	72,57
OSA	0	819	576	72,57	58,71	59,65			
CSA	0	554	797	72,57	58,99	58,05			

Tabela 8.16. Tablica pomyłek oraz ocena klasyfikacji modelu ANN o 14+14+14+14+14 neuronach w warstwach ukrytych i z uczeniem LM.

Tablica pomyłek				Ocena klasyfikacji [%]					
				w klasach			uśredniona		
	NORM	OSA	CSA	A_i	P_i	R_i	A_c	P_μ	R_μ
NORM	1373	1	3	99,90	99,71	100,00	80,80	71,21	71,21
OSA	0	701	511	71,28	57,84	51,06			
CSA	0	671	859	71,23	56,14	62,56			

8.4 Podsumowanie

Celem rozdziału było porównanie wybranych klasyfikatorów, ocena jakości klasyfikacji wykonanej za ich pomocą na podstawie wyselekcjonowanych cech oraz wybór metody, która umożliwiła uzyskanie najwyższej dokładności klasyfikacji w obrębie trzech klas: NORM, OSA i CSA. Porównano trzy wybrane klasyfikatory: k-NN, SVM i ANN. Dla każdego przypadku poszukiwano suboptymalnego modelu klasyfikatora. Każdy z ocenianych klasyfikatorów umożliwił uzyskanie średniej dokładności klasyfikacji trójetykietowej powyżej 82%: 82,29%, 83,26% i 82,25% kolejno dla k-NN z metryką standaryzowaną euklidesową i $k = 47$, SVM z radialną funkcją bazową, $2\sigma^2 = 40$ i $C = 20$ oraz jednokierunkowej ANN o 14+14 neuronach w dwóch warstwach ukrytych, o log-sig funkcji aktywacji, z zastosowania uczenia algorytmem LM. W tabeli poniżej przedstawiono średnią dokładność klasyfikacji i odchylenie standardowe z wyników walidacji krzyżowej, dla których wykonano dwustronny test t -Studenta na równość średnich. Na podstawie wykonanych testów można zaobserwować brak istotnej

statystycznie różnicy pomiędzy średnią dokładnością poszczególnych klasyfikatorów i w związku z tym wyniki uzyskane z zastosowaniem tych metod są porównywalne.

Tabela 8.17. Porównanie średniej dokładności klasyfikacji dla trzech najlepszych modeli klasyfikatorów.

	kNN	SVM	ANN
średnia ± odchylenie standardowe	82,29±2,29 _{a,b}	83,27±2,62 _{a,c}	82,25±2,80 _{b,c}

Test dwustronny:

a. brak istotnie statystycznie różnicy (wartość $p_t=0,1192$)

b. brak istotnie statystycznie różnicy (wartość $p_t = 0,9382$)

c. brak istotnie statystycznie różnicy (wartość $p_t = 0,1374$)

Średnia czułość oraz precyzja klasyfikacji dla wszystkich klasyfikatorów wyniosła między 73% a 75%. Porównując tablice pomyłek badanych klasyfikatorów można zauważyć, że epoki NORM zostały bezbłędnie rozróżnione od epok bezdechu dla k-NN i ANN oraz z dokładnością 99,98% dla SVM. Natomiast czułość i precyzja detekcji epok z klas OSA i CSA wynosi od 55% do 66%, a przypadki błędnej klasyfikacji dotyczą tylko typu bezdechu. Najbardziej równomierną precyzję i czułość klasyfikacji typu bezdechu uzyskano dla SVM i wynosiła ona 62%. W związku z tym, na podstawie uzyskanych wyników można wnioskować, że dzięki właściwej ekstrakcji i selekcji cech możliwa jest bezbłędna lub prawie bezbłędna detekcja epok z bezdechem w rozróżnieniu od normalnego oddychania tylko na podstawie jednokanałowego sygnału EEG, natomiast aby poprawić precyzję rozróżniania typu bezdechu, powinny zostać przeprowadzone dalsze badania (np. selekcja innego zestawu cech, uwzględnienie dodatkowych kanałów EEG lub innych sygnałów fizjologicznych z polisomnografii). Wyniki te świadczą zatem o bardzo wysokim potencjale różnicującym wektora cech, który został wyekstrahowany i wyselekcjonowany w Rozdziałach 6 i 7.

Wszystkie znane prace, w których uzyskana dokładność klasyfikacji wynosiła powyżej 84%, dotyczyły klasyfikacji w obrębie dwóch klas: rozróżnienia epok bezdechu od normalnego oddychania [12], [121], [275], [288], [322], [343]. Po zakończeniu badań przedstawionych w tym rozdziale pojawił się artykuł [342], odnoszący się do prac autora [250], [251], w którym wykonane zostało rozpoznawanie epok w obrębie trzech klas: NORM, OSA i CSA z dwóch kanałów EEG (C3-A2 i C4-A1). Uzyskana w tej pracy

dokładność klasyfikacji 88,99% jest wyższa niż w zaprezentowanych w tym rozdziale badaniach i potwierdza hipotezę z badań autora [250], [251], że wykorzystanie dwóch kanałów EEG może zwiększyć dokładność klasyfikacji bezdechu tylko na podstawie sygnału EEG. Tym niemniej należy nadmienić, że Zhao i in. wykorzystali inną bazę danych, a klasyfikacja została wykonana dla nie zrównoważonych klas z korzyścią dla dobrze rozpoznawanego NORM (NORM: 1418, OSA: 1229 i CSA: 812 epok), co musiało się przełożyć na wzrost uzyskanej dokładności. Zastosowano też inne metody przetwarzania wstępnego, ekstrakcji i selekcji cech. Dwa spośród analizowanych tam klasyfikatorów: k-NN i SVM były testowane w bieżącym rozdziale i dla kNN uzyskano dokładność niższą o 3%, natomiast dla SVM wyższą o 14%. Trzeci z klasyfikatorów, dla którego Zhao i in. uzyskali najwyższą dokładność klasyfikacji, to lasy losowe (ang. *Random Forest* (RF)), które nie zostały uwzględnione przez autora dysertacji [342].

Rozdział 9

Podsumowanie i wnioski

9.1 Rozwiązywany problem naukowy, cel i teza pracy

Punktem wyjścia badań objętych niniejszą pracą był zidentyfikowany wcześniej problem naukowy, polegający na braku systematycznej analizy stosowanych dotąd metod wykrywania bezdechu sennego w oparciu o epoki jednokanałowego EEG z wykorzystaniem ekstrakcji i selekcji charakteryzujących je cech oraz uczenia maszynowego, pozwalającej na wybór spośród nich optymalnych rozwiązań na każdym z etapów przetwarzania sygnału oraz ocenę, czy można w ten sposób uzyskać poprawę dokładności automatycznego rozpoznawania bezdechu sennego i jego różnicowania. Ponadto wszystkie publikowane prace z tego obszaru dotyczyły klasyfikacji binarnej na bezdech lub normalne oddychanie, z pominięciem różnicowanie typu bezdechu na obturacyjny i centralny, co ma duże znaczenie medyczne, gdyż są to rozdzielne schorzenia.

Wychodząc z wyżej sformułowanego problemu sformułowano **cel pracy**, polegający na zaproponowaniu takiej 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 i ostatecznie będzie się charakteryzować lepszą dokładnością ich rozpoznawania niż metody dotąd publikowane.

U podstaw prezentowanych badań leżała **hipoteza**, że odpowiedni dobór metod przetwarzania jednokanałowego sygnału EEG na poszczególnych etapach: przetwarzania wstępnego, ekstrakcji i selekcji cech, oraz uczenia maszynowego pozwoli na uzyskanie dokładności automatycznego rozróżniania między bezdechem sennym a normalnym oddychaniem oraz różnicowania typu bezdechu większej, niż uzyskano w dotychczasowych badaniach.

9.2 Podsumowanie i wyniki zrealizowanych prac

Na początku dysertacji (Rozdziały 2 i 3) zaprezentowano wyniki przeglądu literatury dotyczący badań nad zaburzeniami oddychania podczas snu, w szczególności tych, w których analizowano zastosowanie sygnału EEG w detekcji bezdechu nocnego,

a w dalszej części pracy przedstawiono wykonane przez autora rozprawy badania nad optymalizacją metody analizy całonocnego zapisu jednokanałowego sygnału EEG, umożliwiającej automatyczne wykrywanie epizodów bezdechu sennego oraz częściowe rozróżnienie ich typu: obturacyjnego lub centralnego – jedynie na podstawie tego sygnału.

W pracy zastosowano następującą metodologię: po przeglądzie literatury wybrano bazę danych (Rozdział 4) i wstępnie przetworzono sygnały EEG zarejestrowane podczas snu tak, aby możliwe było wykonanie kolejnych etapów ich analizy. Na każdym etapie przetestowano kilka metod wyselekcjonowanych na podstawie przeglądu literaturowego, a w efekcie wybrano suboptymalne dla danych EEG wykorzystywanych w badaniach rozwiązanie z zakresu: przetwarzania wstępnego (Rozdział 5), ekstrakcji cech (Rozdział 6), ich selekcji (Rozdział 7) oraz klasyfikacji (Rozdział 8). Wybór metod na pierwszych etapach został wykonany z wykorzystaniem oceny dokładności tego samego klasyfikatora (k-NN) oraz poprzez statystyczne porównanie uzyskiwanej dokładności klasyfikacji dla różnych testowanych metod. Wszystkie obliczenia związane z analizą sygnałów EEG wykonano w środowisku obliczeń naukowo-technicznych Matlab.

Analizy sygnału EEG przeprowadzono na jednokanałowych sygnałach z lokacji elektrod C3-A2 zgromadzonych w ogólnodostępnej i szeroko stosowanej bazie danych *University College Dublin Sleep Apnea Database* dostępnej na portalu *PhysioNet*, zawierającej zapisy z całonocnego badania polisomnograficznego (w tym EEG), zebrane spośród 25 osób z podejrzeniem zaburzeń oddychania podczas snu oraz opisane przez ekspertów medycznych za pomocą etykiet. Podczas przetwarzania wstępnego zdecydowano się ostatecznie na zastosowanie następujących metod:

- usuwania wysycień oraz nadmiernych amplitud,
- filtracji dolnoprzepustowej,
- standaryzacji sygnału EEG.
- podziału sygnału na 30-sekundowe epoki i ich podział na klasy.

Ponieważ w pracy badano nie tylko automatyczne rozróżnianie między bezdechem sennym a normalnym oddychaniem, ale też między bezdechem obturacyjnym i centralnym, epoki w liczbie 4119 zostały podzielone na trzy zbalansowane klasy: 1 – normalne oddychanie (NORM), 2 – bezdech/spłycenie obturacyjne (OSA), 3 – bezdech/spłycenie centralne

(CSA), z których dwie ostatnie tworzą superklasę bezdechu (APNEA). Ilość epok w każdej z nich wynosiła 1373.

Podczas ekstrakcji cech zdecydowano się wykorzystać kilka jednoetapowych metod dekompozycji sygnałów na składowe:

- filtrację pasmowoprzepustową (BPF),
- dyskretną transformację falkową (DWT),
- dekompozycję empiryczną (EMD),
- dekompozycję wariacyjną (VMD)

i dwuetapowych:

- transformację Hilberta-Huanga (HHT: EMD i HT),
- dyskretną transformację falkową z transformacją Hilberta (DWT i HT),
- dekompozycję wariacyjną z transformacją Hilberta (VMD i HT).

Dla każdego z uzyskanych po dekompozycji komponentów obliczono 9 cech skalarnych: skośność, kurtozę, medianę, aktywność (wariancję), proporcję wariancji do sumy wariancji wszystkich sygnałów, mobilność, złożoność, entropię Shanona i maksymalną amplitudę. W efekcie, dla każdej przeanalizowanej metody dekompozycji, uzyskano wektory o różnej ilości cech (od 45 do 351).

Następnym etapem była selekcja uzyskanych cech w celu uzyskania suboptymalnego ich podzbioru, który umożliwiłby efektywne różnicowanie w obrębie klas. Przetestowano kilka metod selekcji, z których ostatecznie jako najefektywniejszą wybrano metodę ReliefF i wykorzystano ją do selekcji cech osobno z każdego zbioru uzyskanego wspomnianymi metodami ekstrakcji. Uzyskane podzbiory zostały połączone w zbiór całościowy o wymiarze 520 cech, dla którego ponownie wykonano selekcję metodą ReliefF. Jej wynikiem jest końcowy zbiór różnicujący złożony z 387 cech, z których większość uzyskano z dekompozycji metodą HHT (66,41%) oraz DWT+HT (14,99%).

Uzyskany po selekcji wektor cech został wykorzystany do badania i optymalizacji następujących klasyfikatorów: k-NN, SVM i jednokierunkowe ANN. Ocenę dokładności klasyfikatorów wykonano poprzez zastosowanie 32-krotnej walidacji krzyżowej. Wśród testowanych klasyfikatorów, każdy umożliwił 100% lub prawie 100% dokładność rozróżnienia pomiędzy klasą NORM a bezdechem, bez względu na jego typ. Czulość

i precyzja dla klasy NORM wyniosły od 99,98% dla SVM do 100% dla k-NN i dwuwarstwowej ANN. Dokładność klasyfikacji trójetykietowej jest porównywalna dla każdego z klasyfikatorów i wynosi powyżej 82%, kolejno 82,29%, 83,27% i 82,25% dla k-NN, SVM i ANN, co jest lepszym wynikiem niż w dotychczasowych pracach (77,27% [249], 63,82% [250]). Średnia czułość oraz precyzja klasyfikacji dla wszystkich klasyfikatorów wyniosła między 73% a 75%. W klasyfikacji trójetykietowej błędna klasyfikacja epok w 96,9% dotyczyła typu bezdechu, czyli OSA zaklasyfikowane jako CSA i odwrotnie, a najbardziej równomierną precyzję i czułość klasyfikacji typu bezdechu uzyskano dla SVM (62%).

9.3 Oryginalność rozwiązania problemu naukowego

Na podstawie przeglądu literaturowego przedstawionego w Rozdziale 3 oraz Rozdziałach 5.2, 6.2, 7.2 i 8.2 można stwierdzić, że do oryginalnych osiągnięć autora rozprawy należą:

- Opracowanie metody przetwarzania wstępnego sygnału EEG polegającej na usunięciu wysycień oraz nadmiernych amplitud oraz jej połączenie z filtracją dolnoprzepustową o częstotliwości granicznej 45 Hz – zaproponowana metoda detekcji próbek sygnału o zbyt dużej amplitudzie nie była stosowana w znanych pracach analizujących jednokanałowy sygnał EEG.
- Analiza jednokanałowego sygnału EEG wykonana w obrębie nie tylko dwóch klas (APNEA i NORM), ale też trzech, w celu odróżnienia normalnego oddychania od typu bezdechu: OSA lub CSA. Taka wieloetykietowa klasyfikacja była również przedstawiona w pracach autora [249], [250].
- Zaproponowanie połączenia dyskretnej transformacji falkowej z transformatą Hilberta jako metody ekstrakcji cech (wkład ok. 15% w ostateczny, całościowy zbiór cech różnicujących), co było również przedstawione w innych pracach autora [249], [250], [251].
- Zastosowanie połączenia cech uzyskiwanych z kilku różnych metod dekompozycji sygnałów (w tym zaproponowanych podejść dwuetapowych) w jeden wektor, w celu wyodrębnienia jak najbardziej różnicującej informacji umożliwiającej rozróżnienie epok sygnału w obrębie bezdechu sennego i normalnego oddychania, jaki i trzech szczegółowych klas.

- Wykonanie selekcji cech poprzez połączenie metody ReliefF+MRA, które nie było testowane w znanych pracach dotyczących analizy sygnału EEG..
- Uzyskanie bardzo wysokiej dokładności binarnej klasyfikacji epok EEG do bezdechu sennego lub normalnego oddychania, dzięki czemu możliwe jest bezbłędne (dokładność 100% dla k-NN i ANN) rozróżnienie stanu oddychania.

Zdaniem autora, powyżej wylistowane wyniki i osiągnięcia mogą mieć też szerszy wpływ na rozwój dziedziny nauk technicznych. Pierwszym elementem jest zaprezentowana w pracy systematyczna metodyka wyboru i selekcja metod przetwarzania danych pomiarowych na poszczególnych etapach, prowadząca do znacznie bardziej efektywnego wspomagania procesów podejmowania decyzji, która powinna się sprawdzić również w innych zastosowaniach. Ponadto wykazana w pracy możliwość osiągnięcia bardzo dokładnych wyników rozpoznawania stanu funkcjonowania organizmu człowieka (w tym przypadku zaburzeń snu) jedynie na podstawie analizy jednego kanału EEG powinna motywować do technologicznego rozwoju konstrukcji prostych i tanich elektroencefalografów przenośnych z jednym lub tylko kilkoma kanałami pomiarowymi. Co jednak najważniejsze, osiągnięte na stosunkowo dużej liczbie danych (4119 30-sekundowych epok EEG) bezbłędne rozróżnianie normalnego oddychania i bezdechu sennego niewątpliwie może mieć znaczenie aplikacyjne nie tylko w diagnostyce bezdechu sennego, ale również innych chorób, które wpływają na funkcjonowanie mózgu.

9.4 Wnioski i dalsze prace

Podsumowywane powyżej wyniki uzyskane w pracy dokumentują osiągnięcie postawionego celu, gdyż dzięki przyjętej metodyce i zidentyfikowaniu suboptymalnych metod na kolejnych etapach analizy: przetwarzania wstępnego, ekstrakcji i selekcji cech oraz klasyfikacji, możliwe było zaproponowanie procedury przetwarzania jednokanałowego sygnału EEG i automatycznego rozróżniania pomiędzy epokami rejestrowanymi podczas bezdechu sennego i w czasie normalnego oddychania (klasyfikacja binarna), której dokładność wynosi 100% oraz osiągnięcie dokładności różnicowania typu bezdechu (klasyfikacja trójetykietowa) wyższej niż w dotychczasowych badaniach.

Tym samym wykazana została prawdziwość sformułowanej na wstępie hipotezy badawczej, że odpowiedni dobór metod przetwarzania jednokanałowego sygnału EEG na

poszczególnych etapach: przetwarzania wstępnego, ekstrakcji i selekcji cech, oraz uczenia maszynowego pozwoli na uzyskanie dokładności automatycznego rozróżniania między bezdechem sennym a normalnym oddychaniem oraz różnicowania typu bezdechu większej, niż prezentowanej w dotychczasowych badaniach

Uzyskane wyniki klasyfikacji, w szczególności bezbłędne rozróżnienie normalnego oddychania od bezdechu sennego tylko na podstawie jednokanałowego sygnału EEG potwierdzają zasadność prowadzenia dalszych badań nad możliwościami detekcji i różnicowania zdarzeń oddechowych rejestrowanych podczas snu.

W związku z tym, że klasyfikacja była wykonana na zbiorze 4119 epok, korzystnym wydaje się opracowanie liczniejszej bazy danych, z większą ilością zdarzeń oddechowych, w szczególności czystych bezdechów sennych typu centralnego, których ilość przy założeniu równomiernych klas ograniczyła liczebność zbioru epok. W tym celu w najbliższej przyszłości przeanalizowane zostaną także inne publicznie dostępne bazy oraz zostanie podjęta próba nawiązania współpracy z ośrodkami medycznymi zajmującymi się tą tematyką. Ponadto wśród proponowanych dalszych badań mogłoby być powtórzenie analizy sygnału EEG z wykorzystaniem nie zrównoważonych liczbowo klas, co w większym stopniu odwzorowałoby rzeczywisty przebieg ilości zdarzeń oddechowych w stosunku do czasu normalnego oddychania w syndromie bezdechu sennego.

W celu zwiększenia dokładności rozróżnienia samego typu bezdechu sennego proponowane są dalsze prace nad obserwacją różnic w charakterystykach fal mózgowych w epokach z bezdechem w zależności od jego typu, co mogłoby umożliwić lepszy dobór cech reprezentujących te epoki. W związku z tym, być może korzystne byłoby zastosowanie w przyszłości klasyfikacji hierarchicznej, tak aby po rozróżnieniu zdarzeń oddechowych od normalnego oddychania, ponownie wykonać selekcję cech i klasyfikację tylko w obrębie typów bezdechu i w ten sposób zwiększyć prawdopodobieństwa utworzenia wektora cech, który umożliwi lepsze rozróżnienie epok ze zdarzeniami oddechowymi typu centralnego i obturacyjnego oraz ich skuteczną klasyfikację.

Zaproponowana metodyka umożliwiła skuteczne rozróżnienie epok normalnego oddychania od zdarzeń oddechowych, dlatego należałoby w przyszłości wykonać pogłębioną analizę jakościową i ilościową opracowanego zbioru cech uzyskanego różnymi metodami ekstrakcji, co pokazałoby związek poszczególnych cech z zakresami częstotliwości odpowiadającymi poszczególnym falom mózgowym. Ponadto rozwój

wiedzy nad zmianami w sygnale EEG związanymi z bezdechem mógłby przyczynić się do trafniejszego doboru metody dekompozycji sygnału EEG oraz wyboru cech skalarnych i zwiększyć prawdopodobieństwo prawidłowej klasyfikacji epok, w tym również typu tego zdarzenia oddechowego. Ponadto, jak to już wykazano w innych pracach autora, uwzględnienie dodatkowego (przede wszystkim symetrycznego) kanału EEG powinno przyczynić się do dalszej poprawy efektywności różnicowania typów bezdechu. Co więcej, kolejnym planowanym etapem badań będzie przekształcenie wypracowanej procedury do formy działającej on-line oraz uzupełniające wykrywanie innych zdarzeń widocznych w EEG, takich jak wrzeciona snu, kompleksy K, wyładowania impulsowo-falowe, czy wzbudzenia.

Innym proponowanym kierunkiem planowanych badań będzie przetworzenie epok EEG na dwuwymiarowe „obrazy” z zastosowaniem wybranych transformacji, takich jak: STFT, ciągła i dyskretna transformacja falkowa (CWT, DWT), EMD czy VMD i wykonie klasyfikacji z bezpośrednim wykorzystaniem algorytmów głębokiego uczenia.

Bibliografia

- [1] *The AASM Manual for the Scoring of Sleep and Associated Events*. Dostępne w Internecie:<https://static1.squarespace.com/static/5459a5d0e4b09a5cc2e5497a/t/54f8d3d5e4b03ea829c7ef53/1425593307109/Sleep+Stage+Scoring+c3+version.pdf> [dostęp: 21.05.2021]
- [2] Aboalayon, K. A., Ocbagabir, H. T., & Faezipour, M. (2014, May). Efficient sleep stage classification based on EEG signals. In *IEEE Long Island Systems, Applications and Technology (LISAT) Conference 2014* (pp. 1-6). IEEE.
- [3] Abraham, W. T., Pleister, A., & Germany, R. (2018). Identification and treatment of central sleep apnoea: beyond SERVE-HF. *Cardiac failure review*, 4(1), 50.
- [4] Acharya, U. R., Bhat, S., Faust, O., Adeli, H., Chua, E. C. P., Lim, W. J. E., & Koh, J. E. W. (2015). Nonlinear dynamics measures for automated EEG-based sleep stage detection. *European neurology*, 74(5-6), 268-287.
- [5] Acharya, U. R., Chua, E. C. P., Chua, K. C., Min, L. C., & Tamura, T. (2010). Analysis and automatic identification of sleep stages using higher order spectra. *International journal of neural systems*, 20(06), 509-521.
- [6] Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adeli, H., & Subha, D. P. (2018). Automated EEG-based screening of depression using deep convolutional neural network. *Computer methods and programs in biomedicine*, 161, 103-113.
- [7] Acharyya, A., Jadhav, P. N., Bono, V., Maharatna, K., & Naik, G. R. (2018). Low-complexity hardware design methodology for reliable and automated removal of ocular and muscular artifact from EEG. *Computer methods and programs in biomedicine*, 158, 123-133.
- [8] Adeli, H., Zhou, Z., & Dadmehr, N. (2003). Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of neuroscience methods*, 123(1), 69-87.
- [9] Ahmed, F., Paromita, P., Bhattacharjee, A., Saha, S., Azad, S., & Fattah, S. A. (2016, December). Detection of sleep apnea using sub-frame based temporal variation of energy in beta band in EEG. In *2016 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE)* (pp. 258-261). IEEE.
- [10] Akşahin, M., Aydın, S., Fırat, H., & Eroğul, O. (2012). Artificial apnea classification with quantitative sleep eeg synchronization. *Journal of medical systems*, 36(1), 139-144.
- [11] Al-Angari, H. M., & Sahakian, A. V. (2012). Automated recognition of obstructive sleep apnea syndrome using support vector machine classifier. *IEEE Transactions on Information Technology in Biomedicine*, 16(3), 463-468.
- [12] Almuhammadi, W. S., Aboalayon, K. A., & Faezipour, M. (2015, May). Efficient obstructive sleep apnea classification based on EEG signals. In *2015 Long Island Systems, Applications and Technology* (pp. 1-6). IEEE.
- [13] Álvarez, D., Gutierrez, G. C., Marcos, J. V., Del Campo, F., & Hornero, R. (2010, January). Spectral analysis of single-channel airflow and oxygen saturation recordings in

obstructive sleep apnea detection. In *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology* (pp. 847-850). IEEE.

[14] Álvarez-Estévez, D., & Moret-Bonillo, V. (2009, June). Model comparison for the detection of EEG arousals in sleep apnea patients. In *International Work-Conference on Artificial Neural Networks* (pp. 997-1004). Springer, Berlin, Heidelberg.

[15] Álvarez-Estévez, D., & Moret-Bonillo, V. (2010). Identification of electroencephalographic arousals in multichannel sleep recordings. *IEEE Transactions on Biomedical Engineering*, 58(1), 54-63.

[16] Álvarez-Estévez, D., Sánchez-Marño, N., Alonso-Betanzos, A., & Moret-Bonillo, V. (2011). Reducing dimensionality in a database of sleep EEG arousals. *Expert Systems with Applications*, 38(6), 7746-7754.

[17] American Sleep Disorders Association, & European Sleep Research Society. (2001). *The international classification of sleep disorders, revised: diagnostic and coding manual*. American Sleep Disorders Association.

[18] *Analiza dyskryminacyjna*. Dostępny w Internecie: https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstdiscan.html [dostęp: 21.05.2021]

[19] Ansari, A. H., De Wel, O., Lavanga, M., Caicedo, A., Dereymaeker, A., Jansen, K., ... & Van Huffel, S. (2018). Quiet sleep detection in preterm infants using deep convolutional neural networks. *Journal of neural engineering*, 15(6), 066006.

[20] Avcı, C., Delibaşoğlu, İ., & Akbaş, A. (2012, February). Sleep apnea detection using wavelet analysis of ECG derived respiratory signal. In *2012 International Conference on Biomedical Engineering (ICoBE)* (pp. 272-275). IEEE.

[21] Azim, M. R., Haque, S. A., Amin, M. S., & Latif, T. (2010, December). Analysis of EEG and EMG signals for detection of sleep disordered breathing events. In *International Conference on Electrical & Computer Engineering (ICECE 2010)* (pp. 646-649). IEEE.

[22] Azimi, H., Bouchard, M., Goubran, R. A., & Knoefel, F. (2019, June). Apnea event detection methodology using pressure sensors. In *2019 IEEE International Symposium on Medical Measurements and Applications (MeMeA)* (pp. 1-6). IEEE.

[23] Azlan, W. A. W., & Low, Y. F. (2014, December). Feature extraction of electroencephalogram (EEG) signal-A review. In *2014 IEEE Conference on Biomedical Engineering and Sciences (IECBES)* (pp. 801-806). IEEE.

[24] Babaeizadeh, S., White, D. P., Pittman, S. D., & Zhou, S. H. (2010). Automatic detection and quantification of sleep apnea using heart rate variability. *Journal of electrocardiology*, 43(6), 535-541.

[25] Badrakalimuthu, V. R., Swamiraju, R., & de Waal, H. (2011). EEG in psychiatric practice: to do or not to do?. *Advances in psychiatric treatment*, 17(2), 114-121.

[26] BaHammam, A., Sharif, M., Gacuan, D. E., & George, S. (2011). Evaluation of the accuracy of manual and automatic scoring of a single airflow channel in patients with a high probability of obstructive sleep apnea. *Medical science monitor: international medical journal of experimental and clinical research*, 17(2), MT13.

[27] BaHammam, A. S. (2017). Treatment-Emergent Central Sleep Apnea (Complex Sleep Apnea). *Sleep and Vigilance*, 1(2), 53-56.

- [28] Bajaj, N., Carrión, J. R., Bellotti, F., Berta, R., & De Gloria, A. (2020). Automatic and tunable algorithm for EEG artifact removal using wavelet decomposition with applications in predictive modeling during auditory tasks. *Biomedical Signal Processing and Control*, 55, 101624.
- [29] Bandla, H. P., & Gozal, D. (2000). Dynamic changes in EEG spectra during obstructive apnea in children. *Pediatric pulmonology*, 29(5), 359-365.
- [30] Baratloo, A., Hosseini, M., Negida, A., & El Ashal, G. (2015). Part 1: simple definition and calculation of accuracy, sensitivity and specificity.
- [31] Bayatfar, S., Seifpour, S., Oskoei, M. A., & Khadem, A. (2019, April). An Automated System for Diagnosis of Sleep Apnea Syndrome Using Single-Channel EEG Signal. In *2019 27th Iranian Conference on Electrical Engineering (ICEE)* (pp. 1829-1833). IEEE.
- [32] Bearpark, H., Elliott, L., Grunstein, R., Hedner, J., Cullen, S., Schneider, H., ... & Sullivan, C. (1993). Occurrence and correlates of sleep disordered breathing in the Australian town of Busselton: a preliminary analysis. *Sleep*, 16(suppl_8), S3-S5.
- [33] Berry, R. B., Kushida, C. A., Kryger, M. H., Soto-Calderon, H., Staley, B., & Kuna, S. T. (2012). Respiratory event detection by a positive airway pressure device. *Sleep*, 35(3), 361-367.
- [34] Berry, R. B., Brooks, R., Gamaldo, C., Harding, S. M., Lloyd, R. M., Quan, S. F., ... & Vaughn, B. V. (2017). AASM scoring manual updates for 2017 (version 2.4).
- [35] Bhattacharjee, A., Fattah, S. A., Zhu, W. P., & Ahmad, M. O. (2018). VMD-RiM: Rician modeling of temporal feature variation extracted from variational mode decomposed EEG signal for automatic sleep apnea detection. *IEEE Access*, 6, 77440-77453.
- [36] Bhattacharjee, A., Saha, S., Fattah, S. A., Zhu, W. P., & Ahmad, M. O. (2018). Sleep apnea detection based on rician modeling of feature variation in multiband EEG signal. *IEEE journal of biomedical and health informatics*, 23(3), 1066-1074.
- [37] Biegański W. (1906) *Pojęcie przyczynowości w biologii*. Krytyka Lekarska. Warszawa. Dostępne w Internecie: <https://rcin.org.pl/dlibra/doccontent?id=16259> [dostęp 21.05.2021].
- [38] Bigdely-Shamlo, N., Mullen, T., Kothe, C., Su, K. M., & Robbins, K. A. (2015). The PREP pipeline: standardized preprocessing for large-scale EEG analysis. *Frontiers in neuroinformatics*, 9, 16.
- [39] Biswal, S., Kulas, J., Sun, H., Goparaju, B., Westover, M. B., Bianchi, M. T., & Sun, J. (2017). SLEEPNET: automated sleep staging system via deep learning. *arXiv preprint arXiv:1707.08262*.
- [40] Bixler, E. O., Vgontzas, A. N., Ten Have, T., Tyson, K., & Kales, A. (1998). Effects of age on sleep apnea in men: I. Prevalence and severity. *American journal of respiratory and critical care medicine*, 157(1), 144-148.
- [41] Bixler, E. O., Vgontzas, A. N., Lin, H. M., Ten Have, T., Rein, J., Vela-Bueno, A., & Kales, A. (2001). Prevalence of sleep-disordered breathing in women: effects of gender. *American journal of respiratory and critical care medicine*, 163(3), 608-613.

- [42] Black, J. E., Guilleminault, C., Colrain, I. M., & Carrillo, O. (2000). Upper airway resistance syndrome: central electroencephalographic power and changes in breathing effort. *American journal of respiratory and critical care medicine*, 162(2), 406-411.
- [43] Bono, V., Das, S., Jamal, W., & Maharatna, K. (2016). Hybrid wavelet and EMD/ICA approach for artifact suppression in pervasive EEG. *Journal of neuroscience methods*, 267, 89-107.
- [44] *Multivariate Regression*. Dostępny w Internecie: brilliant.org/wiki/multivariate-regression/ [dostęp: 21.05.2021]
- [45] Bsoul, M., Minn, H., & Tamil, L. (2010). Apnea MedAssist: real-time sleep apnea monitor using single-lead ECG. *IEEE transactions on information technology in biomedicine*, 15(3), 416-427.
- [46] Burgos, A., Goni, A., Illarramendi, A., & Bermudez, J. (2009). Real-time detection of apneas on a PDA. *IEEE Transactions on Information Technology in Biomedicine*, 14(4), 995-1002.
- [47] Cabrero-Canosa, M., Castro-Pereiro, M., Graña-Ramos, M., Hernández-Pereira, E., Moret-Bonillo, V., Martin-Egana, M., & Vereza-Hernando, H. (2003). An intelligent system for the detection and interpretation of sleep apneas. *Expert Systems with Applications*, 24(4), 335-349.
- [48] Xiaobai, C. A. I., & Junjun, C. H. E. N. (2016, December). A Method for Blink Artifact Detection and Removal with Wavelet Transform and Hilbert Transform. In *International Conference on Biological Engineering and Pharmacy 2016 (BEP 2016)*. Atlantis Press.
- [49] Campisi, P., La Rocca, D., & Scarano, G. (2012). EEG for automatic person recognition. *Computer*, 45(7), 87-89.
- [50] Cashero, Z. (2011). Comparison of EEG preprocessing methods to improve the classification of P300 trials. *Master of Science Thesis, Colorado State University*.
- [51] Cen, L., Yu, Z. L., Kluge, T., & Ser, W. (2018, July). Automatic system for obstructive sleep apnea events detection using convolutional neural network. In *2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC)* (pp. 3975-3978). IEEE.
- [52] Chakraborty, M., Das, T., & Ghosh, D. (2016, January). Detecting the origin of multifractality of eeg signals with sleep apnea syndrome using multifractal detrended fluctuation analysis method. In *2016 2nd International Conference on Control, Instrumentation, Energy & Communication (CIEC)* (pp. 135-139). IEEE..
- [53] Charbonneau, M., Marin, J. M., Olha, A., Kimoff, R. J., Levy, R. D., & Cosio, M. G. (1994). Changes in obstructive sleep apnea characteristics through the night. *Chest*, 106(6), 1695-1701.
- [54] Chatterjee D. R. (2019). *Log Book Guide to Distance Measuring Approaches for k-Means Clustering*. Dostępny w Internecie: <https://towardsdatascience.com/log-book-guide-to-distance-measuring-approaches-for-k-means-clustering-f137807e8e21> [dostęp: 21.05.2021].
- [55] de Chazal, P., Jayawardhana, M., & Sadr, N. (2018, July). Optimising the Apnoea Classification Performance of a Neural Network Classifier Processing ECG-Oximetry

Signals. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 6026-6029). IEEE.

[56] Cheng L. (2019). *Support Vector Machine Simply Explained*. Dostępny w Internecie: <https://towardsdatascience.com/support-vector-machine-simply-explained-fee28eba5496> [dostęp: 21.05.2021].

[57] Chervin, R. D., Burns, J. W., Subotic, N. S., Roussi, C., Thelen, B., & Ruzicka, D. L. (2004). Method for detection of respiratory cycle-related EEG changes in sleep-disordered breathing. *Sleep*, 27(1), 110-115.

[58] Chervin, R. D., & Burns, J. W. (2011). Engineering better sleep.

[59] Chervin, R. D., Shelgikar, A. V., & Burns, J. W. (2012). Respiratory cycle-related EEG changes: response to CPAP. *Sleep*, 35(2), 203-209.

[60] Chervin, R. D., Garetz, S. L., Ruzicka, D. L., Hodges, E. K., Giordani, B. J., Dillon, J. E., ... & Burns, J. W. (2014). Do respiratory cycle-related EEG changes or arousals from sleep predict neurobehavioral deficits and response to adenotonsillectomy in children?. *Journal of Clinical Sleep Medicine*, 10(8), 903-911.

[61] de Cheveigné, A., & Arzounian, D. (2018). Robust detrending, rereferencing, outlier detection, and inpainting for multichannel data. *NeuroImage*, 172, 903-912.

[62] Chikhi, S., & Benhammada, S. (2009). ReliefMSS: a variation on a feature ranking Relief algorithm. *International Journal of Business Intelligence and Data Mining*, 4(3-4), 375-390.

[63] Chmielnicki W. (2012). *Efektywne metody selekcji cech i rozwiązywania problemu wieloklasowego w nadzorowanej klasyfikacji danych*. Instytut Podstawowych Problemów Techniki Polskiej Akademii Nauk

[64] Chokroverty, S. (1999). *Sleep Disorders Medicine E-Book: Basic Science, Technical Considerations, and Clinical Aspects*. Butterworth-Heinemann Press.

[65] Chokroverty, S., Thomas, R., Bhatt, M. (2014). *Atlas of Sleep Medicine*. Philadelphia: Elsevier Saunders. Dostępne w Internecie: https://books.google.pl/books?id=LbQKAQAQBAJ&printsec=frontcover&dq=Chokroverty,+Atlas+of+Sleep+Medicine&hl=pl&sa=X&redir_esc=y#v=onepage&q=Chokroverty%2C%20Atlas%20of%20Sleep%20Medicine&f=false [dostęp: 21.05.2021]

[66] *Choose a Multilayer Neural Network training function*. Dostępny w Internecie: <https://www.mathworks.com/help/deeplearning/ug/choose-a-multilayer-neural-network-training-function.html> [dostęp 20.05.2021].

[67] Pulse transit time in screening sleep disordered breathing in an elderly population: the PROOF-SYNAPSE study. *Sleep*, 2011, 34.8: 1051-1059.

[68] Chung, F., Liao, P., Elsaid, H., Islam, S., Shapiro, C. M., & Sun, Y. (2012). Oxygen desaturation index from nocturnal oximetry: a sensitive and specific tool to detect sleep-disordered breathing in surgical patients. *Anesthesia & Analgesia*, 114(5), 993-1000.

[69] *Classification Using Nearest Neighbors*. Dostępny w Internecie: <https://www.mathworks.com/help/stats/classification-using-nearest-neighbors.html> [dostęp 20.05.2021].

[70] Cofta, S. (2013). *Ocena wpływu stopnia ciężkości obturacyjnego bezdechu sennego na wybrane wykładniki nasilenia procesów patogenetycznych z uwzględnieniem selektyn i*

stresu oksydacyjnego. Wydawnictwo Naukowe Uniwersytetu Medycznego im. Karola Marcinkowskiego.

[71] Coito A. L., Belo D., Paiva T., Sanches J. M. (2010) EEG spectral power changes before, during and after obstructive sleep apnea. *16th Portuguese Conference on Pattern Recognition*.

[72] Correa, M. A. G., & Leber, E. L. (2011). Noise removal from EEG signals in polisomnographic records applying adaptive filters in cascade. *Adaptive filtering applications*, 61.

[73] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.

[74] Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of neural engineering*, 16(3), 031001.

[75] *Cross Validation*. Dostępny w Internecie: <https://www.mathworks.com/discovery/cross-validation.html> [dostęp 20.05.2021].

[76] Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), 303-314.

[77] Damon, C., Liutkus, A., Gramfort, A., & Essid, S. (2013, May). Non-negative matrix factorization for single-channel EEG artifact rejection. In *2013 IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 1177-1181). IEEE.

[78] Da Silva, F. L. (2009). EEG: origin and measurement. In *EEg-fMRI* (pp. 19-38). Springer, Berlin, Heidelberg.

[79] De Vos, M., Deburchgraeve, W., Cherian, P. J., Matic, V., Swarte, R. M., Govaert, P., ... & Van Huffel, S. (2011). Automated artifact removal as preprocessing refines neonatal seizure detection. *Clinical Neurophysiology*, 122(12), 2345-2354.

[80] Deepa, V. B., Nadu, T., Thangaraj, P., & Sathyamangalam, E. (2011). A study on classification of EEG Data using the Filters. *IJACSA* (4).

[81] Delorme, A., Jung, T. P., Sejnowski, T., & Makeig, S. (2005). Improved rejection of artifacts from EEG data using high-order statistics and independent component analysis. *Neuroimage*.

[82] Delorme, A., Sejnowski, T., & Makeig, S. (2007). Enhanced detection of artifacts in EEG data using higher-order statistics and independent component analysis. *Neuroimage*, 34(4), 1443-1449.

[83] Denoeux, T. (2008). A k-nearest neighbor classification rule based on Dempster-Shafer theory. In *Classic works of the Dempster-Shafer theory of belief functions* (pp. 737-760). Springer, Berlin, Heidelberg.

[84] De Silva, S., Abeyratne, U. R., & Hukins, C. (2011). A method to screen obstructive sleep apnea using multi-variable non-intrusive measurements. *Physiological measurement*, 32(4), 445.

[85] De Silva, S., Abeyratne, U. R., & Hukins, C. (2012). Impact of gender on snore-based obstructive sleep apnea screening. *Physiological measurement*, 33(4), 587.

[86] Devuyst, S., Dutoit, T., Stenuit, P., Kerkhofs, M., & Stanus, E. (2008, August). Removal of ECG artifacts from EEG using a modified independent component analysis

approach. In *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 5204-5207). IEEE.

[87] Devuyst, S., Dutoit, T., Ravet, T., Stenuit, P., Kerkhofs, M., & Stanus, E. (2009). Automatic processing of EEG-EOG-EMG artifacts in sleep stage classification. In *13th International Conference on Biomedical Engineering* (pp. 146-150). Springer, Berlin, Heidelberg.

[88] Dingli, K., Assimakopoulos, T., Fietze, I., Witt, C., Wraith, P. K., & Douglas, N. J. (2002). Electroencephalographic spectral analysis: detection of cortical activity changes in sleep apnoea patients. *European Respiratory Journal*, *20*(5), 1246-1253.

[89] Donovan, L. M., & Kapur, V. K. (2016). Prevalence and characteristics of central compared to obstructive sleep apnea: analyses from the sleep heart health study cohort. *Sleep*, *39*(7), 1353-1359.

[90] Dragomiretskiy, K., & Zosso, D. (2013). Variational mode decomposition. *IEEE transactions on signal processing*, *62*(3), 531-544.

[91] D'Rozario, A. L., Kim, J. W., Wong, K. K., Bartlett, D. J., Marshall, N. S., Dijk, D. J., ... & Grunstein, R. R. (2013). A new EEG biomarker of neurobehavioural impairment and sleepiness in sleep apnea patients and controls during extended wakefulness. *Clinical Neurophysiology*, *124*(8), 1605-1614.

[92] D'Rozario, A. L., Dungan, G. C., Banks, S., Liu, P. Y., Wong, K. K., Killick, R., ... & Kim, J. W. (2015). An automated algorithm to identify and reject artefacts for quantitative EEG analysis during sleep in patients with sleep-disordered breathing. *Sleep and Breathing*, *19*(2), 607-615.

[93] Ebrahimi, F., Mikaeili, M., Estrada, E., & Nazeran, H. (2008, August). Automatic sleep stage classification based on EEG signals by using neural networks and wavelet packet coefficients. In *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 1151-1154). IEEE.

[94] Eckert, D. J., Jordan, A. S., Merchia, P., & Malhotra, A. (2007). Central sleep apnea: pathophysiology and treatment. *Chest*, *131*(2), 595-607.

[95] Eckert, D. J., & Malhotra, A. (2008). Pathophysiology of adult obstructive sleep apnea. *Proceedings of the American thoracic society*, *5*(2), 144-153.

[96] *Electroencephalogram (EEG) techniques measuring sleep activity and sleep stages diagram.*

Dostępny

w

Internecie:

<https://quizlet.com/au/336073417/electroencephalogram-eeg-techniques-measuring-sleep-activity-and-sleep-stages-diagram/> [dostęp: 21.05.2021]

[97] Elwali, A., & Moussavi, Z. (2017). Obstructive sleep apnea screening and airway structure characterization during wakefulness using tracheal breathing sounds. *Annals of biomedical engineering*, *45*(3), 839-850.

[98] Endo, Y., Suzuki, M., Inoue, Y., Sato, M., Namba, K., Hasegawa, M., & Matsuura, M. (2008). Prevalence of complex sleep apnea among Japanese patients with sleep apnea syndrome. *The Tohoku journal of experimental medicine*, *215*(4), 349-354.

[99] Estrada, E., Nazeran, H., Nava, P., Behbehani, K., Burk, J., & Lucas, E. (2004, September). EEG feature extraction for classification of sleep stages. In *The 26th Annual*

- International Conference of the IEEE Engineering in Medicine and Biology Society* (Vol. 1, pp. 196-199). IEEE.
- [100] Estrada, E., Nava, P., Nazeran, H., Behbehani, K., Burk, J., & Lucas, E. (2006, January). Itakura distance: A useful similarity measure between EEG and EOG signals in computer-aided classification of sleep stages. In *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference* (pp. 1189-1192). IEEE.
- [101] Estrada, E., Nazeran, H., Ebrahimi, F., & Mikaeili, M. (2009, April). EEG signal features for computer-aided sleep stage detection. In *2009 4th International IEEE/EMBS Conference on Neural Engineering* (pp. 669-672). IEEE.
- [102] Estrada, E., & Nazeran, H. (2010, February). EEG and HRV signal features for automatic sleep staging and apnea detection. In *2010 20th International Conference on Electronics Communications and Computers (CONIELECOMP)* (pp. 142-147). IEEE.
- [103] The European Respiratory Society (2003). *Sleep breathing disorders*. European Lung white book. Dostępny w Internecie: https://www.erswhitebook.org/files/public/Chapters/23_sleep.pdf [dostęp: 21.05.2021]
- [104] *Fale mózgowe*. Dostępny w Internecie: <https://biofeedbackgdansk.pl/biofeedback/fale-mozgowe> [dostęp: 21.05.2021]
- [105] Farabi, S. S., Prasad, B., Quinn, L., & Carley, D. W. (2014). Impact of dronabinol on quantitative electroencephalogram (qEEG) measures of sleep in obstructive sleep apnea syndrome. *Journal of Clinical Sleep Medicine*, 10(1), 49-56.
- [106] Farzan, F., Atluri, S., Frehlich, M., Dhami, P., Kleffner, K., Price, R., ... & Kennedy, S. H. (2017). Standardization of electroencephalography for multi-site, multi-platform and multi-investigator studies: insights from the canadian biomarker integration network in depression. *Scientific reports*, 7(1), 1-11.
- [107] Fernández-Varela, I., Alvarez-Estevéz, D., Hernández-Pereira, E., & Moret-Bonillo, V. (2017). A simple and robust method for the automatic scoring of EEG arousals in polysomnographic recordings. *Computers in biology and medicine*, 87, 77-86.
- [108] Fietze, I., Penzel, T., Partinen, M., Sauter, J., Küchler, G., Suvoro, A., & Hein, H. (2015). Actigraphy combined with EEG compared to polysomnography in sleep apnea patients. *Physiological measurement*, 36(3), 385.
- [109] Filters in the Electroencephalogram. Dostępny w Internecie: <http://www.electroneurodiagnostics.org/resources/EEG-Material/7-Filters-in-the-Electroencephalogram.pdf> [dostęp: 21.05.2021]
- [110] Fisher, R. A. (1950). The use of multiple measurements in taxonomic problems, *Annual Eugenics*, 7, Part II, 179-188 (1936); also in *Contributions to Mathematical Statistics*.
- [111] *Fitcsvm*. Dostępny w Internecie: <https://www.mathworks.com/help/stats/fitcsvm.html#bt70o83-5> [dostęp 20.05.2021].
- [112] Fonseca, P., Long, X., Radha, M., Haakma, R., Aarts, R. M., & Rolink, J. (2015). Sleep stage classification with ECG and respiratory effort. *Physiological measurement*, 36(10), 2027.
- [113] Fraiwan, L., Lweesy, K., Khasawneh, N., Wenz, H., & Dickhaus, H. (2012). Automated sleep stage identification system based on time–frequency analysis of a single

EEG channel and random forest classifier. *Computer methods and programs in biomedicine*, 108(1), 10-19.

[114] Franaszczuk, P. J., Bergey, G. K., Durka, P. J., & Eisenberg, H. M. (1998). Time–frequency analysis using the matching pursuit algorithm applied to seizures originating from the mesial temporal lobe. *Electroencephalography and clinical neurophysiology*, 106(6), 513-521.

[115] Garrett, D., Peterson, D. A., Anderson, C. W., & Thaut, M. H. (2003). Comparison of linear, nonlinear, and feature selection methods for EEG signal classification. *IEEE Transactions on neural systems and rehabilitation engineering*, 11(2), 141-144.

[116] Gath, I., & Geva, A. B. (1989). Unsupervised optimal fuzzy clustering. *IEEE Transactions on pattern analysis and machine intelligence*, 11(7), 773-780.

[117] Gawędzki, W., Socha, M., & Sławik, P. (2015). Dekompozycja sygnałów EEG w dziedzinie czasu przy zastosowaniu transformacji Hilberta-Huanga HHT. *Przegląd Elektrotechniczny*, 91(5), 33-36.

[118] Gil, E., Bailón, R., Vergara, J. M., & Laguna, P. (2010). PTT variability for discrimination of sleep apnea related decreases in the amplitude fluctuations of PPG signal in children. *IEEE Transactions on Biomedical Engineering*, 57(5), 1079-1088.

[119] Gislason, T., Almqvist, M., Eriksson, G., Taube, A., & Boman, G. (1988). Prevalence of sleep apnea syndrome among Swedish men—an epidemiological study. *Journal of Clinical Epidemiology*, 41(6), 571-576.

[120] Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *circulation*, 101(23), e215-e220.

[121] Gosavi, P. B., & Singh, R. (2017, April). Automatic sleep apnea detection based on entropy of multi-band EEG signal mechanism. In *7th International Conference on Recent Trends in Engineering, Science and Management* (pp. 728-735).

[122] Gubbi, J., Khandoker, A., & Palaniswami, M. (2012). Classification of sleep apnea types using wavelet packet analysis of short-term ECG signals. *Journal of clinical monitoring and computing*, 26(1), 1-11.

[123] Gupta, S., & Singh, H. (1996, November). Preprocessing EEG signals for direct human-system interface. In *Proceedings IEEE International Joint Symposia on Intelligence and Systems* (pp. 32-37). IEEE.

[124] Gupta, R., Zaidi, T. F., & Farooq, O. (2020, November). Automatic Detection of Sleep Apnea Using Sub-Band Features from EEG Signals. In *2020 3rd International Conference on Signal Processing and Information Security (ICSPIS)* (pp. 1-4). IEEE.

[125] Gutiérrez-Tobal, G. C., Álvarez, D., Marcos, J. V., Del Campo, F., & Hornero, R. (2013). Pattern recognition in airflow recordings to assist in the sleep apnoea–hypopnoea syndrome diagnosis. *Medical & biological engineering & computing*, 51(12), 1367-1380.

[126] Gutiérrez-Tobal, G. C., Álvarez, D., Del Campo, F., & Hornero, R. (2015). Utility of adaboost to detect sleep apnea-hypopnea syndrome from single-channel airflow. *IEEE Transactions on Biomedical Engineering*, 63(3), 636-646.

- [127] Hallez, H., Vanrumste, B., Grech, R., Muscat, J., De Clercq, W., Vergult, A., ... & Lemahieu, I. (2007). Review on solving the forward problem in EEG source analysis. *Journal of neuroengineering and rehabilitation*, 4(1), 1-29.
- [128] Hasić, A., Szumowski, Ł., & Walczak, F. (2012). Obturacyjny bezdech—senny zabójca. In *Forum Medycyny Rodzinnej* (Vol. 6, No. 3, pp. 103-114).
- [129] Hassan, A. R., & Bhuiyan, M. I. H. (2016). A decision support system for automatic sleep staging from EEG signals using tunable Q-factor wavelet transform and spectral features. *Journal of neuroscience methods*, 271, 107-118.
- [130] Hassan, A. R., & Bhuiyan, M. I. H. (2017). Automated identification of sleep states from EEG signals by means of ensemble empirical mode decomposition and random under sampling boosting. *Computer methods and programs in biomedicine*, 140, 201-210.
- [131] Hassan, A. R., & Bhuiyan, M. I. H. (2017). An automated method for sleep staging from EEG signals using normal inverse Gaussian parameters and adaptive boosting. *Neurocomputing*, 219, 76-87.
- [132] Hassan, A. R., & Haque, M. A. (2016). Computer-aided obstructive sleep apnea screening from single-lead electrocardiogram using statistical and spectral features and bootstrap aggregating. *Biocybernetics and Biomedical Engineering*, 36(1), 256-266.
- [133] Hassan, A. R., & Haque, M. A. (2017). An expert system for automated identification of obstructive sleep apnea from single-lead ECG using random under sampling boosting. *Neurocomputing*, 235, 122-130.
- [134] Hayano, J., Watanabe, E., Saito, Y., Sasaki, F., Fujimoto, K., Nomiya, T., ... & Sakakibara, H. (2011). Screening for obstructive sleep apnea by cyclic variation of heart rate. *Circulation: Arrhythmia and Electrophysiology*, 4(1), 64-72.
- [135] Hayano, J., Watanabe, E., Saito, Y., Sasaki, F., Kawai, K., Kodama, I., & Sakakibara, H. (2011, August). Diagnosis of sleep apnea by the analysis of heart rate variation: A mini review. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 7731-7734). IEEE.
- [136] Heaton Research. *The number of hidden layers*. (2017). Dostępny w Internecie: <https://www.heatonresearch.com/2017/06/01/hidden-layers.html> [dostęp: 21.05.2021].
- [137] Hernandez, A. B., & Patil, S. P. (2016). Pathophysiology of central sleep apneas. *Sleep and Breathing*, 20(2), 467-482.
- [138] Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- [139] Holmes, G. L., & Khazipov, R. (2007). Basic neurophysiology and the cortical basis of EEG. *The clinical neurophysiology primer*, 19-33.
- [140] Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural networks*, 4(2), 251-257.
- [141] van Houdt, P. J., Ossenblok, P. P., Van Erp, M. G., Schreuder, K. E., Krijn, R. J. J., Boon, P. A., & Cluitmans, P. J. (2011). Automatic breath-to-breath analysis of nocturnal polysomnographic recordings. *Medical & biological engineering & computing*, 49(7), 819-830.
- [142] van Houdt, P. J., Ossenblok, P. P., Van Erp, M. G., Schreuder, K. E., Krijn, R. J. J., Boon, P. A., & Cluitmans, P. J. (2011). Automatic breath-to-breath analysis of nocturnal

polysomnographic recordings. *Medical & biological engineering & computing*, 49(7), 819-830.

[143] How Deep Learning is changing machine learning AI in EEG data processing. Dostępny w Internecie: <https://www.bitbrain.com/blog/ai-eeg-data-processing> [dostęp: 21.05.2021]

[144] Hsu, C. C., & Shih, P. T. (2010, July). An intelligent sleep apnea detection system. In *2010 International Conference on Machine Learning and Cybernetics* (Vol. 6, pp. 3230-3233). IEEE.

[145] Hsu, C. C., & Shih, P. T. (2011). A novel sleep apnea detection system in electroencephalogram using frequency variation. *Expert Systems with Applications*, 38(5), 6014-6024.

[146] Huang, M., Wu, P., Liu, Y., Bi, L., & Chen, H. (2008, November). Application and contrast in brain-computer interface between Hilbert-Huang transform and wavelet transform. In *2008 The 9th International Conference for Young Computer Scientists* (pp. 1706-1710). IEEE.

[147] Huang, T. C., Chen, H. Y., & Fang, W. C. (2012, May). Real-time obstructive sleep apnea detection based on ECG derived respiration signal. In *2012 IEEE International Symposium on Circuits and Systems (ISCAS)* (pp. 341-344). IEEE.

[148] Im, C. H. (2018). *Computational EEG Analysis*. Springer Singapore.

[149] *Introduction to Digital Filters*. Dostępny w Internecie: https://www.analog.com/media/en/technical-documentation/dsp-book/dsp_book_Ch14.pdf [dostęp: 21.05.2021]

[150] The inverse problem. Dostępny w Internecie: <https://sapienlabs.org/the-inverse-problem-in-eeg/> [dostęp: 21.05.2021]

[151] Isham, M. F., Leong, M. S., Lim, M. H., & Ahmad, Z. A. (2018). Variational mode decomposition: mode determination method for rotating machinery diagnosis. *Journal of Vibroengineering*, 20(7), 2604-2621.

[152] Islam, M. K., Rastegarnia, A., & Yang, Z. (2016). Methods for artifact detection and removal from scalp EEG: A review. *Neurophysiologie Clinique/Clinical Neurophysiology*, 46(4-5), 287-305.

[153] Jasper H.H. (1958) The ten-twenty electrode system of the International Federation. *EEG. Clin. Neurophysiol.* 10: 371-375.

[154] Javaheri, S., Parker, T. J., Wexler, L., Michaels, S. E., Stanberry, E., Nishyama, H., & Roselle, G. A. (1995). Occult sleep-disordered breathing in stable congestive heart failure. *Annals of Internal Medicine*, 122(7), 487-492.

[155] Javaheri, S. (1996). Central sleep apnea-hypopnea syndrome in heart failure: prevalence, impact, and treatment. *Sleep*, 19(suppl_10), S229-S231.

[156] Javaheri, S. (2006). Sleep disorders in systolic heart failure: a prospective study of 100 male patients. The final report. *International journal of cardiology*, 106(1), 21-28.

[157] Jen, R., Grandner, M. A., & Malhotra, A. (2015). Future of sleep-disordered breathing therapy using a mechanistic approach. *Canadian Journal of Cardiology*, 31(7), 880-888.

- [158] Jennum, P., & Riha, R. L. (2009). Epidemiology of sleep apnoea/hypopnoea syndrome and sleep-disordered breathing. *European Respiratory Journal*, 33(4), 907-914
- [159] Jiang, D., Ma, Y., & Wang, Y. (2018, October). A Multi-Scale Parallel Convolutional Neural Network for Automatic Sleep Apnea Detection Using Single-Channel EEG Signals. In *2018 11th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)* (pp. 1-5). IEEE.
- [160] Jordan, A., & McEvoy, R. D. (2003). Gender differences in sleep apnea: epidemiology, clinical presentation and pathogenic mechanisms. *Sleep medicine reviews*, 7(5), 377-389.
- [161] Jung, R., & Kuhlo, W. (1965). Neurophysiological studies of abnormal night sleep and the Pickwickian syndrome. In *Progress in brain research* (Vol. 18, pp. 140-159). Elsevier.
- [162] Kanoga, S., & Mitsukura, Y. (2014). Eye-blink artifact reduction using 2-step nonnegative matrix factorization for single-channel electroencephalographic signals. *Journal of Signal Processing*, 18(5), 251-257.
- [163] Kanoga, S., & Mitsukura, Y. (2017). Review of artifact rejection methods for electroencephalographic systems. *Electroencephalography*, 69, 69-89.
- [164] Kasai, T., Floras, J. S., & Bradley, T. D. (2012). Sleep apnea and cardiovascular disease: a bidirectional relationship. *Circulation*, 126(12), 1495-1510.
- [165] Keil, A., Debener, S., Gratton, G., Junghöfer, M., Kappenman, E. S., Luck, S. J., ... & Yee, C. M. (2014). Committee report: publication guidelines and recommendations for studies using electroencephalography and magnetoencephalography. *Psychophysiology*, 51(1), 1-21.
- [166] Kesper, K., Canisius, S., Penzel, T., Ploch, T., & Cassel, W. (2012). ECG signal analysis for the assessment of sleep-disordered breathing and sleep pattern. *Medical & biological engineering & computing*, 50(2), 135-144.
- [167] Khalighi, S., Sousa, T., Santos, J. M., & Nunes, U. (2016). ISRUC-Sleep: A comprehensive public dataset for sleep researchers. *Computer methods and programs in biomedicine*, 124, 180-192.
- [168] Khandoker, A. H., Palaniswami, M., & Karmakar, C. K. (2008). Support vector machines for automated recognition of obstructive sleep apnea syndrome from ECG recordings. *IEEE transactions on information technology in biomedicine*, 13(1), 37-48.
- [169] Khatun, S., Mahajan, R., & Morshed, B. I. (2015, May). Comparative analysis of wavelet based approaches for reliable removal of ocular artifacts from single channel EEG. In *2015 IEEE International Conference on Electro/Information Technology (EIT)* (pp. 335-340). IEEE.
- [170] Kilkenny, T. M. (2002). *Fundamentals of polysomnography and sleep disorders*. Intellisleep Technology and Consulting.
- [171] *K-najbliższych sąsiadów*. Dostępny w Internecie: https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstknn.html [dostęp: 21.05.2021]
- [172] Kocak, O., Bayrak, T., Erdamar, A., Ozparlak, L., Telatar, Z., & Eroglu, O. (2012). Automated detection and classification of sleep apnea types using electrocardiogram

- (ECG) and electroencephalogram (EEG) features. *Advances in Electrocardiograms-Clinical Applications*, 211-230.
- [173] Koley, B., & Dey, D. (2012). An ensemble system for automatic sleep stage classification using single channel EEG signal. *Computers in biology and medicine*, 42(12), 1186-1195.
- [174] Koley, B. L., & Dey, D. (2013). Real-time adaptive apnea and hypopnea event detection methodology for portable sleep apnea monitoring devices. *IEEE Transactions on Biomedical Engineering*, 60(12), 3354-3363.
- [175] Kołodziej, M., Majkowski, A., & Rak, R. J. (2012). Linear discriminant analysis as EEG features reduction technique for brain-computer interfaces. *Przegląd Elektrotechniczny*, 88(3 A), 28-30.
- [176] Kononenko, I. (1994, April). Estimating attributes: Analysis and extensions of RELIEF. In *European conference on machine learning* (pp. 171-182). Springer, Berlin, Heidelberg.
- [177] A. Kowalska. (2011-2013) Mózg a sen, *Neurokognitywistyka w patologii i zdrowiu*, Pomorski Uniwersytet Medyczny w Szczecinie.
- [178] Kripke, D. F., Ancoli-Israel, S., Klauber, M. R., Wingard, D. L., Mason, W. J., & Mullaney, D. J. (1997). Prevalence of sleep-disordered breathing in ages 40–64 years: a population-based survey. *Sleep*, 20(1), 65-76.
- [179] Krishnan, S., & Athavale, Y. (2018). Trends in biomedical signal feature extraction. *Biomedical Signal Processing and Control*, 43, 41-63.
- [180] Borbely, A. A., Achermann, P., Kryger, M. H., Roth, T., & Dement, W. C. (2000). Principles and practice of sleep medicine. *Kryger, MH*, 405-417.
- [181] Kumari, C. U., Kora, P., Meenakshi, K., Swaraja, K., Padma, T., Panigrahy, A. K., & Vignesh, N. A. (2020). Feature Extraction and Detection of Obstructive Sleep Apnea from Raw EEG Signal. In *International Conference on Innovative Computing and Communications* (pp. 425-433). Springer, Singapore.
- [182] Laland, K. N., Sterelny, K., Odling-Smee, J., Hoppitt, W., & Uller, T. (2011). Cause and effect in biology revisited: is Mayr's proximate-ultimate dichotomy still useful?. *science*, 334(6062), 1512-1516.
- [183] Lam, J. C., Sharma, S. K., & Lam, B. (2010). Obstructive sleep apnoea: definitions, epidemiology & natural history. *Indian Journal of Medical Research*, 131, 165-170.
- [184] Lavie, P. (1984). Nothing new under the moon. *Arch Intern Med*, 144(10), 2025-2028.
- [185] Lavie, P. (2008). Who was the first to use the term Pickwickian in connection with sleepy patients? History of sleep apnoea syndrome. *Sleep medicine reviews*, 12(1), 5-17.
- [186] Lehman, S., Antic, N. A., Thompson, C., Catcheside, P. G., Mercer, J., & McEvoy, R. D. (2007). Central sleep apnea on commencement of continuous positive airway pressure in patients with a primary diagnosis of obstructive sleep apnea-hypopnea. *Journal of Clinical Sleep Medicine*, 3(5), 462-466.
- [187] Li, X., Al-Ani, A., & Ling, S. H. (2018, July). Feature Selection for the Detection of Sleep Apnea using Multi-Bio Signals from Overnight Polysomnography. In *2018 40th*

Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 1444-1447). IEEE.

[188] Lin, R., Lee, R. G., Tseng, C. L., Zhou, H. K., Chao, C. F., & Jiang, J. A. (2006). A new approach for identifying sleep apnea syndrome using wavelet transform and neural networks. *Biomedical Engineering: Applications, Basis and Communications*, 18(03), 138-143.

[189] Lin, R., Yeh, M., Lee, R., & Tseng, C. (2011). Sleep apnea syndrome recognition using the GreyART network. *2011 International Conference on Electric Information and Control Engineering*, 2605-2608.

[190] Lin, S. Y., Wu, Y. T., Mao, W. C., & Wang, P. S. (2017, July). EEG signal analysis of patients with obstructive sleep apnea syndrome (OSAS) using power spectrum and fuzzy entropy. In *2017 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)* (pp. 677-681). IEEE.

[191] Lindsen, J. P., & Bhattacharya, J. (2010). Correction of blink artifacts using independent component analysis and empirical mode decomposition. *Psychophysiology*, 47(5), 955-960.

[192] Liu, D., Pang, Z., & Lloyd, S. R. (2008). A neural network method for detection of obstructive sleep apnea and narcolepsy based on pupil size and EEG. *IEEE Transactions on Neural Networks*, 19(2), 308-318.

[193] Liu, Z., Sun, J., Zhang, Y., & Rolfe, P. (2016). Sleep staging from the EEG signal using multi-domain feature extraction. *Biomedical Signal Processing and Control*, 30, 86-97.

[194] Lucey, B. P., Mcleland, J. S., Toedebusch, C. D., Boyd, J., Morris, J. C., Landsness, E. C., ... & Holtzman, D. M. (2016). Comparison of a single-channel EEG sleep study to polysomnography. *Journal of sleep research*, 25(6), 625-635.

[195] Maciejewska, M. (2012). *Analiza danych w czujnikowych pomiarach zanieczyszczeń „powietrza*. Oficyna Wydawnicza Politechniki Wrocławskiej.

[196] Maier, C., Rodler, V., Wenz, H., & Dickhaus, H. (2009). ECG fingerprints of obstructed breathing in sleep apnea patients. *IEEE Engineering in Medicine and Biology magazine*, 28(6), 41-48.

[197] Majkowski, J. (Ed.). (1989). *Elektroencefalografia kliniczna*. Państw. Zakład Wydawnictw Lekarskich.

[198] Malhotra, A. (2004). Central sleep apnea In: Carney PR, Berry RB, Geyer JD, eds. *Clinical Sleep Disorders*.

[199] Martínez-Vargas, J. D., Sepúlveda-Cano, L. M., Travieso-Gonzalez, C., & Castellanos-Dominguez, G. (2012). Detection of obstructive sleep apnoea using dynamic filter-banked features. *Expert Systems with Applications*, 39(10), 9118-9128.

[200] Mateika, J. H., & Syed, Z. (2013). Intermittent hypoxia, respiratory plasticity and sleep apnea in humans: present knowledge and future investigations. *Respiratory physiology & neurobiology*, 188(3), 289-300.

[201] Matsuoka, G., Sugi, T., Kawana, F., & Nakamura, M. (2009, August). Automatic detection of apnea and EEG arousals for sleep apnea syndrome. In *2009 ICCAS-SICE* (pp. 4651-4654). IEEE.

- [202] Maury, G., Cambron, L., Jamart, J., Marchand, E., Senny, F., & Poirrier, R. (2013). Added value of a mandible movement automated analysis in the screening of obstructive sleep apnea. *Journal of sleep research*, 22(1), 96-103.
- [203] Mayr, E. (1961). Cause and effect in biology. *Science*, 134(3489), 1501-1506.
- [204] *Measuring entropy in EEG*. Dostępny w Internecie: <https://sapienlabs.org/measuring-entropy-in-the-ee/> [dostęp: 21.05.2021]
- [205] Mendez, M. O., Corthout, J., Van Huffel, S., Matteucci, M., Penzel, T., Cerutti, S., & Bianchi, A. M. (2010). Automatic screening of obstructive sleep apnea from the ECG based on empirical mode decomposition and wavelet analysis. *Physiological measurement*, 31(3), 273.
- [206] *Metoda wektorów nośnych*. Dostępny w Internecie: https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fsvm.html [dostęp: 21.05.2021]
- [207] *Metoda wzmacniania klasyfikatorów (ang. Boosting)*. Dostępny w Internecie: <http://mst.mimuw.edu.pl/lecture.php?lecture=syd&part=Ch11> [dostęp: 21.05.2021].
- [208] Mijović, B., De Vos, M., Gligorijević, I., Taelman, J., & Van Huffel, S. (2010). Source separation from single-channel recordings by combining empirical-mode decomposition and independent component analysis. *IEEE transactions on biomedical engineering*, 57(9), 2188-2196.
- [209] Mohajon J. (2020). *Confusion Matrix for Your Multi-Class Machine Learning Model*. Dostępny w Internecie: <https://towardsdatascience.com/confusion-matrix-for-your-multi-class-machine-learning-model-ff9aa3bf7826> [dostęp: 21.05.2021].
- [210] Monasterio, V., Burgess, F., & Clifford, G. D. (2012). Robust classification of neonatal apnoea-related desaturations. *Physiological measurement*, 33(9), 1503.
- [211] Morgenstern, C., Schwaibold, M., Randerath, W. J., Bolz, A., & Jané, R. (2010). An invasive and a noninvasive approach for the automatic differentiation of obstructive and central hypopneas. *IEEE transactions on biomedical engineering*, 57(8), 1927-1936.
- [212] Morgenthaler, T. I., Kagramanov, V., Hanak, V., & Decker, P. A. (2006). Complex sleep apnea syndrome: is it a unique clinical syndrome?. *Sleep*, 29(9), 1203-1209.
- [213] Moridani, M. K., Heydar, M., & Behnam, S. S. J. (2019, February). A reliable algorithm based on combination of EMG, ECG and EEG signals for sleep apnea detection:(a reliable algorithm for sleep apnea detection). In *2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI)* (pp. 256-262). IEEE.
- [214] Morisson, F., Lavigne, G., Petit, D., Nielsen, T., Malo, J., & Montplaisir, J. (1998). Spectral analysis of wakefulness and REM sleep EEG in patients with sleep apnoea syndrome. *European Respiratory Journal*, 11(5), 1135-1140.
- [215] Mostafa, S. S., Mendonça, F., G Ravelo-García, A., & Morgado-Dias, F. (2019). A systematic review of detecting sleep apnea using deep learning. *Sensors*, 19(22), 4934.
- [216] Motamedi-Fakhr, S., Moshrefi-Torbati, M., Hill, M., Hill, C. M., & White, P. R. (2014). Signal processing techniques applied to human sleep EEG signals—A review. *Biomedical Signal Processing and Control*, 10, 21-33.
- [217] *MRMR*. Dostępny w Internecie: <https://www.mathworks.com/help/stats/fscMRMR.html> [dostęp 20.05.2021].

- [218] Nagpal, C., & Upadhyay, P. K. (2018, July). Wavelet based sleep EEG detection using fuzzy logic. In *International Conference on Advanced Informatics for Computing Research* (pp. 794-805). Springer, Singapore.
- [219] *Neural Network Subobject Properties*. Dostępny w Internecie: <https://www.mathworks.com/help/deeplearning/ug/neural-network-object-properties.html> [dostęp 20.05.2021].
- [220] *Neural Network*. Dostępny w Internecie: <https://www.mathworks.com/discovery/neural-network.html> [dostęp 20.05.2021].
- [221] *Neuron*. Dostępny w Internecie: http://encyklopedia.naukowy.pl/Neuron,vstrona_2 [dostęp 21.05.2021].
- [222] *Neurony z biasem i bez biasu*. Dostępny w Internecie: <http://galaxy.agh.edu.pl/~vlsi/AI/bias/bias.html> [dostęp 21.05.2021].
- [223] Nigam, G., Pathak, C., & Riaz, M. (2016). A systematic review on prevalence and risk factors associated with treatment-emergent central sleep apnea. *Annals of thoracic medicine*, 11(3), 202
- [224] Noehren, A., Brockmann, P. E., Urschitz, M. S., Sokollik, C., Schlaud, M., & Poets, C. F. (2010). Detection of respiratory events using pulse rate in children with and without obstructive sleep apnea. *Pediatric pulmonology*, 45(5), 459-468.
- [225] *Normalized Function, Normalized Data and Normalization*. Dostępny w Internecie: <https://www.statisticshowto.datasciencecentral.com/normalized/> [dostęp 20.05.2021].
- [226] Nowakowski, A. (2017). Przyczynowa wizja świata. *Przegląd Filozoficzny. Nowa Seria*.
- [227] *Ogólne modele regresji*. Dostępny w Internecie: https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstgrm.html [dostęp: 21.05.2021]
- [228] *One-Way ANOVA*. Dostępny w Internecie: <https://www.mathworks.com/help/stats/one-way-anova.html> [dostęp 20.05.2021].
- [229] Orr, J. E., Malhotra, A., & Sands, S. A. (2017). Pathogenesis of central and complex sleep apnoea. *Respirology*, 22(1), 43-52.
- [230] Osowski S., Cichocki A., Siwek K. (2006). Matlab w zastosowaniu do obliczeń obwodowych i przetwarzania sygnałów. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- [231] Özşen, S. (2013). Classification of sleep stages using class-dependent sequential feature selection and artificial neural network. *Neural Computing and Applications*, 23(5), 1239-1250.
- [232] *Pairwise distance between pairs of observations*. Dostępny w Internecie: <https://www.mathworks.com/help/stats/pdist.html> [dostęp 20.05.2021].
- [233] Pane, E. S., Hendrawan, M. A., Wibawa, A. D., & Purnomo, M. H. (2017, November). Identifying rules for electroencephalograph (EEG) emotion recognition and classification. In *2017 5th International Conference on Instrumentation, Communications, Information Technology, and Biomedical Engineering (ICICI-BME)* (pp. 167-172). IEEE.
- [234] Panossian, L. A., & Avidan, A. Y. (2009). Review of sleep disorders. *Medical Clinics of North America*, 93(2), 407-425.

- [235] Papini, G. B., Fonseca, P., Margarito, J., van Gilst, M. M., Overeem, S., Bergmans, J. W., & Vullings, R. (2018, July). On the generalizability of ECG-based obstructive sleep apnea monitoring: merits and limitations of the Apnea-ECG database. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 6022-6025). IEEE.
- [236] Peng, H., Long, F., & Ding, C. (2005). Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on pattern analysis and machine intelligence*, 27(8), 1226-1238.
- [237] Piątkowski, J. P. Analiza i rozwój metod selekcji cech dla dużych problemów klasyfikacyjnych.
- [238] Pitson, D., & Stradling, J. (1998). Autonomic markers of arousal during sleep in patients undergoing investigation for obstructive sleep apnoea, their relationship to EEG arousals, respiratory events and subjective sleepiness. *Journal of sleep research*, 7(1), 53-59.
- [239] Płoński, P. (2016). *Zastosowanie wybranych metod przekształcania i selekcji danych oraz konstrukcji cech w zadaniach klasyfikacji i klasteryzacji* (Doctoral dissertation, The Institute of Radioelectronics and Multimedia Technology).
- [240] Polak, A. G., Wysoczyński, D., & Mroczka, J. (2004). A transient state analysis of gas exchange in a human body. *Metrology and Measurement Systems*, 11(4), 321-332.
- [241] Pombo, N., Garcia, N., & Bousson, K. (2017). Classification techniques on computerized systems to predict and/or to detect Apnea: A systematic review. *Computer methods and programs in biomedicine*, 140, 265-274.
- [242] *Potencjał spoczynkowy i pompa sodowo-potasowa*. Dostępny w Internecie: <https://pl.khanacademy.org/science/biology/human-biology/neuron-nervous-system/v/sodium-potassium-pump> [dostęp 21.05.2021].
- [243] Poulain, M., Doucet, M., Major, G. C., Drapeau, V., Sériès, F., Boulet, L. P., ... & Maltais, F. (2006). The effect of obesity on chronic respiratory diseases: pathophysiology and therapeutic strategies. *Cmaj*, 174(9), 1293-1299.
- [244] Poyares, D., Guilleminault, C., Rosa, A., Ohayon, M., & Koester, U. (2002). Arousal, EEG spectral power and pulse transit time in UARS and mild OSAS subjects. *Clinical neurophysiology*, 113(10), 1598-1606.
- [245] Pracownia EEG. (2020, październik 20). *Brain-wiki*. Dostępny w Internecie: http://brain.fuw.edu.pl/edu/index.php?title=Pracownia_EEG&oldid=8484 [dostęp 21.05.2021].
- [246] Prasatha, V. S., Alfeilate, H. A. A., Hassanate, A. B., Lasassmehe, O., Tarawnehf, A. S., Alhasanatg, M. B., & Salmane, H. S. E. (2017). Effects of distance measure choice on KNN classifier performance-a review. *arXiv preprint arXiv:1708.04321*.
- [247] *Project DREAMS*. Dostępny w Internecie: <http://www.tcts.fpms.ac.be/projects/dreams/#partners> [dostęp 1.05.2020].
- [248] Prucnal, M., & Polak, A. G. (2017). **Effect of feature extraction on automatic sleep stage classification by artificial neural network.** *Metrology and Measurement Systems*, 24(2).

- [249] Prucnal, M. A., & Polak, A. G. (2018, July). Analysis of features extracted from EEG epochs by discrete wavelet decomposition and Hilbert transform for sleep apnea detection. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 287-290). IEEE.
- [250] Prucnal, M. A., & Polak, A. G. (2019, July). Effectiveness of Sleep Apnea Detection Based on One vs. Two Symmetrical EEG Channels. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 4056-4059). IEEE.
- [251] Prucnal, M. A., & Polak, A. G. (2019). Comparison of information on sleep apnoea contained in two symmetric EEG recordings. *Metrology and Measurement Systems*, 229-239.
- [252] Pusalavidyasagar, S. S., Olson, E. J., Gay, P. C., & Morgenthaler, T. I. (2006). Treatment of complex sleep apnea syndrome: a retrospective comparative review. *Sleep medicine*, 7(6), 474-479.
- [253] *QEEG Brain Mapping*. Dostępny w Internecie: <https://neurofieldneurotherapy.com/quantitative-eeeg-brain-mapping> [dostęp 1.04.2021].
- [254] Quan, S. F., Gillin, J. C., Littner, M. R., & Shepard, J. W. (1999). Sleep-related breathing disorders in adults: Recommendations for syndrome definition and measurement techniques in clinical research. editorials. *Sleep (New York, NY)*, 22(5), 662-689.
- [255] Radha, M., Garcia-Molina, G., Poel, M., & Tononi, G. (2014, August). Comparison of feature and classifier algorithms for online automatic sleep staging based on a single EEG signal. In *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 1876-1880). IEEE.
- [256] Radovic, M., Ghalwash, M., Filipovic, N., & Obradovic, Z. (2017). Minimum redundancy maximum relevance feature selection approach for temporal gene expression data. *BMC bioinformatics*, 18(1), 1-14.
- [257] Rahman, M. J., Mahajan, R., & Morshed, B. I. (2019, March). Exacerbation in obstructive sleep apnea: early detection and monitoring using a single channel EEG with quadratic discriminant analysis. In *2019 9th International IEEE/EMBS Conference on Neural Engineering (NER)* (pp. 85-88). IEEE.
- [258] Raiesdana, S. (2018). Automated sleep staging of OSAs based on ICA preprocessing and consolidation of temporal correlations. *Australasian physical & engineering sciences in medicine*, 41(1), 161-176.
- [259] Ranjan, R., Arya, R., Fernandes, S. L., Sravya, E., & Jain, V. (2018). A fuzzy neural network approach for automatic K-complex detection in sleep EEG signal. *Pattern Recognition Letters*, 115, 74-83.
- [260] Rao, T. V. K. H., & Vishwanath, D. D. (2014, March). Detecting sleep disorders based on EEG signals by using discrete wavelet transform. In *2014 International conference on green computing communication and electrical engineering (ICGCCEE)* (pp. 1-5). IEEE.
- [261] Rathnayake, S. I., Wood, I. A., Abeyratne, U. R., & Hukins, C. (2010). Nonlinear features for single-channel diagnosis of sleep-disordered breathing diseases. *IEEE Transactions on Biomedical Engineering*, 57(8), 1973-1981.

- [262] Ratnavadivel, R., Chau, N., Stadler, D., Yeo, A., McEvoy, R. D., & Catcheside, P. G. (2009). Marked reduction in obstructive sleep apnea severity in slow wave sleep. *Journal of clinical sleep medicine*, 5(6), 519-524.
- [263] Kales, A., & Rechtschaffen, A. (1968). *A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects*. US Department of Health, Education and Welfare, Public Health Service, National Institutes of Health, National Institute of Neurological Diseases and Blindness, Neurological Information Network.
- [264] *Regresja wieloraka*. Dostępny w Internecie: https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstmulreg.html [dostęp: 21.05.2021]
- [265] Rejer, I., & Górski, P. (2013, September). Independent Component Analysis for EEG data preprocessing-algorithms comparison. In *IFIP International Conference on Computer Information Systems and Industrial Management* (pp. 108-119). Springer, Berlin, Heidelberg.
- [266] *ReliefF*. Dostępny w Internecie: <https://www.mathworks.com/help/stats/relieff.html> [dostęp 20.05.2021].
- [267] L. (2017) Polysomnography Artifacts and Updates on AASM Scoring Rules. In *2017 Utah Sleep Society Conference*. FAASM. Dostępny w Internecie: <https://intermountainphysician.org/intermountaincme/Documents/05%20Lloyd.pdf> [dostęp 20.05.2021].
- [268] Robnik-Šikonja, M., & Kononenko, I. (2003). Theoretical and empirical analysis of ReliefF and RReliefF. *Machine learning*, 53(1), 23-69.
- [269] Rofail, L. M., Wong, K. K., Unger, G., Marks, G. B., & Grunstein, R. R. (2010). Comparison between a single-channel nasal airflow device and oximetry for the diagnosis of obstructive sleep apnea. *Sleep*, 33(8), 1106-1114.
- [270] Rofail, L. M., Wong, K. K., Unger, G., Marks, G. B., & Grunstein, R. R. (2010). The utility of single-channel nasal airflow pressure transducer in the diagnosis of OSA at home. *Sleep*, 33(8), 1097-1105.
- [271] Ronzhina, M., Janoušek, O., Kolářová, J., Nováková, M., Honzík, P., & Provazník, I. (2012). Sleep scoring using artificial neural networks. *Sleep medicine reviews*, 16(3), 251-263.
- [272] Rowan, A. J., Tolunsky, E., & Sobieszek, A. (2004). *Podstawy EEG z miniatlasem. Wydanie I polskie. Sobieszek A.[red.]*, Urban & Partner, Wrocław.
- [273] Rutkowski, T. M. (2016). Data-driven multimodal sleep apnea events detection. *Journal of medical systems*, 40(7), 162.
- [274] Saccá, V., Campolo, M., Mirarchi, D., Gambardella, A., Veltri, P., & Morabito, F. C. (2018). On the classification of EEG signal by using an SVM based algorithm. In *Multidisciplinary approaches to neural computing* (pp. 271-278). Springer, Cham.
- [275] Saha, S., Bhattacharjee, A., Ansary, M. A. A., & Fattah, S. A. (2016, November). An approach for automatic sleep apnea detection based on entropy of multi-band EEG signal. In *2016 IEEE Region 10 Conference (TENCON)* (pp. 420-423). IEEE.

- [276] Saha, S., Bhattacharjee, A., & Fattah, S. A. (2019). Automatic detection of sleep apnea events based on inter-band energy ratio obtained from multi-band EEG signal. *Healthcare technology letters*, 6(3), 82-86.
- [277] Sankri-Tarbichi, A. G., Rowley, J. A., & Badr, M. S. (2009). Expiratory pharyngeal narrowing during central hypocapnic hypopnea. *American journal of respiratory and critical care medicine*, 179(4), 313-319.
- [278] Scholle, S., & Zwacka, G. (2001). Arousals and obstructive sleep apnea syndrome in children. *Clinical neurophysiology*, 112(6), 984-991.
- [279] Schlüter, T., & Conrad, S. (2012). An approach for automatic sleep stage scoring and apnea-hypopnea detection. *Frontiers of Computer Science*, 6(2), 230-241.
- [280] [Seifpour et al 2018] Seifpour, S., Niknazar, H., Mikaeili, M., & Nasrabadi, A. M. (2018). A new automatic sleep staging system based on statistical behavior of local extrema using single channel EEG signal. *Expert Systems with Applications*, 104, 277-293.
- [281] Şen, B., Peker, M., Çavuşoğlu, A., & Çelebi, F. V. (2014). A comparative study on classification of sleep stage based on EEG signals using feature selection and classification algorithms. *Journal of medical systems*, 38(3), 1-21.
- [282] Senaratna, C. V., Perret, J. L., Lodge, C. J., Lowe, A. J., Campbell, B. E., Matheson, M. C., ... & Dharmage, S. C. (2017). Prevalence of obstructive sleep apnea in the general population: a systematic review. *Sleep medicine reviews*, 34, 70-81.
- [283] Senliol, B., Gulgezen, G., Yu, L., & Cataltepe, Z. (2008, October). Fast Correlation Based Filter (FCBF) with a different search strategy. In *2008 23rd international symposium on computer and information sciences* (pp. 1-4). IEEE.
- [284] Shaguftah, M. M. S. (2015). An overview of sleep apnea and EEG recording.[J]. *International Journal of Advanced Research in Computer Science and Software Engineering*, 5(10), 617-619.
- [285] Shah R, Pandey A. (2019). Central Sleep Apnea Syndrome. *Int J Head Neck Surg*, 10(2), 34–38.
- [286] Shahbaba, B. (2012). Hypothesis Testing. In *Biostatistics with R* (pp. 173-191). Springer, New York, NY.
- [287] Shahnaz, C., & Minhaz, A. T. (2016, December). Sleep Apnea frame detection based on Empirical Mode Decomposition of delta wave extracted from wavelet of EEG signals. In *2016 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE)* (pp. 233-236). IEEE.
- [288] Shahnaz, C., Minhaz, A. T., & Ahamed, S. T. (2016, November). Sub-frame based apnea detection exploiting delta band power ratio extracted from EEG signals. In *2016 IEEE Region 10 Conference (TENCON)* (pp. 190-193). IEEE
- [289] da Silveira, T. L., Kozakevicius, A. J., & Rodrigues, C. R. (2017). Single-channel EEG sleep stage classification based on a streamlined set of statistical features in wavelet domain. *Medical & biological engineering & computing*, 55(2), 343-352.
- [290] Simms, T., Brijbassi, M., Montemurro, L. T., & Bradley, T. D. (2013). Differential timing of arousals in obstructive and central sleep apnea in patients with heart failure. *Journal of Clinical Sleep Medicine*, 9(8), 773-779.

- [291] Simões, H., Pires, G., Nunes, U., & Silva, V. (2010, June). Feature Extraction and Selection for Automatic Sleep Staging using EEG. In *ICINCO (3)* (pp. 128-133).
- [292] Sin, D. D., Fitzgerald, F., Parker, J. D., Newton, G., Floras, J. S., & Bradley, T. D. (1999). Risk factors for central and obstructive sleep apnea in 450 men and women with congestive heart failure. *American journal of respiratory and critical care medicine*, *160*(4), 1101-1106.
- [293] Siuly, S., Li, Y., & Zhang, Y. (2016). Electroencephalogram (EEG) and its background. In *EEG Signal Analysis and Classification* (pp. 3-21). Springer, Cham. Dostępny w Internecie: https://link.springer.com/chapter/10.1007/978-3-319-47653-7_1 [dostęp 1.04.2021].
- [294] Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, *45*(4), 427-437.
- [295] Sors, A., Bonnet, S., Mirek, S., Vercueil, L., & Payen, J. F. (2018). A convolutional neural network for sleep stage scoring from raw single-channel EEG. *Biomedical Signal Processing and Control*, *42*, 107-114.
- [296] Solà-Soler, J., Fiz, J. A., Morera, J., & Jané, R. (2012). Multiclass classification of subjects with sleep apnoea–hypopnoea syndrome through snoring analysis. *Medical engineering & physics*, *34*(9), 1213-1220.
- [297] Strohl, K. P. (2019). *MSD Manual Professional Version: Obstructive Sleep Apnea*. Dostępny w Internecie: <https://www.msmanuals.com/professional/pulmonary-disorders/sleep-apnea/obstructive-sleep-apnea> [dostęp 20.05.2021].
- [298] Subasi, A. (2005). Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients. *Expert systems with applications*, *28*(4), 701-711.
- [299] Subramaniyam N. P. (2018). *Pitfalls of filtering the EEG signal*. Dostępny w Internecie: <https://sapienlabs.org/pitfalls-of-filtering-the-eeg-signal/> [dostęp 20.05.2021].
- [300] Sugi, T., Kawana, F., & Nakamura, M. (2009). Automatic EEG arousal detection for sleep apnea syndrome. *Biomedical Signal Processing and Control*, *4*(4), 329-337.
- [301] *Support Vector Machine*. Dostępny w Internecie: <https://www.mathworks.com/discovery/support-vector-machine.html> [dostęp 20.05.2021].
- [302] *Support Vector Machines for Binary Classification*. Dostępny w Internecie: <https://www.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html> [dostęp 20.05.2021].
- [303] Suzuki, T., Kameyama, K. I., Inoko, Y., & Tamura, T. (2010, January). Development of a sleep apnea event detection method using photoplethysmography. In *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology* (pp. 5258-5261). IEEE.
- [304] Tagluk, M. E., & Sezgin, N. (2010). Classification of sleep apnea through sub-band energy of abdominal effort signal using wavelets+ neural networks. *Journal of medical systems*, *34*(6), 1111-1119.
- [305] Tagluk, M. E., Akin, M., & Sezgin, N. (2010). Classification of sleep apnea by using wavelet transform and artificial neural networks. *Expert Systems with Applications*, *37*(2), 1600-1607.

- [306] Tang, W. C., Lu, S. W., Tsai, C. M., Kao, C. Y., & Lee, H. H. (2007). Harmonic parameters with HHT and wavelet transform for automatic sleep stages scoring. *REM*, 365, 8-6.
- [307] Taran, S., Bajaj, V., & Sharma, D. (2017, August). TEO separated AM-FM components for identification of apnea EEG signals. In *2017 IEEE 2nd International Conference on Signal and Image Processing (ICSIP)* (pp. 391-395). IEEE.
- [308] Taran, S., & Bajaj, V. (2020). Sleep apnea detection using artificial bee colony optimize hermite basis functions for EEG signals. *IEEE Transactions on Instrumentation and Measurement*, 69(2), 608-616.
- [309] Tatum IV, W. O. (Ed.). (2014). *Handbook of EEG interpretation*. Demos Medical Publishing.
- [310] Teplan, M. (2002). Fundamentals of EEG measurement. *Measurement science review*, 2(2), 1-11.
- [311] *The MIT-BIH Polysomnographic Database*. Dostępny w Internecie: <https://physionet.org/physiobank/database/slpdb/> [dostęp 20.05.2021].
- [312] Toth, M., Kondakor, I., & Faludi, B. (2016). Differences of brain electrical activity between moderate and severe obstructive sleep apneic patients: a LORETA study. *Journal of sleep research*, 25(5), 596-604.
- [313] Tripathy, R. K., & Acharya, U. R. (2018). Use of features from RR-time series and EEG signals for automated classification of sleep stages in deep neural network framework. *Biocybernetics and Biomedical Engineering*, 38(4), 890-902.
- [314]] Tsinalis, O., Matthews, P. M., Guo, Y., & Zafeiriou, S. (2016). Automatic sleep stage scoring with single-channel EEG using convolutional neural networks. *arXiv preprint arXiv:1610.01683*.
- [315] Uczenie maszynowe i sztuczne sieci neuronowe/Wykład Ocena jakości klasyfikacji. (2018, marzec 17). *Brain-wiki*,. Dostępny w Internecie: http://brain.fuw.edu.pl/edu/index.php?title=Uczenie_maszynowe_i_sztuczne_sieci_neuronowe/Wyk%C5%82ad_Ocena_jako%C5%9Bci_klasyfikacji&oldid=7635. [dostęp: 21.05.2021].
- [316] Uddin, M. B., Su, S. W., Chen, W., & Chow, C. M. (2019). Dynamic changes in electroencephalogram spectral power with varying apnea duration in older adults. *Journal of sleep research*, 28(6), e12850.
- [317] *University College Dublin Sleep Apnea Database*. Dostępny w Internecie: <https://www.physionet.org/pn3/ucddb/#subjects> oraz <https://physionet.org/content/ucddb/1.0.0/> [dostęp 20.05.2021].
- [318] Urbanowicz, R. J., Meeker, M., La Cava, W., Olson, R. S., & Moore, J. H. (2018). Relief-based feature selection: Introduction and review. *Journal of biomedical informatics*, 85, 189-203.
- [319] *Using SMOTEboost and RUSboost to deal with class imbalance*. Dostępny w Internecie: <https://medium.com/urbint-engineering/using-smoteboost-and-rusboost-to-deal-with-class-imbalance-c18f8bf5b805> [dostęp: 21.05.2021].

- [320] Uznańska, B., Trzos, E., Rechciński, T., Kasprzak, J. D., & Kurpesa, M. (2010). Repeatability of sleep apnea detection in 48-hour Holter ECG monitoring. *Annals of Noninvasive Electrocardiology*, 15(3), 218-222.
- [321] Verbraecken, J. (2013). Complex sleep apnoea syndrome. *Breathe*, 9(5), 372-380.
- [322] Vimala, V., Ramar, K., & Ettappan, M. (2019). An intelligent sleep apnea classification system based on EEG signals. *Journal of medical systems*, 43(2), 36.
- [323] Chaovalitwongse, W. A., Fan, Y. J., & Sachdeo, R. C. (2007). On the time series k-nearest neighbor classification of abnormal brain activity. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 37(6), 1005-1016.
- [324] Waxman, J. A., Graupe, D., & Carley, D. W. (2010). Automated prediction of apnea and hypopnea, using a LAMSTAR artificial neural network. *American journal of respiratory and critical care medicine*, 181(7), 727-733.
- [325] White, D. P., Gleeson, K. E. V. I. N., Pickett, C. K., Rannels, A. M., Cymerman, A. L. L. A. N., & Weil, J. V. (1987). Altitude acclimatization: influence on periodic breathing and chemoresponsiveness during sleep. *Journal of Applied Physiology*, 63(1), 401-412.
- [326] Wróbel, A. (1997). Zbiorcza aktywność elektryczna mózgu. *Kosmos*, 46(3), 317-326.
- [327] Xavier, P., Behbehani, K., Watenpaugh, D., & Burk, J. R. (2007, August). Detecting electroencephalography variations due to sleep disordered breathing events. In *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 6097-6100). IEEE.
- [328] Xie, B., & Minn, H. (2012). Real-time sleep apnea detection by classifier combination. *IEEE Transactions on information technology in biomedicine*, 16(3), 469-477.
- [329] Yadav, S. K., Bajaj, V., & Kumar, A. (2017, October). An EMD based approach for discrimination of apnea and normal EEG signals. In *2017 International Conference on Recent Innovations in Signal processing and Embedded Systems (RISE)* (pp. 191-194). IEEE.
- [330] Yadollahi, A., Giannouli, E., & Moussavi, Z. (2010). Sleep apnea monitoring and diagnosis based on pulse oximetry and tracheal sound signals. *Medical & biological engineering & computing*, 48(11), 1087-1097.
- [331] ang, Y., Xia, X., Lo, D., & Grundy, J. (2020). A Survey on Deep Learning for Software Engineering. *arXiv preprint arXiv:2011.14597*.
- [332] Yazdani, A., Ebrahimi, T., & Hoffmann, U. (2009, April). Classification of EEG signals using Dempster Shafer theory and a k-nearest neighbor classifier. In *2009 4th International IEEE/EMBS Conference on Neural Engineering* (pp. 327-330). IEEE.
- [333] Yılmaz, B., Asyalı, M. H., Arıkan, E., Yetkin, S., & Özgen, F. (2010). Sleep stage and obstructive apneic epoch classification using single-lead ECG. *Biomedical engineering online*, 9(1), 1-14.
- [334] Younes, M. (2017). The case for using digital EEG analysis in clinical sleep medicine. *Sleep Science and Practice*, 1(1), 1-15.
- [335] Young, T., Palta, M., Dempsey, J., Skatrud, J., Weber, S., & Badr, S. (1993). The occurrence of sleep-disordered breathing among middle-aged adults. *New England Journal of Medicine*, 328(17), 1230-1235.

- [336] Young, T., Peppard, P. E., & Gottlieb, D. J. (2002). Epidemiology of obstructive sleep apnea: a population health perspective. *American journal of respiratory and critical care medicine*, 165(9), 1217-1239.
- [337] Zadeh L.A. (1965). *Fuzzysets*. *Inf.Control*8. 338–353.
- [338] *Zasięg i precyzja – czyli ocena jakości klasyfikacji*. Dostępny w Internecie: <http://mathspace.pl/matematyka/ocena-jakosci-klasyfikacji-czesc-2> [dostęp 21.05.2021].
- [339] Zdunek, R. (2014). *Nieujemna faktoryzacja macierzy i tensorów: zastosowanie do klasyfikacji i przetwarzania sygnałów*. Oficyna Wydawnicza Politechniki Wrocławskiej.
- [340] Zhang, D. X., Wu, X. P., & Guo, X. J. (2008, May). The EEG signal preprocessing based on empirical mode decomposition. In *2008 2nd International Conference on Bioinformatics and Biomedical Engineering* (pp. 2131-2134). IEEE.
- [341] Zhang, X., Yao, L., Zhang, D., Wang, X., Sheng, Q. Z., & Gu, T. (2017, November). Multi-person brain activity recognition via comprehensive EEG signal analysis. In *Proceedings of the 14th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services* (pp. 28-37).
- [342] Zhao, X., Wang, X., Yang, T., Ji, S., Wang, H., Wang, J., ... & Wu, Q. (2021). Classification of sleep apnea based on EEG sub-band signal characteristics. *Scientific Reports*, 11(1), 1-11.
- [343] Zhou, J., Wu, X. M., & Zeng, W. J. (2015). Automatic detection of sleep apnea based on EEG detrended fluctuation analysis and support vector machine. *Journal of clinical monitoring and computing*, 29(6), 767-772.
- [344] Zhou, G., Pan, Y., Yang, J., Zhang, X., Guo, X., & Luo, Y. (2020). Sleep Electroencephalographic Response to Respiratory Events in Patients With Moderate Sleep Apnea–Hypopnea Syndrome. *Frontiers in neuroscience*, 14, 310.
- [345] Ziemia, P. (2012). Redukcja wymiarowości i selekcja cech w zadaniach klasyfikacji i regresji z wykorzystaniem uczenia maszynowego. *Zeszyty Naukowe. Studia Informatica/Uniwersytet Szczeciński*, (30), 221-236.
- [346] Ziółko, E. (2006). *Podstawy fizjologii człowieka*. Oficyna Wydawnicza Państwowej Wyższej Szkoły Zawodowej. Dostępny w Internecie: https://www.dbc.wroc.pl/Content/14559/podstawy_fizjologii_czlowieka.pdf [dostęp 21.05.2021]