

POLITECHNIKA WARSZAWSKA

DYSCYPLINA NAUKOWA INŻYNIERIA BIOMEDYCZNA

DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

Rozprawa doktorska

mgr inż. Marcin Jurczak

**Zastosowanie uczenia głębokiego na użytek usuwania
artefaktów mięśniowych z sygnału EEG**

Promotor

dr hab. inż. Marcin Kołodziej

WARSZAWA 2025

Streszczenie

Celem pracy doktorskiej jest opracowanie metody eliminacji artefaktów mięśniowych z sygnałów elektroencefalograficznych (EEG) z wykorzystaniem technik uczenia głębokiego. W początkowej części pracy przedstawiono podstawowe pojęcia związane z elektroencefalografią oraz szczegółowo scharakteryzowano zakłócenia pojawiające się w trakcie akwizycji sygnałów EEG. Analiza literatury przedmiotu pozwoliła na identyfikację głównych kierunków rozwoju metod eliminacji artefaktów, od rozwiązań klasycznych, takich jak regresja liniowa, analiza składowych niezależnych czy filtracja adaptacyjna, po podejścia nowoczesne, wykorzystujące sztuczne sieci neuronowe oraz modele hybrydowe.

W ramach badań zaprojektowano i przetestowano autorską sieć hybrydową składającą się z sieci konwolucyjnej i rekurencyjnej (CNN-LSTM), której zadaniem była eliminacja artefaktów mięśniowych. Opracowano i przetestowano generator sygnałów EEG i EMG, umożliwiający skuteczne przygotowanie danych treningowych. Na potrzeby treningu i testowania sieci CNN-LSTM przeprowadzono eksperymenty z udziałem 17 ochotników, podczas których rejestrowano sygnały elektroencefalograficzne i elektromiograficzne.

Opracowana sieć neuronowa CNN-LSTM została porównana z klasycznymi metodami oczyszczania sygnałów EEG. Wprowadzono nową miarę jakości oczyszczania sygnałów polegającą na analizie potencjałów wywołanych bodźcami wzrokowymi w stanie ustalonym (SSVEP). Analiza przeprowadzona na rzeczywistych sygnałach EEG wykazała, że proponowana sieć CNN-LSTM skutecznie usuwa zakłócenia spowodowane występowaniem artefaktów, jednocześnie zachowując istotne informacje w sygnale EEG we fragmentach pozbawionych zakłóceń.

Przeprowadzone eksperymenty wykazały przewagę opracowanej sieci nad tradycyjnymi metodami oczyszczania sygnałów EEG, zarówno pod względem skuteczności eliminacji artefaktów, jak i dokładności rekonstrukcji oczyszczonego sygnału. Proponowana hybrydowa sieć CNN-LSTM skutecznie poprawia jakość sygnałów EEG, a krótki czas jej działania umożliwia zastosowanie w aplikacjach wymagających przetwarzania w czasie rzeczywistym. Wyniki uzyskane w pracy potwierdzają postawioną tezę o skuteczności wykorzystania hybrydowej sieci neuronowej oraz dodatkowej rejestracji źródeł EMG w eliminacji artefaktów mięśniowych z sygnału EEG.

Słowa kluczowe

EEG, EMG, artefakty, głębokie uczenie, sieci neuronowe, CNN, LSTM, SSVEP

Abstract

The aim of this doctoral thesis is to develop a method for eliminating electromyographic artifacts from electroencephalographic (EEG) signals using deep learning techniques. The initial part of the thesis presents fundamental concepts related to electroencephalography and provides a detailed characterization of the disturbances occurring during EEG signal acquisition. A literature review enabled the identification of the main directions in the development of artifact removal methods, ranging from classical approaches such as linear regression, independent component analysis, and adaptive filtering, to modern methods involving artificial neural networks and hybrid models.

As part of the research, a proprietary hybrid neural network composed of a convolutional and a recurrent network (CNN-LSTM) was designed and tested to eliminate muscle artifacts. A generator for EEG and EMG signals was developed and validated, enabling effective preparation of training data. For the training and testing of the CNN-LSTM network, experiments were conducted involving 17 volunteers, during which both EEG and electromyographic (EMG) signals were recorded.

The developed CNN-LSTM neural network was compared with classical EEG signal denoising methods. A new signal-cleaning quality metric was introduced, based on the analysis of steady-state visually evoked potentials (SSVEP). The analysis performed on real EEG data showed that the proposed CNN-LSTM network effectively removes disturbances caused by artifacts, while preserving essential information in the EEG signal segments that are free from interference.

The conducted experiments demonstrated the superiority of the developed network over traditional EEG signal cleaning methods, both in terms of artifact removal effectiveness and fidelity of the reconstructed clean signal. The proposed hybrid CNN-LSTM network significantly improves EEG signal quality, and its short processing time enables its use in real-time applications. The results obtained in this study confirm the thesis that hybrid neural network, combined with additional EMG source recording, are effective in eliminating muscle artifacts from EEG signals.

Keywords

EEG, EMG, artifacts, deep learning, neural networks, CNN, LSTM, SSVEP

Spis treści:

1. Wstęp.....	7
1.1. Encefalografia i artefakty fizjologiczne	7
1.2. Motywacja	8
1.3. Cel i teza pracy	9
2. Przegląd literatury	13
2.1. Regresja liniowa	13
2.2. Adaptacyjna filtracja sygnałów.....	13
2.3. Ślepa separacja sygnałów.....	15
2.4. Analiza czasowo-częstotliwościowa i falkowa	17
2.5. Sztuczne sieci neuronowe	18
2.6. Metody hybrydowe	27
2.7. Wnioski z przeglądu literatury	33
3. Materiał badawczy.....	34
3.1. Zgoda Zespołu ds. etyki i badań naukowych z udziałem ludzi	34
3.2. Autorska baza artefaktów	35
3.3. Autorska baza sygnałów SSVEP z artefaktami zaciskania szczęki	39
3.4. Generator sygnałów EEG oraz artefaktów mięśniowych.....	44
3.4.1. Generator sygnałów EEG	45
3.4.2. Generator artefaktów mięśniowych.....	47
3.4.3. Syntetyczne zapisy EEG z artefaktami mięśniowymi.....	48
3.4.4. Porównanie sygnałów zarejestrowanych i syntetycznych	49
3.4.5. Zastosowanie generatora sygnałów w uczeniu maszynowym.....	52
4. Metody badawcze.....	54
4.1. Metody usuwania artefaktów	54
4.1.1. Sieć neuronowa o architekturze CNN-LSTM.....	54
4.1.2. Regresja liniowa	63
4.1.3. Analiza składowych niezależnych.....	66
4.1.4. Filtracja adaptacyjna	69
4.1.5. Filtracja cyfrowa	73
4.2. Metody oceny skuteczności usuwania artefaktów.....	73
5. Rezultaty i dyskusja	77
5.1. Analiza wpływu artefaktów na sygnały EEG	77
5.2. Identyfikacja źródeł wybranych artefaktów	81
5.3. Badanie użyteczności zarejestrowanej bazy SSVEP z artefaktami	86

5.4.	Porównanie metod oczyszczania na danych syntetycznych	90
5.5.	Oczyszczanie sygnałów EEG zawierających potencjały SSVEP	94
5.5.1.	Sieć neuronowa CNN-LSTM	97
5.5.2.	Analiza składowych niezależnych	100
5.5.3.	Regresja liniowa	103
5.5.4.	Filtracja adaptacyjna LMS	106
5.5.5.	Filtracja adaptacyjna RLS	108
5.5.6.	Metody transformacji międzykanałowej w oczyszczaniu sygnałów EEG	111
5.5.7.	Podsumowanie wyników oczyszczania sygnałów EEG za pomocą badanych metod usuwania artefaktów	114
5.6.	Ocena eliminacji artefaktów na podstawie analizy SSVEP	121
5.6.1.	Współczynnik SNR_{SSVEP} dla niskich częstotliwości	122
5.6.2.	Eliminacja artefaktów dla wyższych częstotliwości	126
5.7.	Porównanie metod oczyszczania sygnałów z wykorzystaniem klasyfikacji SSVEP	133
5.8.	Ocena skuteczności metod oczyszczania w obecności różnorodnych artefaktów	136
5.9.	Porównanie czasów oczyszczania sygnałów	139
5.10.	Porównanie z wynikami badań dostępnych w literaturze	140
6.	Podsumowanie	144
7.	Bibliografia	146
8.	Załączniki	154
8.1.	Formularz zgody na udział w badaniu	154
8.2.	Kody źródłowe modeli CNN-LSTM (Python)	155
8.3.	Szczegółowe wartości wyznaczonych współczynników SNR_{SSVEP}	162
9.	Spis skrótów	180

1. Wstęp

1.1. Encefalografia i artefakty fizjologiczne

Encefalografia (EEG) to nieinwazyjna metoda badania aktywności elektrycznej mózgu, znana już od ponad stu lat [1]. Przez ten czas technologia i metody pomiarowe zostały znacznie udoskonalone, a EEG znalazło zastosowanie w wielu dziedzinach, od diagnostyki neurologicznej po psychologię i interfejsy mózg-komputer (Brain-Computer Interface, BCI) [2]. Badanie EEG polega na pomiarze bardzo słabych potencjałów elektrycznych, generowanych przez aktywność neuronów w korze mózgowej [3]. Z tego powodu do rejestracji sygnałów potrzebne są zaawansowane urządzenia, takie jak elektrody umieszczane na skórze głowy oraz wzmacniacze sygnałów [4]. Początkowo elektrody były proste i mniej liczne, ale z biegiem czasu rozwinięto systemy referencyjne, które pozwalają na precyzyjniejsze pomiary. Opracowany przez Herberta Jaspera system 10-20 stał się standardem rozmieszczania elektrod, co umożliwiło porównywanie wyników badań na całym świecie [5]. Dziś technologia poszła jeszcze dalej, wprowadzając możliwość bezprzewodowych pomiarów EEG, co pozwala na rejestrowanie sygnałów nawet podczas codziennych aktywności.

Przy niewielkich amplitudach sygnałów (mikrowolty), EEG jest narażone na zakłócenia, które mogą pochodzić zarówno z urządzeń, jak i z aktywności fizjologicznej osoby badanej. Źródłem artefaktów fizjologicznych jest naturalna aktywność organizmu człowieka. W kontekście analizy sygnałów biologicznych wyróżnia się trzy główne typy artefaktów: artefakty mięśniowe, artefakty elektrookulograficzne oraz artefakty związane z aktywnością serca [3]. Aktywność bioelektryczna mięśni, gałek ocznych oraz serca może być rejestrowana za pomocą odpowiednich metod pomiarowych: elektromiografii (EMG), elektrookulografii (EOG) oraz elektrokardiografii (EKG). Spośród zakłóceń sprzętowych możemy wyróżnić na przykład odklejenie elektrody, brak przewodzenia między skórą a elektrodą, błędne umieszczenie elektrody referencyjnej lub wpływ sieci elektroenergetycznej. Artefakty sprzętowe można zredukować poprzez odpowiednie przygotowanie oraz zapewnienie optymalnych warunków pomiarowych. Jednakże naturalna i często spontaniczna aktywność osoby badanej, taka jak odruchy bezwarunkowe (np. mruganie, przełykanie śliny czy bicie serca), pozostaje trudna do wyeliminowania. Aktywność elektromiograficzna, szczególnie związana z napięciem mięśni twarzy i szyi (np. podczas mrugania, przełykania, zaciskania szczęki czy poruszania głową), stanowi jedno z najsilniejszych źródeł zakłóceń w sygnałach EEG. Artefakty mięśniowe charakteryzują się stosunkowo dużą amplitudą, sięgającą kilku

miliwoltów, oraz szerokim widmem częstotliwościowym, co może prowadzić do znacznego zniekształcenia sygnału EEG i utrudniać jego interpretację, zwłaszcza w kontekście diagnostycznym i analitycznym [3].

Ekstremalne artefakty mięśniowe w sygnale EEG stanowią istotne utrudnienie w wielu zastosowaniach klinicznych i badawczych. W diagnostyce napadów padaczkowych, szczególnie u pacjentów hospitalizowanych na oddziałach intensywnej terapii, napięcia mięśni, zwłaszcza w obrębie twarzy, szyi i karku, mogą całkowicie zamaskować lub wręcz imitować wyładowania epileptyczne, co znacząco utrudnia prawidłową ocenę aktywności napadowej [6], [7]. W systemach typu mózg–komputer, obecność artefaktów mięśniowych znacząco obniża dokładność klasyfikacji intencji ruchowych użytkownika, w tym poleceń opartych na rytmach motorycznych [8]. W polisomnografii, zwłaszcza podczas analizy fazy snu REM (Rapid Eye Movement), mimowolne napięcia mięśniowe lub zrywy mogą zaburzać zarówno automatyczne, jak i manualne rozpoznawanie stadiów snu [9].

1.2. Motywacja

Analiza stanu badań wykazała, że w obszarze Inżynierii Biomedycznej nadal brakuje dokładnych analiz dotyczących usuwania artefaktów mięśniowych z sygnałów elektroencefalograficznych. W momencie rozpoczęcia badań, sieci konwolucyjne (CNN) znajdowały szerokie zastosowanie w wizji komputerowej. Wzrost mocy obliczeniowej z roku na rok umożliwia stosowanie modeli, które jeszcze kilka lat temu były poza zasięgiem praktycznego wykorzystania. Zauważono, że filtry konwolucyjne mogą wspomagać redukcję zakłóceń z danych wielokanałowych, a ich połączenie z warstwami rekurencyjnymi LSTM umożliwiać jednoczesne uchwycenie zależności przestrzennych i czasowych, co w rezultacie może prowadzić do skuteczniejszego oczyszczania sygnałów EEG z artefaktów. Oprócz teoretycznego zastosowania podejścia i porównania go z istniejącymi, dobrze przebadanymi metodami (takimi jak filtracja adaptacyjna, regresja czy metody ślepej separacji sygnałów), tematyka podejmowanej pracy ma również wymiar praktyczny. Wyniki zastosowanych badań mogą być wykorzystane między innymi w interfejsach mózg-komputer oraz w badaniach podczas których obecność artefaktów jest szczególnie uciążliwa. Przykładami mogą być badania EEG u małych dzieci, diagnostyka epilepsji, polisomnografia a także wirówki przeciążeniowe wykorzystywane podczas treningu pilotów.

Motywacją do podjęcia badań jest osobiste zainteresowanie analizą sygnałów EEG oraz możliwościami praktycznego zastosowania opracowanych metod. Praca doktorska może

wnieść istotny wkład w rozwój inżynierii biomedycznej, a także przyczynić się do naukowego i zawodowego rozwoju autora.

1.3. Cel i teza pracy

Celem pracy jest próba zastosowania metod uczenia głębokiego, w szczególności konwolucyjnych (CNN) i rekurencyjnych (LSTM) sieci neuronowych, do usuwania artefaktów mięśniowych z sygnałów elektroencefalograficznych, a następnie porównanie uzyskanych wyników z tradycyjnymi technikami eliminacji zakłóceń. Na użytek badań postawiono tezę: ***„Zastosowanie sieci hybrydowej typu CNN-LSTM oraz dodatkowej rejestracji źródeł EMG pozwala na skuteczną eliminację artefaktów mięśniowych z sygnału EEG”***.

Wśród osiągnięć dokonanych w trakcie prowadzonych badań, zdaniem autora na szczególną uwagę zasługują:

- Opracowanie dwóch autorskich baz sygnałów EEG z artefaktami mięśniowymi, zarejestrowanych odpowiednio podczas stymulacji wzrokowej wywołującej SSVEP (potencjały wywołane bodźcami wzrokowymi w stanie ustalonym) oraz w warunkach bez stymulacji wzrokowej.
- Identyfikacja źródeł artefaktów mięśniowych oraz ocena ich wpływu na jakość sygnału EEG. Przeprowadzona analiza pozwoliła na określenie typu zakłóceń, który wywiera największy wpływ na jakość rejestracji oraz na komponenty SSVEP w pasmach częstotliwości wykorzystywanych w systemach BCI.
- Implementacja generatora sygnałów EEG oraz artefaktów mięśniowych, umożliwiającego ocenę metod oczyszczania na danych syntetycznych. Wygenerowane dane posłużyły także do treningu sieci neuronowych.
- Dobór i eksperymentalna analiza architektur sieci neuronowych w zadaniu eliminacji artefaktów mięśniowych z sygnałów EEG. Przetestowano wiele konfiguracji warstw konwolucyjnych i rekurencyjnych na danych syntetycznych, co pozwoliło na wybór docelowego rozwiązania w postaci hybrydowej sieci CNN-LSTM.
- Implementacja oraz dobór parametrów klasycznych metod usuwania artefaktów, takich jak analiza składowych niezależnych (ICA), regresja liniowa oraz filtracja adaptacyjna. Metody te posłużyły jako punkt odniesienia do porównań z podejściem opartym na sieci CNN-LSTM.
- Przeprowadzenie porównania skuteczności klasycznych metod oczyszczania takich jak analiza składowych niezależnych, regresja liniowa, filtracja adaptacyjna z podejściem

opartym na sieci CNN-LSTM, na danych syntetycznych i rzeczywistych. Ocena jakości oczyszczania obejmowała zarówno analizę widmową, jak i ocenę w dziedzinie czasu.

- Wprowadzenie nowej metody oceny skuteczności oczyszczania sygnałów EEG w oparciu o współczynnik SNR_{SSVEP} , wykorzystany do ilościowej oceny stopnia zachowania komponentów SSVEP po eliminacji artefaktów i porównania skuteczności poszczególnych metod oczyszczania sygnałów.

We wstępie pracy przedstawiono podstawowe pojęcia związane z elektroencefalografią, a także szczegółowo opisano rodzaje zakłóceń mogących występować podczas rejestracji sygnałów.

Kolejnym krokiem był szczegółowy przegląd literatury, obejmujący różne podejścia do eliminacji artefaktów z sygnałów EEG. W przeglądzie ujęto zarówno metody klasyczne, jak również nowoczesne rozwiązania, oparte na sztucznych sieciach neuronowych oraz podejścia hybrydowe, łączące różne techniki przetwarzania sygnałów

W badaniach zdecydowano się na wykorzystanie modelu opartego na hybrydowej sieci neuronowej. Wymagało to jednak przygotowania danych syntetycznych, umożliwiających trening i testowanie modelu. W tym celu konieczne było szczegółowe przebadanie właściwości artefaktów mięśniowych obecnych w sygnałach EEG. Zdecydowano więc o przeprowadzeniu badań z udziałem ochotników, na co uzyskano pozytywną opinię Zespołu ds. etyki i badań naukowych z udziałem ludzi.

Pierwszy etap badań obejmował rejestrację różnorodnych artefaktów mięśniowych w celu ich dokładnej analizy. Na podstawie zebranego materiału zidentyfikowano źródła pochodzenia poszczególnych artefaktów i wybrano artefakt zaciskania szczęki jako najbardziej zakłócający i reprezentatywny przykład artefaktu mięśniowego. Dodatkowo określono minimalny zestaw elektrod niezbędny do skutecznej rejestracji artefaktów mięśniowych.

W drugim etapie badań opracowano docelową bazę sygnałów EEG zawierającą artefakty związane z zaciskaniem szczęki, rejestrowane równocześnie ze stymulacją wzrokową wywołującą SSVEP. Obecność SSVEP umożliwiła ocenę skuteczności metod oczyszczania, zwłaszcza pod kątem usuwania artefaktów przy jednoczesnym zachowaniu integralnych elementów aktywności bioelektrycznej mózgu. Do oceny skuteczności oczyszczania wprowadzono współczynnik SNR_{SSVEP} , który pozwala na ilościową ocenę zachowania SSVEP w sygnale oczyszczonym.

Zgromadzona baza danych rzeczywistych umożliwiła opracowanie oraz implementację generatora sztucznych sygnałów EEG i artefaktów mięśniowych. Na jej podstawie

przygotowano dane syntetyczne, które posłużyły jako zestaw treningowy i testowy w procesie projektowania oraz doboru architektury sieci neuronowej. Dane te umożliwiły również przetestowanie skuteczności różnych metod oczyszczania sygnałów, ponieważ znane były zarówno przebiegi sygnału, jak i zakłócających artefaktów.

W dalszej części pracy przedstawiono wybrane metody badawcze. Obejmowały one zarówno metody klasyczne, jak regresję liniową, analizę składowych niezależnych, filtrację adaptacyjną z algorytmami LMS i RLS, jak również metody międzykanałowe, takie jak montaż bipolarny oraz filtrację Laplace'a. Dokonano ich implementacji oraz doboru parametrów umożliwiających eliminację artefaktów i porównanie skuteczności każdej z metod. Jednocześnie przeprowadzono rozbudowaną analizę architektur sieci neuronowych do eliminacji artefaktów mięśniowych w sygnałach EEG, co pozwoliło na wybór docelowego modelu jakim była hybrydowa sieć neuronowa typu CNN-LSTM.

Zarejestrowane sygnały EEG z bazy docelowej zostały poddane oczyszczaniu przy użyciu każdej z rozważanych metod. Skuteczność oczyszczania oceniono zarówno na danych rzeczywistych, jak i syntetycznych. Otrzymane wyniki poddano analizie porównawczej i omówiono ich znaczenie z perspektywy dalszych zastosowań w przetwarzaniu sygnałów EEG.

Jako uzupełnienie przeprowadzonych analiz, zaprezentowano działanie każdej z metod oczyszczania na przykładzie dodatkowego sygnału EEG zawierającego różnorodne artefakty,. Ponadto przeprowadzono porównanie otrzymanych wyników z rezultatami opisanymi w literaturze naukowej.

W podsumowaniu przedstawiono zalety i ograniczenia każdej z analizowanych metod, a także wskazano potencjalne kierunki dalszych badań w obszarze oczyszczania sygnałów EEG z artefaktów mięśniowych.

Schemat blokowy prowadzonych badań przedstawiono w formie diagramu na rysunku 1.



Rysunek 1. Schemat blokowy badań w formie diagramu.

2. Przegląd literatury

W literaturze można znaleźć różnorodne metody usuwania artefaktów, które różnią się złożonością obliczeniową i zastosowanymi algorytmami przetwarzania sygnałów [10], [11]. Do popularnych metod należą techniki takie jak filtracja, analiza składowych niezależnych, regresja liniowa, metody hybrydowe oraz zaawansowane metody oparte na algorytmach uczenia maszynowego. Każda z tych technik ma swoje zalety i wady, a jej dobór zależy od rodzaju artefaktów, specyfiki badań oraz jakości zebranego sygnału EEG.

2.1. Regresja liniowa

Metody regresji liniowej są wykorzystywane jako efektywne podejście do eliminacji artefaktów w sygnałach EEG [12], [13]. Regresja liniowa umożliwia modelowanie związków między artefaktami a rzeczywistym sygnałem EEG, co pozwala na skuteczne odseparowanie szumów od istotnych informacji. W artykule [14] badacze porównali skuteczność metody regresji EMCP (Eye Movement Correction Procedure) do usuwania artefaktów elektrookulograficznych z sygnałów EEG. Metoda EMCP wykorzystuje kanały EOG jako pomocnicze, obliczając współczynniki propagacji z wykorzystaniem metody najmniejszych kwadratów, które określają, jak sygnały EOG wpływają na EEG. Proces ten opiera się na regresji liniowej, w której od sygnałów EEG odejmowane są skalowane wartości EOG w celu redukcji zakłóceń. Metoda jest prostsza i mniej wymagająca obliczeniowo niż bardziej zaawansowane techniki, choć może być mniej precyzyjna w eliminowaniu artefaktów w porównaniu z ICA. W artykule [15] badacze przedstawili nową metodę o nazwie REBLINCA, mającą na celu usuwanie artefaktów związanych z mrugnięciami z sygnałów EEG. W metodzie wykorzystano kanał EEG (np. *Fpz*) do wykrywania mrugnięć, które służą jako wzorce do korekcji sygnału. Regresja jest przeprowadzana tylko wtedy, gdy na kanale zostanie wykryty artefakt, co minimalizuje ryzyko nieuzasadnionej modyfikacji sygnału EEG. Rozwiązanie to pozwala metodzie REBLINCA na efektywne usuwanie zakłóceń minimalizując wpływ na resztę sygnału EEG, co stanowi problem w typowych metodach, które korzystają ze wzorca z kanału EOG.

2.2. Adaptacyjna filtracja sygnałów

Zastosowanie powszechnie znanych filtrów FIR (Finite Impulse Response) oraz IIR (Infinite Impulse Response), w konfiguracjach środkowozaporowych (Band-stop) i dolnoprzepustowych (Low-pass), stanowi standardową metodę tłumienia zakłóceń

w sygnałach EEG. Techniki filtracji cyfrowej były wykorzystywane w licznych badaniach, gdzie eliminacja artefaktów związanych z zasilaniem pozwoliła na uzyskanie bardziej precyzyjnych wyników analiz aktywności bioelektrycznej mózgu [12], [16], [17], [18]. Filtracja adaptacyjna znajduje zastosowanie w przypadkach, gdy zakłócenia są bardziej złożone i zmienne. Działanie filtrów adaptacyjnych polega na wykorzystaniu sygnałów z dodatkowych elektrod rejestrujących aktywność związaną z artefaktami w celu ich eliminacji. W odróżnieniu od prostych filtrów liniowych, filtry adaptacyjne dopasowują się dynamicznie do zmian w sygnale, co umożliwia skuteczniejsze usuwanie artefaktów. W artykule [19] przedstawiono zoptymalizowany adaptacyjny filtr oparty na algorytmie RLS, do usuwania artefaktów kardiologicznych z sygnałów EEG. W proponowanej metodzie zastosowano ważony algorytm RLS, który dopasowuje się do zmieniających się charakterystyk zakłóceń. Optymalizacja parametrów algorytmu RLS była przeprowadzona przy użyciu techniki optymalizacji bayesowskiej (Bayesian optimization), co pozwoliło na zwiększenie jego efektywności w porównaniu do tradycyjnych metod, takich jak filtry środkowozaporowe czy analiza składowych niezależnych. Zastosowanie metody prowadzi do obniżenia błędów MSE oraz wyższego stosunku sygnału do artefaktów. Autorzy skupili się na artefaktach powodowanych aktywnością serca, jednakże uważają, że proponowane podejście umożliwi również usuwanie innych rodzajów artefaktów takich jak elektrookulograficzne lub mięśniowe. W artykule [20] opisano wykorzystanie technik adaptacyjnego filtrowania opartych na algorytmie LMS do usuwania artefaktów z sygnałów EEG. Głównym celem badań jest opracowanie algorytmów do usuwania artefaktów, zwiększających stosunek SNR (sygnału do szumu) oraz umożliwiających bardziej dokładną analizę sygnałów EEG. Autorzy przedstawili różne warianty algorytmu LMS, które różnią się metodami aktualizacji wag. Analizy przeprowadzonych symulacji wykazały, że algorytm Variable Step Size Leaky LMS pozwala na uzyskanie najwyższej wartości SNR w porównaniu z innymi metodami. W artykule [21] przedstawiono metodę usuwania artefaktów z sygnałów EEG przy użyciu kaskady filtrów adaptacyjnych opartych na algorytmie LMS. Każdy z trzech filtrów został zaprojektowany do eliminacji określonego rodzaju artefaktu: pierwszy usuwał zakłócenia pochodzące od sieci energetycznej, drugi redukował artefakty związane z pracą serca, a trzeci artefakty elektrookulograficzne. Każdy etap wykorzystywał filtr o skończonej odpowiedzi impulsowej, który dostosowywał swoje współczynniki z wykorzystaniem algorytmu LMS, aby wytworzyć sygnał zbliżony do artefaktów obecnych w EEG. Metoda została przetestowana na pięciu rzeczywistych zapisach EEG z badań polisomnograficznych, gdzie wszystkie przypadki wykazały skuteczne tłumienie artefaktów. Analiza wyników potwierdza, że zastosowana

kaskada filtrów adaptacyjnych skutecznie redukuje powszechne artefakty EEG, nie naruszając istotnych informacji zawartych w zapisach.

2.3. Ślepa separacja sygnałów

W eliminacji artefaktów wykorzystuje się także metody oparte na ślepej separacji źródeł sygnałów – BSS (Blind Source Separation), które pozwalają na rozdzielenie sygnałów na komponenty źródłowe bez znajomości ich pochodzenia. Przykładową metodą wykorzystywaną już od dawna jest analiza składowych niezależnych [22]. Podstawowym założeniem, a niekiedy również ograniczeniem metody ICA jest niezależność źródeł sygnału. Algorytm umożliwia wyznaczenie tak zwanej macierzy separacji (Separation matrix), która pozwala na oddzielenie sygnałów źródłowych (w tym artefaktów) od zarejestrowanego sygnału EEG. Eliminacja następuje poprzez wyzerowanie składowych związanych z artefaktami.

Dobór liczby komponentów źródłowych w ICA stanowi ważny element analizy, ponieważ zależy od niego skuteczność oddzielenia aktywności bioelektrycznej mózgu od artefaktów. Liczba komponentów zazwyczaj nie może przekroczyć liczby kanałów wykorzystanych do akwizycji danych, zgodnie z założeniami algorytmu. Gdy rzeczywista liczba źródeł przekracza liczbę elektrod, ICA nie jest w stanie ich w pełni rozdzielić, co prowadzi do nakładania się sygnałów [23]. Wybór zbyt dużej liczby komponentów może powodować rozdzielenie jednego artefaktu na kilka składowych i utrudniać jego identyfikację, natomiast wybór zbyt małej liczby skutkuje niedostatecznym rozdzieleniem źródeł, prowadząc do pozostawiania artefaktów w sygnale mózgowym. Nawet przy prawidłowej separacji źródeł, identyfikacja komponentów odpowiadających za artefakty wymaga specjalistycznej wiedzy oraz doświadczenia w analizie sygnałów biomedycznych [24].

Autorzy publikacji [25] postanowili zastosować modyfikację dotyczącą wyznaczania macierzy separacji poprzez maksymalizację wspólnej entropii z wykorzystaniem algorytmu gradient ascent. Modyfikacja pozwoliła na skuteczniejszą eliminację artefaktów związanych z aktywnością serca w porównaniu z innymi podejściami do ICA. Kolejna modyfikacja metody ICA: cICA (constrained ICA) [26], wykorzystana była do eliminacji artefaktów związanych z pulsem użytkownika PRA (Pulse Related Artifact) z sygnałów EEG zarejestrowanych podczas badania funkcjonalnego rezonansu magnetycznego. Algorytm wykorzystuje szablony artefaktów generowane na podstawie sygnału EKG, które służą jako odniesienie pozwalające na odszukanie przez ICA odpowiadających im komponentów w sygnale EEG. W kolejnym kroku wykorzystywana jest klasteryzacja celem połączenia podobnych komponentów i minimalizacji wpływu na prawidłowe składowe sygnału. Komponenty uznane za związane

z artefaktami są odrzucane, a sygnał rekonstruowany jest do formy pozbawionej artefaktów. Publikacja [27] dotyczy metody ARCI, która automatycznie usuwa zakłócenia sercowe z sygnałów EEG bez potrzeby jednoczesnej rejestracji EKG. Proponowana metoda wykorzystuje analizę składowych niezależnych do rozdzielenia sygnału na różne źródła, a następnie klasyfikuje wyodrębnione komponenty jako zakłócenia sercowe na podstawie dwóch wskaźników: CIF, który sprawdza regularność rytmu serca, oraz CorrCI, który porównuje kształt fali do wzorca zakłóceń sercowych. Gdy zakłócenie zostanie wykryte, jest automatycznie usuwane, co poprawia jakość sygnału EEG. Metoda jest całkowicie zautomatyzowana i może działać w różnych warunkach. W badaniu [28] wykorzystano metodę ICA do usunięcia artefaktów z sygnałów EEG zarejestrowanych podczas wykonywania symulowanych prac pszczelarskich. Symulowane prace pszczelarskie zostały wybrane jako zadanie eksperymentalne ze względu na swoją złożoność motoryczną i umysłową. Zadania wymagające precyzji i koncentracji, takie jak manipulowanie ulami czy obsługa narzędzi, sprzyjają powstawaniu artefaktów w sygnałach EEG. Do eliminacji artefaktów wykorzystano narzędzie ICLabel, które pozwoliło na automatyczną klasyfikację komponentów uznanych za źródła artefaktów i ich usunięcie. Narzędzie wykorzystuje sieci neuronowe wytrenowane na zbiorze ponad 6000 sygnałów EEG zawierających ponad 200000 różnych komponentów ICA pochodzących od aktywności bioelektrycznej mózgu, ruchu oczu, aktywności serca oraz mięśniowej [28], [29]. Oczyszczone sygnały posłużyły do treningu modelu mającego na celu wykrywanie zmęczenia. W artykule [30] zaproponowano modyfikację algorytmu ASR (Artifact Subspace Reconstruction) poprzez zastosowanie geometrii riemanowskiej w celu poprawy usuwania artefaktów z sygnałów EEG. Klasyczny ASR to algorytm do usuwania artefaktów z sygnałów EEG, który bazuje na PCA (analizie składowych głównych). Algorytm ASR w pierwszej kolejności uczy się statystycznych właściwości czystych sygnałów kalibracyjnych (zarejestrowanych podczas spoczynku), a następnie w czasie rzeczywistym porównuje nowe dane EEG z tymi wzorcami. Jeśli sygnał przekracza ustalony próg, jest uznawany za artefakt i rekonstruowany. Metoda rASR została porównana z tradycyjnym ASR pod kątem skuteczności w redukcji artefaktów wzrokowych, jakości uzyskiwanych VEP (potencjałów wywołanych) oraz wydajności obliczeniowej. Przeprowadzone badania wykazały, że rASR pozwala uzyskać wyniki porównywalne ze standardowym ASR, jednak w znacznie krótszym czasie. Sugeruje to, że rASR jest skutecznym narzędziem do korekcji artefaktów w sygnałach EEG rejestrowanych z wielu kanałów. W artykule [31] opisano metodę BSS-CCA służącą do usuwania artefaktów mięśniowych z sygnałów EEG przy użyciu CCA (analizy kanonicznej korelacji, Canonical Correlation Analysis). Wykorzystanie metody CCA umożliwia separację

sygnałów o różnym stopniu autokorelacji, dzięki czemu artefakty mięśniowe, charakteryzujące się niską autokorelacją, są oddzielane od sygnałów mózgowych, które mają wyższą autokorelację. Podczas testów, metoda BSS-CCA przewyższyła filtrację dolnoprzepustową i metodę ICA, które często nie są w stanie całkowicie usunąć artefaktów bez utraty cennych danych EEG. Filtry dolnoprzepustowe usuwają artefakty mięśniowe, ale również tłumią istotne częstotliwości sygnałów mózgowych, a ICA często nie rozdziela poprawnie sygnałów, gdy komponenty zawierają zarówno aktywność mózgową, jak i mięśniową. Proponowana metoda okazała się skutecznie usuwać artefakty mięśniowe zarówno dla syntetycznych, jak również rzeczywistych sygnałów. Zdecydowanym ograniczeniem był jednak manualny wybór komponentów CCA przeznaczonych do odrzucenia, co eliminuje metodę z wykorzystania w czasie rzeczywistym.

2.4. Analiza czasowo-częstotliwościowa i falkowa

Kolejna grupa metod eliminacji artefaktów wykorzystuje transformacje: dyskretną i ciągłą transformację falkową, krótkoczasową transformację Fouriera i inne techniki przekształcania sygnałów. Autorzy [32] proponują wykorzystanie transformacji falkowej i progowania do usuwania artefaktów elektrookulograficznych. Zaburzony sygnał EEG poddawany jest transformacji falkowej, która dekomponuje sygnał na różne pasma częstotliwości. Następnie dokonywane jest progowanie wybranych współczynników. Wartość progu ustalana jest na podstawie statystyk zanieczyszczonego sygnału. Po odfiltrowaniu artefaktów sygnał rekonstruowany jest z wykorzystaniem transformacji odwrotnej. Celem badania opisanego w artykule [33] było stworzenie zestawu danych LieWaves na użytek detekcji kłamstw przy użyciu sygnałów EEG. Kluczowym krokiem w tym procesie było usuwanie artefaktów z sygnałów EEG, które mogą znacząco zakłócać rzeczywiste pomiary aktywności mózgu. Wybrany sposobem eliminacji artefaktów był algorytm ATAR (Automatic and Tunable Artifact Removal). Metoda oparta jest na dekompozycji falkowej, a proces działania ATAR obejmuje kilka kluczowych etapów. Na początku ustalany jest próg istotności, który ma na celu identyfikację komponentów sygnału EEG wymagających przetworzenia. Po ustaleniu progu, sygnał jest dekomponowany na różne falki, co umożliwia analizę zróżnicowanych częstotliwości. Komponenty sygnału, których amplituda znajduje się poniżej ustalonego progu, są uznawane za nieistotne. W zależności od wybranego sposobu filtrowania, komponenty są poddawane tłumieniu lub całkowitemu usunięciu. W tym przypadku autorzy zdecydowali się na próg o wartości 0.1 i na tłumienie komponentów poniżej tego progu, zamiast ich całkowitej

eliminacji. Podejście to pozwoliło na poprawę jakości sygnałów EEG przekazywanych do kolejnych etapów analizy.

2.5. Sztuczne sieci neuronowe

Sieci neuronowe w ostatnich latach cieszą się bardzo dużą popularnością w wielu dziedzinach nauki. Znalazły również szerokie zastosowanie w oczyszczaniu sygnałów EEG z artefaktów [34]. W artykule [35] zaprezentowano mechanizm oczyszczania nazwany przez autorów EEGDnet, skupiający się jednocześnie na lokalnym i nielokalnym samopodobieństwie w sygnale EEG. Niektóre z metod wykorzystujących uczenie głębokie analizują jedynie wzorce lokalne lub nielocalne, podczas gdy proponowana przez autorów sieć uwzględnia jednocześnie oba rodzaje wzorców. Wykorzystano do tego celu transformer dwuwymiarowy. Wzorce nielocalne uwzględnione zostały w blokach uwagi (Self-attention blocks), a lokalne w blokach sprzężenia zwrotnego (Feed forward blocks). Następnie wykorzystano wiele modułów transformera celem odkrycia uniwersalnego wzorca oczyszczającego, pozwalającego na eliminację zarówno artefaktów elektrookulograficznych jak również mięśniowych. W artykule [36] zaproponowano metodę 1D-ResCNN, opartą na konwolucyjnej sieci neuronowej do automatycznego usuwania artefaktów z sygnałów EEG. Sieć 1D-ResCNN to sieć neuronowa z blokami residualnymi działająca bezpośrednio na sygnałach EEG pochodzących z jednego kanału, bez potrzeby wcześniejszego przetwarzania lub ekstrakcji cech. Innowacyjność podejścia polega na użyciu bloków residualnych (z różnymi rozmiarami filtrów konwolucyjnych), pozwalających na dokładniejsze wydobycie cech z sygnałów EEG. Głębokie warstwy konwolucyjne automatycznie uczą się nieliniowych zależności pomiędzy zaszumionymi i czystymi sygnałami EEG, umożliwiając bardziej precyzyjne usuwanie zakłóceń bez utraty istotnych informacji. Sieć została porównana z innymi podejściami takimi jak tradycyjne ICA, FICA, filtracja RLS, transformacja falkowa i nowoczesne głębokie sieci neuronowe (DNN). Proponowana metoda pozwala na uzyskanie lepszych wyników pod względem dokładności usuwania artefaktów, wartości błędu średniokwadratowego – RMSE (Root Mean Squared Error) czy stosunku sygnału do szumu, a ponadto zachowuje nieliniowe charakterystyki sygnałów EEG. Autorzy artykułu [37] zaprezentowali sieć AGO-CycleGAN, służącą do eliminacji artefaktów z sygnału EEG spowodowanych ruchem osoby badanej. Architektura opiera się na modelu generatywnych sieci przeciwstawnych CycleGAN z dodatkiem mechanizmu uwagi (Attention) i neuronów operacyjnych. Zastosowanie mechanizmu uwagi pozwala na bardziej precyzyjną identyfikację artefaktów, a neurony operacyjne lepiej przetwarzają nieliniowe wzorce w sygnałach EEG. Sieć jest przystosowana

do oczyszczania pojedynczego kanału i wykazuje obiecujące wyniki zarówno w kontekście oczyszczania w czasie rzeczywistym, jak i przetwarzania innych sygnałów fizjologicznych. W artykule [38] autorzy przedstawili tematykę dotyczącą predykcji napadów epileptycznych za pomocą sygnałów EEG. W celu usuwania artefaktów wykorzystano algorytm rekonstrukcji sygnałów SER (Sparsity-Based EEG Reconstruction), a klasyfikację zapewniała trójwymiarowa zoptymalizowana sieć neuronowa CNN (3D OCNN). Proces rozpoczyna się od przekształcenia sygnału EEG na współczynniki oparte na rzadkości (Sparsity), co ułatwia oddzielenie czystego sygnału od zakłóceń wywołanych ruchami oczu oraz aktywnością mięśni. W tym celu stosuje się algorytm K-SVD, który tworzy słownik wzorców, zawierający zarówno charakterystyczne elementy czystego sygnału EEG, jak i potencjalnych artefaktów. Sygnał EEG, który zawiera zarówno czyste komponenty, jak i zakłócenia, jest traktowany jako suma składowych. Metoda SER wykorzystuje rzadką reprezentację, aby dopasować składowe do wzorców ze słownika, umożliwiając skuteczne rozdzielenie części odpowiadających za artefakty od czystego sygnału. Następnie artefakty są usuwane, co pozwala na odzyskanie oryginalnego, oczyszczonego sygnału EEG. Cały proces polega na iteracyjnym dopasowywaniu i aktualizowaniu słownika z pomocą algorytmu K-SVD oraz PCA, aby coraz dokładniej oddzielać zakłócenia od sygnałów. W artykule [39] zaprezentowano metodę usuwania artefaktów z sygnałów EEG, wykorzystującą 1D-CNN (jednowymiarową sieć konwolucyjną) z WDF (ważonymi głębokimi cechami), nazwaną 1D-CNN-WDF. W zaproponowanej metodzie sieć uczy się wydobywać istotne cechy z sygnałów EEG, które następnie są optymalizowane poprzez przypisywanie odpowiednich wag, co umożliwia skuteczniejsze separowanie sygnałów użytecznych od szumów i artefaktów. Kluczową nowością jest zastosowanie hybrydowego algorytmu optymalizacji, łączącego algorytmy COA (Coyote Optimization Algorithm) oraz BSA (Bird Swarm Algorithm), nazwanego HB-COA. Optymalizowano zarówno wagi sieci, jak i liczbę neuronów ukrytych w warstwie, co pozwoliło na lepsze dopasowanie modelu do danych i uniknięcie problemu nadmiernego dopasowania. Dzięki zastosowaniu HB-COA udało się zwiększyć skuteczność oczyszczania sygnałów, redukując złożoność obliczeniową o około 12% w porównaniu do tradycyjnych metod, takich jak PSO (Particle Swarm Optimization) czy BSA. Dodatkowo, nowa metoda poprawiła jakość przetwarzania sygnałów, uzyskując wyższy SNR oraz niższy błąd średniokwadratowy - MSE (Mean Squared Error). Stosunek sygnału do szumu zwiększył się o 59.5% w porównaniu do klasycznych metod, jak SVM (Support Vector Machine) czy LSTM, a MSE zmniejszyło się kilkukrotnie. Celem badania przedstawionego w artykule [40] jest opracowanie metody usuwania artefaktów z sygnałów EEG, która minimalizuje potrzebę ręcznego projektowania

architektur sieci neuronowych przez ekspertów. Autorzy proponują metodę wyszukiwania architektury sieci neuronowych NAS (Neural Architecture Search), opartą na DARTS (Differentiable Architecture Search), w celu automatycznego znalezienia optymalnej struktury sieci do usuwania artefaktów. DARTS pozwala na efektywne przeszukiwanie przestrzeni możliwych architektur poprzez gradientowe uczenie, co znacząco skraca czas potrzebny na znalezienie odpowiedniej sieci w porównaniu do tradycyjnych metod. Autorzy dodatkowo wprowadzają LK-DARTS (duże jądra konwolucyjne), które umożliwiają uchwycenie długoterminowych zależności czasowych w sygnałach EEG. Metoda została przetestowana na zbiorach danych z artefaktami pochodzącymi od aktywności serca, mięśniowymi, elektrookulograficznymi i zakłóceniami spowodowanymi ruchem osoby badanej. Uzyskane wyniki potwierdziły przewagę proponowanej metody nad innymi podejściami. LK-DARTS efektywnie usuwa różne rodzaje artefaktów, przewyższając metody, takie jak EEGIFNet, DARTS oraz rozwiązanie bazujące na sieciach konwolucyjnych. Autorzy wytypowali struktury do usuwania jednego rodzaju artefaktu (mniej skomplikowane) oraz wielu rodzajów artefaktów (znacznie bardziej skomplikowane). W pierwszym przypadku sieć miała 46 milionów parametrów, a w drugim 68 milionów, co wpłynęło również na dłuższy czas obliczeń. W artykule [41] zaprezentowano metodę usuwania artefaktów elektrookulograficznych z sygnałów EEG z użyciem DLN (sieci głębokiego uczenia), eliminując potrzebę dodatkowych kanałów EOG. Struktura sieci składa się z kilku warstw autoenkoderów, które umożliwiają efektywne wychwytywanie i uczenie się kluczowych cech czystego sygnału EEG. Zaproponowane podejście wspomaga działanie modelu w rozróżnianiu sygnałów zawierających artefakty od czystych sygnałów EEG. Metoda składa się z dwóch etapów: offline i online. W trybie offline sieć uczy się wzorców czystych sygnałów EEG na podstawie próbek bez artefaktów, identyfikowanych metodą opartą na kurtozie. Następnie, w trybie online, wytrenowana sieć automatycznie filtruje artefakty z zanieczyszczonych sygnałów w czasie rzeczywistym, bez konieczności ręcznej selekcji. W porównaniu z tradycyjnymi metodami, jak ICA czy SOBI (Second-Order Blind Identification), dla metody DLN można wskazać kilka kluczowych zalet: nie wymaga rejestracji źródeł artefaktów, działa skutecznie nawet z niewielką liczbą kanałów EEG i jest szybsza, co czyni ją odpowiednią do zastosowań online. Wyniki testów wykazały, że DLN lepiej usuwa artefakty i lepiej zachowuje informacje z EEG, szczególnie w porównaniu z ICA i jej wariantami. Opracowany przez autorów [42] model usuwania artefaktów z sygnałów EEG ma na celu uzyskanie czystych sygnałów za pomocą ulepszonej jednowymiarowej sieci neuronowej (1D-CNN), przy użyciu hybrydowego algorytmu metaheurystycznego, nazwanego SM-EFO (Spider Monkey-Based Electric Fish

Optimization). Pierwszą fazą jest trening modelu. Wykorzystano tam sygnały EEG, do których dodane zostały artefakty wywołane pracą mięśni, serca i oczu. Sygnały są dzielone na okna o wymiarach 400×1 , a następnie przekazywane do ulepszonej sieci 1D-CNN, która koncentruje się na usuwaniu artefaktów. W algorytmie SM-EFO optymalizowane są ukryte neurony i liczba epok w 1D-CNN, aby zwiększyć zdolności wyrażania nieliniowości i uzyskać bogatsze cechy. Model korzysta z wielokryterialnej funkcji celu, minimalizując RMSE i PSNR (współczynnik sygnał-szum). Analiza porównawcza proponowanego rozwiązania przeprowadzona została w porównaniu z sieciami 1D-CNN wykorzystujących różne podejścia do optymalizacji: PSO, BSO (Beetle Swarm Optimization), EFO (Electric Fish Optimization) oraz GWO (Grey Wolf Optimization). W artykule [43] przedstawiono metodę DWINet, która wykorzystuje konwolucyjne sieci neuronowe oraz podejście inspirowane technikami poprawy przejrzystości obrazów (dehazing), traktując zadanie usuwania artefaktów EEG w analogiczny sposób. Takie podejście pozwoliło rozwiązać problemy nadmiernego dopasowania i niskiej skuteczności tradycyjnych sieci neuronowych, szczególnie w usuwaniu artefaktów elektrookulograficznych. DWINet korzysta z modułów konwolucyjnych o różnych rozmiarach filtrów, pozwalając na wydobywanie cechy z różnych skali czasowych sygnału EEG. Sieć zawiera również moduł transformacyjny oparty na blokach „bottleneck”, co umożliwia lepsze przetwarzanie złożonych, nieliniowych zależności między czystym a zakłóconym sygnałem. W artykule [44] skupiono się na problemie efektywnego usuwania artefaktów z sygnałów EEG, zwłaszcza w kontekście zdalnego nauczania, gdzie EEG może monitorować zaangażowanie uczniów. Celem było opracowanie szybszej i dokładniejszej metody przetwarzania sygnałów EEG, usuwającej artefakty mięśniowe i elektrookulograficzne, przy jednoczesnym zachowaniu istotnych cech sygnału. Autorzy zastosowali model GCANet, pierwotnie opracowany do poprawy jakości obrazów, który dostosowano do przetwarzania jednowymiarowych sygnałów EEG, zmieniając funkcje 2D na 1D. Sieć opiera się na strukturze koder-dekoder, z blokami konwolucyjnymi i warstwami pooling, które przekształcają zaszumione sygnały w mapy cech. Zastosowano rozszerzone konwolucje, które pozwalają modelowi uwzględniać informacje z szerszego kontekstu przestrzennego bez zwiększania liczby parametrów. Dodatkowo sieć wyposażono w podsystem fuzji cech, który łączy informacje z różnych warstw, co zwiększa dokładność modelu i przyspiesza zbieżność. Model okazał się szczególnie skuteczny w usuwaniu artefaktów mięśniowych, a także dobrze radził sobie z elektrookulograficznymi, choć jego efektywność była nieco niższa w wyższych pasmach częstotliwości. W badaniu wykazano, że zastosowanie technik z dziedziny przetwarzania obrazu do EEG może znacząco poprawić efektywność odszumiania sygnałów jednowymiarowych. W artykule [45]

zaproponowano metodę wykrywania artefaktów w sygnałach EEG, opartą na analizie korelacji między kanałami EEG. Sygnały zostały przekształcone z przestrzeni wielokanałowej na dwuwymiarową mapę współczynników korelacji, która była następnie wprowadzana do sieci CNN, umożliwiając jej rozpoznawanie wzorców związanych z artefaktami. Badania przeprowadzono na danych pochodzących od 15 pacjentów z OIOM, a metoda pozwoliła na uzyskanie dokładności klasyfikacji 92,3% w procedurze walidacji krzyżowej. Omawiane podejście jest skuteczne w redukcji wymiarowości oraz wykrywaniu artefaktów w sygnałach EEG w domenie czasowo-przestrzennej. W porównaniu do metod bazujących na spektrogramach oraz EEGNet, metoda CNN oparta na korelacji uzyskała wyraźną przewagę. Dodatkowo, zaprojektowano uproszczoną wersję, która działa w czasie rzeczywistym z opóźnieniem 0,0181 s. W artykule [46] skupiono się na problemie usuwania artefaktów z sygnałów EEG, proponując nową metodę o nazwie DeepSeparator. Celem metody jest separacja sygnałów mózgowych od zakłóceń, takich jak ruchy oczu i napięcia mięśni, bez potrzeby ręcznego definiowania reguł i wcześniejszej wiedzy o artefaktach. DeepSeparator wykorzystuje sieć neuronową składającą się z trzech głównych elementów: kodera, który wydobywa cechy sygnału, dekompozytora, który wykrywa i tłumi artefakty, oraz dekodera, który rekonstruuje oczyszczony sygnał. Podczas analizy wyników testów na półsyntetycznych i rzeczywistych sygnałach EEG wykazano, że DeepSeparator działa lepiej niż tradycyjne metody, takie jak filtr adaptacyjny, ICA czy EMD (Empirical Mode Decomposition), uzyskując niższy błąd czasowy i częstotliwościowy oraz wyższą korelację sygnału. Metoda ta nie tylko skutecznie usuwa artefakty, ale również oferuje większą interpretowalność wyników dzięki możliwości osobnego wydobywania sygnału i artefaktów. Co istotne, DeepSeparator działa dobrze zarówno na sygnałach jedno-, jak i wielokanałowych, co czyni go elastycznym narzędziem do szerszych zastosowań w przetwarzaniu sygnałów biomedycznych. W pracy [47] skupiono się na problemie usuwania artefaktów elektrookulograficznych z sygnałów EEG, przedstawiając nową metodę hybrydową zwaną DWSAE (Deep Wavelet Sparse Autoencoder). Metoda ta łączy transformację falkową z rzadkim autoenkoderem (Sparse autoencoder), co pozwala na automatyczne usuwanie artefaktów elektrookulograficznych przy jednoczesnym zachowaniu sygnałów EEG. DWSAE działa w trybie nienadzorowanym, co umożliwia zastosowanie jej w czasie rzeczywistym w interfejsach mózg-komputer. Testy przeprowadzono na zestawie danych EEG z zadaniem uwagi wzrokowej, porównując DWSAE z metodami SOBI i WNN (Wavelet Neural Network). Wyniki potwierdzają wyższą skuteczność DWSAE w usuwaniu artefaktów elektrookulograficznych, szczególnie w niższych pasmach częstotliwości, przy jednoczesnym zachowaniu integralności sygnału w pozostałych pasmach.

W odróżnieniu od SOBI, DWSAE jest zdolny do automatycznej pracy na pojedynczych kanałach EEG i nie wymaga ręcznej inspekcji. Ograniczenia innych metod, takie jak potrzeba ręcznego treningu w WNN oraz wizualnej inspekcji w SOBI zostały wyeliminowane, co czyni DWSAE lepszym rozwiązaniem do zadań w czasie rzeczywistym. W artykule [48] przedstawiono metodę usuwania artefaktów z sygnałów EEG o nazwie EEGIFNet, która wykorzystuje architekturę dwugałęziową, umożliwiającą jednoczesne odzyskiwanie zarówno czystego sygnału EEG, jak i samych artefaktów. W każdej z gałęzi zastosowano konwolucyjne warstwy oraz dwukierunkowe jednostki GRU (BiGRU) do wychwytywania lokalnych i globalnych cech sygnałów. Unikalnym elementem jest moduł interakcji, który pozwala na wymianę informacji między obiema gałęziami, co zwiększa efektywność usuwania artefaktów. Po przetworzeniu, dane z obu gałęzi są adaptacyjnie łączone przez moduł fuzji, co pozwala na końcową rekonstrukcję czystego sygnału EEG. W wyniku przeprowadzonych eksperymentów wykazano, że EEGIFNet przewyższa istniejące metody, takie jak FCNN, SCNN czy 1D-ResCNN, uzyskując lepsze wyniki w zakresie poziomów sygnału do szumu. Metoda EEGIFNet okazała się nie tylko skuteczniejsza w usuwaniu artefaktów, ale również bardziej uniwersalna, zdolna do pracy z wieloma rodzajami artefaktów jednocześnie. W artykule [49] zaprezentowano sieć GCTNet, która łączy równoległe bloki sieci konwolucyjnej oraz bloki transformera celem efektywnego oczyszczania jednokanałowych sygnałów EEG z artefaktów. Ta innowacyjna konstrukcja pozwala na uchwycenie zarówno lokalnych, jak i globalnych zależności czasowych, co znacząco poprawia skuteczność usuwania różnorodnych zakłóceń. Kluczowym elementem sieci jest dyskryminator, który ocenia jakość oczyszczonych sygnałów, porównując je z sygnałami EEG pozbawionymi artefaktów. W badaniach wykorzystano różne zestawy danych, zarówno syntetyczne, jak i rzeczywiste, porównując wyniki GCTNet z różnymi metodami oczyszczania. Porównanie dotyczyło między innymi metod hybrydowych takich jak EMD-ICA, EMD-CCA, ale również bardziej zaawansowanych technik opartych na sieciach neuronowych ResCNN, NovelCNN oraz EEGDNet. Autorzy zwracają uwagę na pewne ograniczenia proponowanego rozwiązania dotyczące możliwości oczyszczania tylko jednego kanału oraz konieczność dalszych badań nad poprawą generalizacji modeli na danych rzeczywistych. W pracy [50] przedstawiono metodę SDNet, która łączy segmentację z usuwaniem szumów, aby skutecznie eliminować artefakty ruchowe, elektrookulograficzne oraz mięśniowe z sygnałów EEG. Metoda składa się z sieci segmentacyjnej (ResUnet1D) i odszumiającej i przewyższa tradycyjne podejścia, ponieważ potrafi odróżnić fragmenty sygnału wolne od artefaktów od tych, które są nimi zanieczyszczone. Architektura SDNet umożliwia selektywne usuwanie zakłóceń z sygnału, minimalizując ryzyko zniekształcenia

czystych fragmentów. Eksperymenty przeprowadzone na syntetycznych i rzeczywistych sygnałach EEG oraz trzech typach sieci odsumiającej: SCNN (Simple CNN), RNN oraz ResCNN potwierdzają, że SDNet pozwala na uzyskanie lepszych wyników niż hybrydowe metody, takie jak EEMD-ICA i EEMD-CCA. Proponowane rozwiązanie jest dedykowane do oczyszczania jednokanałowego, jednakże autorzy przebadali oczyszczanie danych wielokanałowych i uznali je za akceptowalne. W artykule [51] opisano metodę usuwania zakłóceń z sygnałów EEG za pomocą sieci AR-WGAN (Wasserstein Generative Adversarial Network) trenowanej na sygnałach syntetycznych (rzeczywiste EEG i sztucznie generowane artefakty). Metoda ta automatycznie rozpoznaje i usuwa artefakty elektrookulograficzne, mięśniowe oraz inne zakłócenia, które obniżają jakość sygnałów EEG. AR-WGAN składa się z dwóch części: generatora, który stara się stworzyć oczyszczony sygnał EEG, i dyskryminatora, który ocenia, czy sygnał pochodzi z rzeczywistych danych. Dzięki współpracy dyskryminatora i generatora, system z czasem generuje sygnały trudne do odróżnienia od rzeczywistych. W modelu zastosowano jednowymiarowe warstwy konwolucyjne, które pozwalają na efektywne wydobywanie kluczowych cech sygnałów EEG i eliminację zakłóceń. Model AR-WGAN został porównany z innymi popularnymi metodami, takimi jak autoenkoder, filtr Wienera oraz EMD. Analiza wyników potwierdza wyższą skuteczność metody AR-WGAN w usuwaniu zakłóceń przy jednoczesnym zachowaniu większej ilości istotnych informacji w porównaniu do innych metod. W artykule [52] opisano nowatorską metodę redukcji artefaktów BCG (balistokardiograficznych) w jednoczesnych nagraniach EEG-fMRI, opartą na rekurencyjnych sieciach neuronowych z jednostkami GRU. Metoda wykorzystuje nieliniowe modelowanie zależności pomiędzy sygnałami EKG a zanieczyszczonymi przez artefakty BCG sygnałami EEG, umożliwiając skuteczniejsze usuwanie tych zakłóceń w porównaniu do tradycyjnych metod, takich jak podejścia oparte na detekcji zespołów QRS i analizie składowych głównych w celu eliminacji powtarzających się artefaktów związanych z aktywnością serca. Sieć neuronowa nazwana BCGNet, przewiduje artefakty BCG dla każdego kanału na podstawie danych z jednego kanału EKG, pozwalając na ich usunięcie z sygnałów EEG. Autorzy przetestowali metodę w różnych pasmach EEG i wykazali, że BCGNet skuteczniej redukuje artefakty niż metoda OBS (Optimal Basis Set), zwłaszcza w zakresie pasma alfa i theta. Dodatkowo, metoda ta nie usuwa istotnych sygnałów mózgowych, co potwierdzono poprawą wyników w zadaniach klasyfikacyjnych. Autorzy publikacji [53] przedstawili metodę usuwania artefaktów z sygnałów EEG z jednego kanału na podstawie sieci DAE (Deep Autoencoder). Rozwiązanie działa w czasie rzeczywistym, a sieć została zaimplementowana na smartfonie przy użyciu TensorFlow Lite. Model DAE jest

zaprojektowany do usuwania zakłóceń związanych z artefaktami takimi jak ruchy gałek ocznych, ruchy ciała oraz aktywność mięśniowa. Przeprowadzone badania potwierdzają, że zaproponowana metoda pozwala na uzyskanie wysokich współczynników korelacji z czystymi sygnałami EEG (Ground-truth), co świadczy o jej skuteczności. Implementacja DAE na smartfonie umożliwia przetwarzanie 4-sekundowych okien EEG w mniej niż 5 milisekund, co sprawia, że jest to rozwiązanie odpowiednie do zastosowań mobilnych w czasie rzeczywistym. Wymagania obliczeniowe i energetyczne DAE są znacznie niższe niż w przypadku FastICA, co czyni go lepszym rozwiązaniem dla urządzeń mobilnych. W artykule [54] przedstawiono metodę opartą na głębokim uczeniu do usuwania artefaktów elektrookulograficznych z sygnałów EEG. U-Net jest konwolucyjną siecią neuronową używaną zwykle do segmentacji obrazów, która na potrzeby badań przeprowadzanych przez autorów została zaadaptowana do oczyszczania sygnałów EEG. Do sieci wejściowej U-Net wchodziły przekształcone na obrazy sygnały EEG po filtracji dolnoprzepustowej, które następnie były przekształcane na obrazy w skali szarości. Najbardziej skutecznym podejściem okazało się trenowanie osobnych modeli U-Net dla każdego kanału EEG. W artykule [55] zaprezentowano model DTP-Net oparty na sieciach neuronowych do usuwania artefaktów z sygnałów EEG w dziedzinie czasowo-częstotliwościowej. Sieć składa się z kodera, separatora i dekodera. Koder przekształca sygnał EEG w jego reprezentację czasowo-częstotliwościową za pomocą konwolucji jednowymiarowej, separator identyfikuje artefakty za pomocą bloków piramid czasowych o zróżnicowanych współczynnikach dylatacji, a dekoderek rekonstruuje oczyszczony sygnał na podstawie reprezentacji czasowo-częstotliwościowej. DTP-Net przewyższa inne nowoczesne metody, takie jak SimpleCNN, 1D-ResCNN i NovelCNN. W artykule [56] przedstawiono model DuoCL, który wykorzystuje połączenie sieci CNN i LSTM do skutecznego usuwania artefaktów z sygnałów EEG. DuoCL działa w trzech fazach: ekstrakcji cech morfologicznych, wzmacniania cech poprzez analizę zależności czasowych oraz rekonstrukcji sygnału EEG bez artefaktów. Metoda bazuje na zestawieniu warstw konwolucyjnych z filtrami o zróżnicowanych rozmiarach z modułem LSTM. Pozwala to na jednoczesne uchwycenie cech morfologicznych i zależności czasowych, zapewniając skuteczniejsze usuwanie artefaktów w porównaniu do innych metod. W testach na syntetycznych zbiorach danych model przewyższył sześć porównywanych metod (między innymi 1D-ResCNN i NovelCNN). Ograniczeniem jest brak wykorzystania korelacji przestrzennej między kanałami, co mogłoby poprawić wyniki w bardziej złożonych scenariuszach. W artykule [57] przedstawiono metodę o nazwie DRNet (Composer Reconstructor Net), zaprojektowaną do usuwania artefaktów elektrookulograficznych i mięśniowych. Główna innowacja DRNet polega na podziale sygnału

EEG na fragmenty czyste i z zakłóceniami, umożliwiając precyzyjne filtrowanie zakłóconych części. Model wykorzystuje dwa główne elementy: dekompozytor i rekonstruktor. Dekompozytor analizuje sygnał i rozbija go na wektory, które przechowują informacje o cechach sygnału oraz zakłóceniach. Następnie rekonstruktor przetwarza wektory, aby odtworzyć sygnał w dziedzinie czasu, usuwając z niego artefakty. Dodatkowo zastosowano połączenie skrótowe SC (Shortcut Connection), które umożliwia selektywne przepuszczanie czystych fragmentów sygnału niewymagających filtracji. Dzięki zastosowaniu bloków Inception (które umożliwiają analizę sygnału z wykorzystaniem różnych rozmiarów filtrów) oraz modułów SE (Squeeze and Excitation) (wspomagających wybór najbardziej istotnych kanałów sygnału na podstawie ich amplitudy), model uzyskuje lepsze wyniki niż inne metody, takie jak DeepSeparator i ResCNN. DRNet cechuje się niższym błędem RRMSE (Relative Root Mean Square Error) i wyższą korelacją sygnału w testach na danych syntetycznych oraz rzeczywistych danych klinicznych. Model działa w czasie rzeczywistym, co czyni go użytecznym w aplikacjach klinicznych, choć w przypadku danych wielokanałowych moduły SC i SE wymagają dalszej optymalizacji. W artykule [58] przedstawiono model do usuwania artefaktów elektrookulograficznych, który opiera się na integracji informacji zarówno z domeny czasowej, jak i częstotliwościowej. Część modelu odpowiedzialna za analizę w dziedzinie czasowej przetwarza sygnał EEG w jego oryginalnej postaci, natomiast komponent częstotliwościowy umożliwia analizę w domenie częstotliwościowej dzięki zastosowaniu DCT (dyskretnej transformacji cosinusowej). W kolejnym etapie, dane z obu komponentów są łączone w tzw. module fuzji, który integruje informacje z obu domen. Dane po fuzji trafiają do różnych architektur sieci neuronowych, takich jak FCNN, SimpleCNN i ResCNN, które są odpowiedzialne za główne przetwarzanie sygnału. Ostatecznym elementem przekształcającym sygnał jest moduł „denoising header”, który rekonstruuje oczyszczony sygnał EEG z połączonych cech uzyskanych w poprzednich etapach. W artykule [59] zaprezentowano nową sieć neuronową MLMRS-Net, zaprojektowaną do usuwania artefaktów ruchowych z sygnałów EEG. Model MLMRS-Net bazuje na jednowymiarowej sieci CNN i wykorzystuje wielopoziomowe podejście do analizy sygnałów dzięki zastosowaniu bloków MRP (Multi-Resolution Pooling), umieszczonych w każdej warstwie kodera i dekodera. Takie podejście pozwala na efektywne wychwytywanie zarówno prostych, jak i złożonych cech sygnału, co umożliwia bardziej precyzyjną eliminację zakłóceń. W proponowanej sieci wyjścia z poziomów kodera są łączone z odpowiednimi warstwami dekodera, pozwalając zachować istotne cechy sygnału na różnych etapach przetwarzania. Sieć poza oczyszczonym sygnałem generuje pięć dodatkowych wyjść, które są równocześnie nadzorowane, co dodatkowo zwiększa jej skuteczność. MLMRS-Net został przetestowany na

jednokanałowych sygnałach EEG z zakłóceniami wywołanymi ruchem ciała i uzyskał wyższą skuteczność w ich redukcji w porównaniu do innych popularnych modeli, takich jak UNet czy FPN. Model przetwarza dane offline, co oznacza, że działa na wcześniej zebranych sygnałach. Innowacyjność MLMRS-Net polega na zdolności do usuwania zakłóceń przy jednoczesnym zachowaniu istotnych dla diagnozy cech biologicznych sygnału EEG, co czyni go szczególnie użytecznym w kontekście zastosowań medycznych. W artykule [60] zaprezentowano model UDNNet, który wprowadza integrację mechanizmu szacowania niepewności z procesem usuwania artefaktów z sygnałów EEG. W modelu zastosowano dwa moduły: UEM (Uncertainty Estimation Module) do oceny niepewności oraz FEM (Feature Enhancement Module) do poprawy jakości sygnałów poprzez uchwycenie lokalnych i globalnych kontekstów za pomocą mechanizmu wieloskalowej uwagi.

2.6. Metody hybrydowe

Metody hybrydowe są wykorzystywane w celu połączenia zalet różnych podejść i zwiększenia skuteczności usuwania artefaktów. Ze względu na złożoność sygnałów EEG, które mogą być zanieczyszczone wieloma rodzajami artefaktów (np. pochodzących od aktywności serca, mięśni, ruchów oczu), pojedyncza technika może nie wystarczyć. Metody hybrydowe umożliwiają efektywne usuwanie artefaktów poprzez łączenie różnych technik, takich jak na przykład ślepa separacja sygnałów (analiza składowych niezależnych), analiza falkowa, klasteryzacja, czy algorytmy uczenia maszynowego. W celu oczyszczania sygnału EEG z artefaktów autorzy [61] proponują wykorzystanie WVFLN (Wavelet Vector Functional Link Network) czyli połączenia transformacji falkowej DWT (Discrete Wavelet Transform), głębokiej sieci neuronowej oraz algorytmu RLS. Na wejście sieci neuronowej podawane są współczynniki po DWT, które w warstwie ukrytej wykorzystywane są jako wagi. Funkcja aktywacji wybrana została jako RBF (radialna). W warstwie wyjściowej wagi aktualizowane są za pomocą algorytmu RLS, co pozwala na minimalizację błędu między sygnałem oczyszczonym, a wzorcowym (czystym). Działanie metody zostało zaprezentowane dla artefaktów elektrookulograficznych, jednakże autorzy twierdzą, że znajdzie również zastosowanie dla pozostałych typów artefaktów. Metoda SSA-CCA (Singular Spectrum Analysis - Canonical Correlation Analysis) opisana w [62], skutecznie usuwa artefakty mięśniowe z sygnałów EEG. Metoda działa poprzez dekompozycję sygnału EEG z wykorzystaniem SSA, która rozdziela sygnał na szereg komponentów rekonstrukcyjnych RCs (Reconstructed Components). CCA identyfikuje komponenty zawierające artefakty mięśniowe, wykorzystując ich niską autokorelację, a następnie usuwa je poprzez wyzerowanie

odpowiednich wierszy macierzy źródłowej. Po zsumowaniu wolnych od artefaktów komponentów RCs, otrzymujemy oczyszczony sygnał EEG. Metoda sprawdza się zarówno dla sygnałów z jednego, jak i kilku kanałów. W porównaniu do innych metod, SSA-CCA uzyskuje lepsze wyniki w usuwaniu artefaktów, zachowując kluczowe informacje z EEG i cechując się mniejszym kosztem obliczeniowym, co czyni ją zdatną do zastosowań w urządzeniach medycznych. W [63] autorzy zaproponowali bardzo podobne podejście, jednakże zamiast SSA wykorzystano EEMD (Ensemble Empirical Mode Decomposition) z CCA. EEMD rozkłada sygnały EEG na składowe IMFs (Intrinsic Mode Functions), które następnie są grupowane i przetwarzane przez CCA w celu oddzielenia artefaktów od właściwych sygnałów mózgowych. Metoda okazała się skutecznie usuwać artefakty mięśniowe w przypadku niskiego stosunku sygnału do szumu i przy ograniczonej liczbie kanałów EEG. Zastosowanie EMD oraz CCA znalazło również zastosowanie w badaniach opisanych w artykule [18]. Zastosowano tam dwustopniowy proces usuwania artefaktów z sygnałów EEG, obejmujący usuwanie artefaktów mięśniowych i elektrookulograficznych. Najpierw, do usunięcia artefaktów mięśniowych użyto metody MEMD-CCA. Proces ten rozpoczął się od dekompozycji 14-kanałowych sygnałów EEG za pomocą MEMD. Następnie, przy pomocy analizy korelacji kanonicznej, rozdzielono źródła artefaktów mięśniowych od sygnałów EEG. Komponenty o niskiej autokorelacji, charakterystyczne dla artefaktów mięśniowych, zostały wyzerowane, a pozostałe zrekonstruowano w celu uzyskania oczyszczonego sygnału EEG. W kolejnym kroku zajęto się usuwaniem artefaktów elektrookulograficznych przy użyciu metody wICA (Wavelet-Independent Component Analysis). Po wstępnej filtracji sygnałów EEG w paśmie 0,5–40Hz, zastosowano analizę ICA w celu dekompozycji sygnału na komponenty niezależne. Artefakty były usuwane poprzez progowanie współczynników uzyskanych w wyniku dekompozycji falkowej, co umożliwiło zachowanie większości istotnych informacji EEG. Na końcu zrekonstruowano sygnał EEG, wolny od zakłóceń. W artykule [64] przedstawiono system analizy sygnałów EEG wykorzystywany do rozpoznawania emocji. Kluczowym elementem był proces usuwania artefaktów, w którym zastosowano filtrację pasmowo-przepustową (na częstotliwościach 0,5-30Hz) oraz metodę wICA, podobnie jak w artykule [18]. Artykuł [65] przedstawia metodę usuwania artefaktów z sygnałów EEG, łączącą CCA z DNN (głęboką siecią neuronową). DNN wyposażona w mechanizm samouwagi (Self-attention mechanism), odpowiada za eliminację artefaktów, zachowując jednocześnie istotne cechy sygnałów EEG. Finalnie sygnały źródłowe są rekonstruowane na poziomie kanałów (elektrod) EEG poprzez zastosowanie macierzy wag odwracającej (pochodzącej z CCA). Struktura sieci neuronowej opiera się na blokach Inception, które analizują sygnały w różnych skalach czasowych,

zwiększając skuteczność w wykrywaniu i usuwaniu artefaktów o różnych częstotliwościach. Z przeprowadzonych eksperymentów wynika, że metoda skutecznie poprawia stosunek sygnału do szumu, szczególnie w obszarach podatnych na zakłócenia, takich jak czołowe partie mózgu. W artykule [66] opisano metodę OS-EHO-CycleGAN służącą do usuwania artefaktów (elektrookulograficznych, mięśniowych oraz powodowanych pracą serca), która łączy DWT (transformację falową), głębokie uczenie maszynowe oraz algorytm optymalizacji OS-EHO (Opposition Searched-Elephant Herding Optimization). Proces usuwania artefaktów z sygnałów EEG opiera się na dekompozycji sygnału przy użyciu EMD oraz adaptacyjnym odsumianiu falowym (wykorzystującym DWT), gdzie kluczowe parametry są optymalizowane przez algorytm OS-EHO. Po etapie odsumiania, sygnał jest dalej przetwarzany przy pomocy sieci generatywnej CycleGAN, która odpowiada za dokładne usunięcie pozostałych artefaktów oraz poprawienie jakości sygnału. Podejście zastosowane w metodzie polega na połączeniu algorytmu optymalizacji metaheurystycznej z głębokim uczeniem maszynowym, umożliwiając bardziej precyzyjne usuwanie artefaktów z sygnałów EEG. OS-EHO optymalizuje progi DWT oraz parametry sieci neuronowej CycleGAN, pozwalając na uzyskanie wyższej jakości odsumionego sygnału bez utraty kluczowych informacji. Symulacje wskazały, że metoda OS-EHO-CycleGAN uzyskuje o ponad 20% wyższą wydajność w porównaniu z innymi algorytmami metaheurystycznymi, takimi jak PSO-CycleGAN, EHO-CycleGAN czy WOA-CycleGAN, Alternatywne podejście NA-FMEMD (Noise-Assisted Fast Multivariate Empirical Mode Decomposition) zaproponowane w [67] łączy adaptacyjną dekompozycję sygnału na podzakresy częstotliwości z analizą kanonicznej korelacji, umożliwiając skuteczne usuwanie artefaktów z EEG zarejestrowanego przy użyciu niewielkiej liczby kanałów. NA-FMEMD rozkłada sygnał na składowe przy jednoczesnym uwzględnieniu wielokanałowej struktury danych i zwiększeniu efektywności obliczeniowej. W kolejnym etapie CCA identyfikuje komponenty zawierające artefakty i usuwa je, zachowując jedynie czyste sygnały EEG. W artykule [68] opisano metodę usuwania artefaktów elektrookulograficznych z sygnałów EEG, łączącą analizę niezależnych komponentów z adaptacyjnym filtrowaniem opartym na algorytmie RLS. Zamiast dedykowanych elektrod EOG, jako sygnały pomocnicze wykorzystano sygnały pochodzące z elektrod zlokalizowanych w pobliżu oczu (*Fp1*, *Fp2*, *F7*, *F8*). Zgromadzone dane przetworzono za pomocą ICA, a następnie oszacowano aktywność związaną z artefaktami na podstawie sygnałów pomocniczych i usunięto ją przy użyciu metody RLS. Wyniki eksperymentów potwierdziły skuteczność metody w eliminacji artefaktów elektrookulograficznych, bez znaczącego zniekształcenia sygnałów mózgowych. Artykuł [69] dotyczył utworzenia głębokiej sieci

neuronowej, która na podstawie rejestrowanych sygnałów EEG pomagałaby klasyfikować znajome i nieznanne dla osoby badanej twarze wyświetlane na ekranie monitora. Jednym z etapów przetwarzania było oczyszczanie sygnałów EEG z artefaktów fizjologicznych i środowiskowych. Proces oczyszczania sygnału przeprowadzono z wykorzystaniem eliptycznego filtra pasmowo przepustowego o zakresie 0,5–50Hz, natomiast do usunięcia artefaktów elektrookulograficznych zastosowano ICA. Oczyszczone sygnały były wprowadzane do sieci neuronowej w celu dalszego przetwarzania i klasyfikacji. W artykule [70] zaproponowano hybrydową metodę usuwania zakłóceń z sygnałów EEG, opartą na filtracji czasowo-przestrzennej i dekompozycji wartości własnych STF-EVD (Spatio Temporal Filtering - Eigenvalue Decomposition). Metoda eliminuje potrzebę stosowania danych kalibracyjnych, ponieważ uczy się statystycznych właściwości sygnałów EEG, co umożliwia równoczesne usuwanie różnych typów zakłóceń. Model został przetestowany na sygnałach EEG od czterech osób po amputacji ramienia, wykonujących pięć różnych zadań związanych z MI (wyobrażeniami ruchu). W porównaniu do innych metod, takich jak STF czy ICA-INFOMAX, proponowana metoda poprawiła dokładność klasyfikacji. Rozwiązanie przedstawione w [71] dotyczy automatycznej klasyfikacji komponentów niezależnych ICs (Independent Components,) w zapisach EEG i MEG, które również opiera się na wykorzystaniu konwolucyjnych sieci neuronowych. Klasyfikacja dotyczyła wyboru komponentów ICs jako pochodzących od aktywności bioelektrycznej mózgu lub artefaktów. Sieć miała dwie równoległe ścieżki wejściowe: jedna przetwarzała mapy topograficzne, a druga widma komponentów niezależnych. Składała się z trzech warstw konwolucyjnych, każda z 4, 8 i 16 filtrami, po których następowały warstwy max pooling i warstwa w pełni połączona. Na końcu sieci znajdowała się warstwa SoftMax, która klasyfikowała komponenty jako pochodzące od artefaktów lub pochodzące z mózgu. Autorzy podkreślają, że dotychczas klasyfikacja ICs była wykonywana przez ekspertów na podstawie wizualnej analizy czasowej, spektralnej i topograficznej, co było czasochłonne i podatne na błędy. Alternatywą były metody automatyczne, które wymagały ręcznej ekstrakcji specyficznych cech, takich jak wariancja, kurtoza, maksymalna amplituda oraz specyficzne właściwości topograficzne. Wyniki przeprowadzonych badań potwierdzają, że CNN może samodzielnie dokonać klasyfikacji ICs bez potrzeby wcześniejszej selekcji tych cech, uzyskując wysoką dokładność (92,4% dla EEG, 95,4% dla MEG i 95,6% dla połączonych danych EEG i MEG). Sieć CNN była porównywana z tradycyjnymi metodami klasyfikacji opartymi na cechach, takimi jak LDA (Linear Discriminant Analysis), SVM (Support Vector Machine) oraz płytkie sieci neuronowe, przy czym sieć CNN okazała się bardziej precyzyjna. Eksperti byli zaangażowani jedynie

w początkowe etykietowanie danych do treningu modelu. W artykule podkreślono, że CNN może stać się nowym standardem w automatycznej klasyfikacji ICs, oferując efektywność i niezawodność. Problematyka automatycznej klasyfikacji komponentów jest często poruszana w literaturze. Zaprezentowano ją również w artykułach [72], [73]. W badaniu opisanym w [73] wykorzystano sztucznie generowane sceny w środowisku VR (wirtualnej rzeczywistości), które miały na celu odwzorowanie sytuacji takich jak zmiany postrzeganej wysokości czy niewielkie zaburzenia równowagi. Uczestnicy z nałożonymi goglami VR stali na platformie i byli poddawani ekspozycji na różne wirtualne wysokości oraz zaburzenia równowagi, co miało na celu wywołanie reakcji mózgowych przy jednoczesnym generowaniu artefaktów w rejestrowanych sygnałach EEG. Po akwizycji sygnałów EEG, przeprowadzono analizę składowych niezależnych, aby wyodrębnić komponenty związane z aktywnością bioelektryczną mózgu i artefaktami, takimi jak ruchy mięśni czy mrugnięcia. Klasyfikacja składowych odbyła się automatycznie na podstawie kolorowych map topograficznych przy użyciu głębokiej sieci neuronowej, która rozróżniała składowe związane z aktywnością bioelektryczną mózgu od składowych związanych z artefaktami. Model CNN, który wykorzystano do klasyfikacji, składał się z 8 warstw konwolucyjnych z funkcją aktywacji ReLU, normalizacją wsadową, warstwami dropout oraz max pooling, a także dwóch w pełni połączonych warstw z funkcją aktywacji ReLU. Ważnym elementem badania było ręczne oznaczenie składowych przez doświadczonego specjalistę, co pozwoliło na porównanie działania sieci z oceną eksperta. Wyznaczona dla modelu dokładność klasyfikacji komponentów wyniosła 89%. W artykule [74] przedstawiono model głębokiego uczenia dedykowany wykrywaniu i usuwaniu artefaktów elektrookulograficznych z sygnałów EEG. Proponowane rozwiązanie opiera się na wykorzystaniu sieci konwolucyjnej DCN (Optimized Deformable Convolution Network), która została dostosowana za pomocą algorytmu optymalizacji DS-EFO (Distance Sorted-Electric Fish Optimization). Proces detekcji obejmuje dekompozycję sygnału przy użyciu 5-poziomowej dyskretnej transformacji falkowej oraz dekompozycji harmonicznej Pisarenki, pozwalając na wyodrębnienie cech sygnału. Następnie wyznaczone cechy są przetwarzane za pomocą analizy składowych głównych oraz analizy składowych niezależnych. Zebrane cechy są wprowadzane do DCN, która wykrywa artefakty elektrookulograficzne. Gdy artefakty zostaną wykryte, model przechodzi do fazy ich usuwania poprzez zastosowanie dekompozycji sygnału techniką EMCD (Empirical Mean Curve Decomposition). Następnie sieć DCN usuwa szumy, a sygnał jest rekonstruowany przy użyciu odwrotnej EMCD, umożliwiającą uzyskanie oczyszczonego sygnału EEG. Proponowany model DS-EFO-DCN uzyskuje wyższą skuteczność w porównaniu do metod takich jak sieci

neuronowe, SVM, kombinacja EMCD+DPE-EWA-LWT oraz sieci DCN. Przeprowadzone analizy potwierdziły przewagę DS-EFO-DCN pod względem dokładności wykrywania i usuwania artefaktów elektrookulograficznych z sygnałów EEG. Autorzy planują dalsze badania i optymalizacje proponowanego rozwiązania. W artykule [75] zaprezentowano metodę usuwania artefaktów mrugnięcia oczu z sygnałów EEG. W przeciwieństwie do tradycyjnych podejść, w proponowanej metodzie sygnały EEG są przekształcane na obrazy przedstawiające zmiany sygnałów w czasie, co umożliwia zastosowanie algorytmów segmentacji obrazu do precyzyjnej identyfikacji obszarów zawierających artefakty. Spośród kanałów EEG wybrano takie, które były najbardziej podatne na zakłócenia, a następnie odpowiadające im sygnały przekształcono w obrazy, stanowiące dane wejściowe dla sieci FCN (Fully Convolutional Network) opartej na ResNet. Sieć skutecznie identyfikowała obszary sygnału zawierające artefakty. W efekcie filtr Butterwortha zastosowano wyłącznie do fragmentów uznanych za zakłócone i dzięki temu uniknięto filtrowania całego sygnału, a także ograniczono utratę istotnych danych. Wyniki analiz potwierdzają wysoką skuteczność metody, dzięki której uzyskano 94,4% skuteczności detekcji artefaktów, a metryki takie jak NMSE (znormalizowany średni błąd kwadratowy) oraz SSIM (wskaźnik podobieństwa strukturalnego) wskazują na brak zniekształceń w sygnałach pozbawionych artefaktów ($NMSE = 0$, $SSIM = 1$). Zastosowanie proponowanego rozwiązania pozwala na skuteczną eliminację artefaktów mrugania, jednocześnie zachowując integralność pozostałych części sygnału. W porównaniu do tradycyjnych metod, takich jak ICA czy DWT, które często usuwają fragmenty całych sygnałów, proponowane rozwiązanie selektywnie filtruje jedynie zanieczyszczone fragmenty, co czyni je bardziej precyzyjnym i efektywnym narzędziem do analizy sygnałów EEG. W artykule [76] opisano wpływ artefaktów elektrookulograficznych, mięśniowych oraz powodowanych pracą serca na systemy oparte na głębokim uczeniu, wykorzystywane do klasyfikacji faz snu z wykorzystaniem sygnałów EEG. Główna część artykułu przedstawia porównanie tradycyjnych metod eliminacji artefaktów, takich jak filtracja, FastICA, Infomax i SOBI oraz wprowadzenie nowej metody SOBI-WT, która łączy podejście SOBI z WT (transformacją falkową). SOBI-WT działa poprzez dekompozycję sygnału EEG na niezależne składowe, a następnie zastosowanie transformacji falkowej i progowania do dalszej filtracji artefaktów. W artykule zwrócono uwagę na znaczenie właściwego przetwarzania sygnałów EEG przed ich analizą przez modele głębokiego uczenia, które może istotnie poprawić wyniki klasyfikacji.

2.7. Wnioski z przeglądu literatury

W trakcie przeglądu literatury zapoznano się z licznymi pracami naukowymi, obejmującymi szeroki zakres metod wykorzystywanych w analizie sygnałów EEG. Opisywane podejścia różniły się m.in. sposobem identyfikacji i usuwania artefaktów, złożonością obliczeniową oraz stopniem ingerencji w dane. Wśród analizowanych rozwiązań znalazły się zarówno klasyczne metody, takie jak regresja liniowa czy analiza składowych niezależnych, jak i bardziej złożone techniki hybrydowe, łączące różne strategie przetwarzania sygnału. Część metod opierała się na wykorzystaniu dodatkowych elektrod rejestrujących aktywność związaną z artefaktami, takich jak regresja, natomiast inne, jak ICA, działały niezależnie od ich obecności. W przypadku ICA istotnym etapem jest wybór liczby komponentów, na które rozkładany jest sygnał, a następnie identyfikacja i usunięcie tych zawierających artefakty. Kwalifikacja komponentów wymaga jednak zazwyczaj wiedzy eksperckiej oraz doświadczenia w interpretacji ich cech, co utrudnia pełną automatyzację analizy.

Podczas przeglądu literatury skupiono się także na wykorzystaniu sztucznych sieci neuronowych. Omówiono wiele różnych architektur i zauważono, że konwolucyjne sieci neuronowe są szeroko stosowane w zadaniach związanych z eliminacją artefaktów z sygnałów EEG, między innymi ze względu na ich zdolność do automatycznego wydobywania istotnych cech przestrzennych. W wielu pracach wykazano skuteczność CNN w detekcji komponentów zawierających artefakty oraz przetwarzaniu sygnałów zakłóconych, co czyni je cennym narzędziem w analizie EEG. Aby efektywnie modelować zależności czasowe i uchwycić dynamikę sygnału, coraz częściej stosuje się rekurencyjne sieci neuronowe, takie jak LSTM, które dzięki swojej strukturze bardzo dobrze radzą sobie z analizą sekwencji czasowych. Połączenie LSTM z warstwami konwolucyjnymi umożliwia jednocześnie wydobywanie cech przestrzennych i czasowych, co zwiększa efektywność analizy sygnałów EEG.

Istotnym wyzwaniem w analizie rzeczywistych danych EEG pozostaje ocena jakości sygnałów, szczególnie w kontekście usuwania artefaktów.

3. Materiał badawczy

W rozdziale przedstawiono materiał badawczy zgromadzony na użytek realizacji rozprawy doktorskiej. Efektem długotrwałej pracy było utworzenie dwóch baz danych zawierających zarówno sygnały EEG, jak i EMG, zarejestrowane od kilkunastu ochotników.

Rozdział przedstawia zarówno aspekty techniczne, takie jak wykorzystany sprzęt, sposób przeprowadzania akwizycji, szczegóły dotyczące umieszczenia elektrod, ale również aspekty formalne związane z celem badań i uzyskaniem zgody Zespołu ds. etyki i badań naukowych z udziałem ludzi. W rozdziale zaprezentowano także sposób generowania sygnałów EEG oraz EMG i artefaktów mięśniowych wykorzystanych do treningu modeli uczenia głębokiego.

3.1. Zgoda Zespołu ds. etyki i badań naukowych z udziałem ludzi

W celu przeprowadzenia badań EEG, które muszą być realizowane w warunkach bezpośredniej interakcji z uczestnikami (w tym fizycznego przygotowania do pomiaru oraz rejestracji danych wrażliwych), wystąpiono do Zespołu ds. etyki i badań naukowych z udziałem ludzi z wnioskiem o wydanie „opinii o zgodności projektu badania naukowego z udziałem ludzi z zasadami etyki”. Pozytywna opinia ma zasadnicze znaczenie dla przeprowadzanych badań EEG zapewniając, że cały proces badawczy jest zgodny ze wszelkimi standardami etycznymi oraz prawnymi. Proces uzyskiwania opinii obejmował szczegółową analizę metodologii badania, procedur związanych z przeprowadzaniem akwizycji, a także przegląd ryzyka i korzyści płynących z badania dla badanych ochotników oraz nauki.

Pozytywna opinia została wydana przez Zespół ds. etyki i badań naukowych z udziałem ludzi w formie certyfikatu w dniu 21.02.2024r. Komisja stwierdziła, że projekt badań spełnia standardy etyczne.

W ramach opracowywania wniosku sporządzono także drugi dokument, którym był „Formularz zgody na udział w badaniu”, przedstawiony w Załączniku 8.1. Dokument został utworzony, aby przed przystąpieniem do badania każdy kandydat mógł dokładnie zapoznać się z celem, procedurą badawczą oraz możliwymi niedogodnościami. Formularz zawierał także oświadczenie o dobrowolnym udziale. Po zapoznaniu się z dokumentem, uczestnik podpisywał oświadczenie i przystępował do badania. Przed rozpoczęciem eksperymentu każda osoba była informowana o jego planowanym przebiegu, a w trakcie badania istniała możliwość uzyskania dodatkowych informacji lub rezygnacji z dalszego udziału. Po zakończonym badaniu uczestnikom proponowano ćwiczenia redukujące zmęczenie oczu i zadawano pytanie odnośnie samopoczucia.

3.2. Autorska baza artefaktów

Utworzenie autorskiej bazy artefaktów mięśniowych obecnych w sygnałach EEG stanowiło istotny element badań i obejmowało rejestrację jedenastu zróżnicowanych typów artefaktów z wykorzystaniem ośmiu elektrod EEG oraz ośmiu elektrod EMG. Celem zadania było nie tylko zgromadzenie obszernego materiału badawczego, ale także identyfikacja źródeł i analiza artefaktów, które w największym stopniu wpływają na zakłócenie sygnału EEG. Uczestnikami badania było 12 ochotników wśród których znaleźli się zarówno pracownicy, jak i studenci Politechniki Warszawskiej. Przedział wiekowy badanych osób wynosił 22-56 lat, a średni wiek $34,4 \pm 12,7$. Uczestnicy przystępujący do badania byli wypoczęci i zrelaksowani. Aby umożliwić precyzyjną akwizycję w badaniach wykorzystano specjalistyczny sprzęt. Był to wzmacniacz sygnałów bioelektrycznych g.Tec g.USBamp 2.0 oraz seria aktywnych elektrod g.LADYBIRD. Wzmacniacz podłączony był do laptopa z wykorzystaniem przewodu USB, gdzie dokonywany był zapis sygnałów na dysku twardym. Rejestrację sygnałów przeprowadzono z użyciem oprogramowania OpenViBE, które wybrano ze względu na możliwość synchronizacji wyświetlanych użytkownikowi poleceń w formie graficznej z jednoczesnym zapisem jego sygnału EEG. Częstotliwość próbkowania sygnału wynosiła 4800 Hz. Zdecydowano o wyborze wysokiej częstotliwości próbkowania celem przeprowadzenia dokładnej analizy artefaktów. Artefakty mięśniowe charakteryzują się szerokim zakresem częstotliwości oraz gwałtownymi zmianami amplitudy. Wysoka rozdzielczość czasowa umożliwiła wierne odwzorowanie kształtu artefaktów oraz identyfikację ewentualnych cech obecnych w wyższych pasmach, które mogłyby nie zostać zarejestrowane przy standardowej częstotliwości próbkowania. Podczas akwizycji sygnały były filtrowane wstępnie za pomocą filtra górnoprzepustowego i dolnoprzepustowego w paśmie 1-1000 Hz. Dodatkowo usunięto zakłócenia sieciowe (50 Hz) z wykorzystaniem środkowo-zaporowego filtra Butterwortha czwartego rzędu o paśmie 48-52 Hz. Zastosowanie tak wysokiej częstotliwości próbkowania było związane zarówno z dostępnością tej opcji we wzmacniaczu g.Tec, jak i z dążeniem do pełnego wykorzystania jego możliwości technicznych oraz zapewnienia możliwie najwyższej dokładności rejestracji artefaktów do dalszej analizy. W trakcie przeprowadzania rejestracji, program prezentował na ekranie monitora polecenia, które badana osoba miała wykonywać przy jednoczesnej akwizycji sygnałów EEG. W celu kontroli eksperymentu i oceny jakości sygnałów możliwa była jednoczesna prezentacja przebiegów czasowych i widma osobie przeprowadzającej badanie.


Przed przystąpieniem do rejestracji sygnałów EEG/EMG przeprowadzono rozmowę z osobą badaną i udzielono wszelkich niezbędnych wyjaśnień dotyczących przebiegu badania. Następnie umieszczono elektrody na głowie i twarzy osoby badanej i uruchamiano sesję testową celem obserwacji sygnałów. Po etapie przygotowawczym następowała zasadnicza część eksperymentu, którą była akwizycja sygnałów. Akwizycja rozpoczynała się od wyświetlenia „Krzyża fiksacji” podczas którego osoba badana miała skupić na nim uwagę i zrelaksować się, nie wykonując przy tym żadnych gwałtownych ruchów. W ten sposób rejestrowano sygnał referencyjny (baseline) z możliwie minimalnym poziomem artefaktów, służący jako punkt odniesienia. W dalszej części eksperymentu rejestrowano celowo wywoływane artefakty, a każdy z nich był wykonywany dobrowolnie przez osobę badaną przez okres 20 sekund. Kolejne artefakty oddzielone były od siebie 10 sekundową przerwą, podczas której wyświetlany był „Krzyż fiksacji”. Po zrealizowaniu całego programu badań prezentowana była plansza informująca o zakończeniu eksperymentu. Sygnały były zapisywane i katalogowane, a następnie zdejmowano elektrody EMG oraz czepek z głowy badanego, dbając przy tym o jego komfort i wygodę. W tabeli 1 przedstawiono rejestrowane artefakty oraz skrócone instrukcje wykonania artefaktu.

Dzięki zastosowaniu precyzyjnie rozmieszczonych elektrod, możliwe było uchwycenie różnorodnych zakłóceń pochodzących z różnych części głowy, twarzy oraz mięśni, co pozwoliło na dokładne zrozumienie charakterystyk i źródeł artefaktów. Do badania wykorzystano zestaw 8 elektrod umieszczonych zgodnie z systemem 10-20. Elektrody służyły do pomiarów aktywności mózgowej EEG: *Oz*, *P4*, *P3*, *Cz*, *F4*, *F3*, *F9* oraz okulograficznej EOG: *Fp1*. Elektrody umieszczone były w czepku EEG z jednoczesną aplikacją żelu przewodzącego celem zapewnienia lepszego kontaktu elektrody ze skórą głowy osoby badanej. Elektrody *O1*, *O2* oraz *Oz* są często wykorzystywane do transferu informacji w interfejsach mózg-komputer związanej z klasyfikacją SSVEP. Dokładne zbadanie propagacji artefaktów na elektrody EEG pozwala na określenie ich wpływu na rejestrację potencjałów wywołanych bodźcami wzrokowymi w stanie ustalonym. W badaniu wykorzystano także 8 elektrod EMG celem rejestracji zakłóceń pochodzących od aktywności mięśniowej podczas wykonywania artefaktów przez osobę badaną. Nazwy elektrod w większości pochodzą od miejsca ich umieszczania. Były to elektrody *VEOG*, *HEOG*, *Policzek*, *Usta*, *Nos*, *Broda*, *Kark* oraz *Szczeka*. Podczas rejestracji sygnałów bioelektrycznych możliwe jest występowanie sygnałów EEG nie tylko na elektrodach przeznaczonych do ich pomiaru, ale również na kanałach EMG i EOG. Analogicznie, sygnały EMG mogą być obecne zarówno na dedykowanych elektrodach

Tabela 1. Artefakty rejestrowane podczas badania celem utworzenia bazy danych.

Nazwa artefaktu	Opis wykonania
Grymas twarzy	Badany proszony był o wykonanie wyrazistego grymasu twarzy, polegającego na marszczeniu brwi z jednoczesnym unoszeniem kącików ust, utrzymując wyraz przez około sekundę, a następnie powrót do neutralnego wyrazu.
Mruganie	Badany był proszony o wykonanie mrugnięcia, zamykając i otwierając powieki w normalnym tempie.
Ruchy oczu (prawo, lewo)	Badany proszony był o przesuwanie wzroku w prawo, a następnie w lewo, starając się trzymać głowę w bezruchu.
Ruchy oczu (góra, dół)	Badany proszony był o kierowanie wzroku ku górze, a następnie ku dołowi, bez poruszania głową.
Zaciskanie szczęki	Badany proszony był o zaciskanie zębów na około sekundę, a następnie zwalnianie uścisku.
Ruchy językiem	Badany proszony był o wykonanie ruchów językiem przesuwając go wewnątrz jamy ustnej, delikatnie dotykając nim na wewnętrznej stronie obu policzków (naprzemiennie).
Napinanie mięśni karku	Badany proszony był o delikatne napięcie mięśni karku, przez podniesienie barków i napięcie szyi, a po około sekundzie relaksację.
Nadymanie policzków	Badany proszony był o nabranie głębokiego wdechu przez usta, zatrzymanie powietrza na chwilę oraz napięcie policzków, a następnie powolne wypuszczenie powietrza.
Mrużenie oczu	Badany proszony był o zmrużenie oczu, zaciskając lekko powieki przez krótką chwilę, a następnie ich rozluźnienie.
Oddychanie	Badany miał wykonywać spokojne, miarowe wdechy nosem i wydechy ustami, próbując pozostać w bezruchu.
Przełykanie śliny	Badany proszony był o wykonanie świadomego przełknięcia śliny, odczekując kilka sekund przed kolejnym powtórzeniem.

mięśniowych, jak i na kanałach EEG oraz EOG. Z kolei na elektrodach EOG mogą pojawiać się sygnały pochodzenia zarówno okulograficznego, jak i mózgowego oraz mięśniowego. Tego rodzaju propagowanie się sygnałów wynika z fizycznej bliskości źródeł. Przyjęte rozmieszczenie elektrod pozwoliło na pokrycie głowy oraz większości najistotniejszych partii mięśniowych głowy i szyi, pozwalając na rejestrację artefaktów mięśniowych oraz elektrookulograficznych. Dobór umieszczenia elektrod dokonany był w oparciu o literaturę [77], [78] oraz konsultacje z neurofizjologiem i został zaprezentowany na rysunku 2. Do umieszczenia elektrod EMG na skórze osoby badanej wykorzystano specjalne naklejki oraz żel przewodzący aplikowany między elektrodę, a skórę głowy. Elektroda referencyjna służąca jako punkt odniesienia dla pomiarów napięcia przez elektrody aktywne była przypinana do płatka ucha osoby badanej.



Rysunek 2. Przedstawienie rozkładu elektrod podczas tworzenia bazy artefaktów.

Parametry techniczne badania dotyczące rejestracji sygnałów EEG/EMG zestawiono w tabeli 2.

Tabela 2. Parametry techniczne badania.

Parametr	Opis
Częstotliwość próbkowania	4800Hz
Wzmacniacz	g.Tec g.USBamp 2.0
Elektrody użyte w badaniu	Aktywne elektrody g.LADYBIRD (16): <i>Oz, P4, P3, Cz, F4, F3, F9, Fp1, VEOG, HEOG, Policzek, Usta, Nos, Broda, Kark, Szczęka</i>
Filtry zakłóceń	Eliminacja zakłóceń sieciowych 50Hz (48–52Hz) – środkowo-zaporowy filtr Butterwortha 4-go rzędu
Filtr sygnału	Pasmo 1–1000Hz – filtr górnoprzepustowy i dolnoprzepustowy
Liczba uczestników	12

W kolejnym etapie przeprowadzono szczegółową ocenę zarejestrowanych artefaktów w celu określenia, które z nich mają największy wpływ na jakość sygnałów EEG i SSVEP, a także które elektrody są najbardziej podatne na poszczególne typy zakłóceń. Ocena obejmowała analizę sygnałów zarówno w dziedzinie czasu, jak i częstotliwości, obliczenie

mocy sygnałów dla każdego artefaktu na wszystkich elektrodach oraz wizualizację uzyskanych rozkładów mocy na powierzchni modelu głowy. Na podstawie przeprowadzonej analizy wytypowano zestaw elektrod umożliwiający rejestrację różnorodnych artefaktów, niezależnie od źródeł ich pochodzenia. Tak zoptymalizowany zestaw nie tylko usprawnił identyfikację zakłóceń, lecz również przyczynił się do standaryzacji procedur rejestracyjnych oraz redukcji liczby elektrod. Identyfikacja artefaktów o największym wpływie na sygnał EEG pozwala na dokładną analizę i opracowanie skutecznych metod ich eliminacji. W rezultacie pierwsza baza sygnałów dostarczyła nie tylko cennych informacji na temat natury i źródeł artefaktów, ale również umożliwiła ustalenie minimalnego zestawu elektrod pozwalającego na rejestrację różnorodnych artefaktów. Dodatkowo wytypowano artefakty mające największy wpływ na akwizycję sygnałów EEG i SSVEP.

3.3. Autorska baza sygnałów SSVEP z artefaktami zaciskania szczęki


Baza danych opisana w punkcie 3.2 dotyczyła rejestracji różnorodnych artefaktów z wykorzystaniem 16 elektrod EEG oraz EMG. Wykonane analizy pozwoliły przebadать charakterystyki i właściwości poszczególnych artefaktów, a także określić ich źródła, co umożliwiło wybór uniwersalnego zestawu 9 elektrod. Zastosowanie zredukowanego zestawu pozwala na ograniczenie wykorzystywanej podczas akwizycji liczby elektrod bez utraty istotnych informacji o artefaktach. W badaniach skupiono się również na identyfikacji artefaktów najsilniej zakłócających częstotliwości charakterystyczne dla SSVEP, które są szeroko wykorzystywane w interfejsach mózg-komputer.

W pracy zaproponowano nowatorskie podejście, w którym potencjały SSVEP wykorzystano jako element odniesienia do oceny jakości oczyszczania sygnału EEG. Założono, że prawidłowo działająca metoda usuwania artefaktów powinna eliminować wyłącznie zakłócenia, pozostawiając w sygnale odpowiedź wywołaną przez stymulację wzrokową. Umożliwia to jednoznaczną ocenę, czy sygnał po oczyszczeniu nadal zawiera pożądany komponent SSVEP. Takie podejście pozwala na obiektywną weryfikację skuteczności metod, nawet mimo braku dostępu do wzorcowego „czystego” sygnału.

Zastosowanie proponowanego rozwiązania wymaga więc utworzenia kolejnej bazy danych i akwizycji sygnałów EEG zawierających jednocześnie artefakty oraz SSVEP. W tym kontekście zaprojektowano specjalny eksperyment, w którym u uczestników wywoływane były SSVEP z jednoczesnym wymuszeniem artefaktów. W akwizycji wzięło udział 17 ochotników w przedziale wiekowym 18-40 lat. Każda z osób wyraziła zgodę na rejestrację sygnałów EEG wedle przygotowanego formularza (Załącznik 8.1). Do badań przystąpiły tylko osoby

spełniające kryteria jakimi były: brak stwierdzonych chorób neurologicznych, osoba wypoczęta i wyspana, nie będąca pod wpływem alkoholu i środków odurzających.

Rejestracja sygnałów EEG z SSVEP w obecności artefaktów pozwoliła na dokładne testowanie nowo opracowanych algorytmów do usuwania zakłóceń, wykorzystując SSVEP jako wzorzec odniesienia. Na podstawie przeprowadzonych badań jako artefakt najsilniej zakłócający sygnał EEG wskazano zaciskanie szczęki. Zakłócenia pochodzące z aktywności mięśni twarzy i szyi propagują się na wiele elektrod EEG i są szczególnie wyraźne na elektrodzie *Oz*. Zaciskanie szczęki nie wymaga ruchów głowy ani oczu, co umożliwia jednoczesną rejestrację artefaktu oraz ciągłą obserwację bodźców świetlnych wywołujących odpowiedzi SSVEP. Artefakt ten charakteryzuje się dużą amplitudą oraz szerokim zakresem częstotliwości i posiada cechy typowe dla zakłóceń elektromiograficznych. Z tych powodów zaciskanie szczęki zostało wykorzystane podczas akwizycji danych jako reprezentatywny przykład zakłóceń mięśniowych. Do akwizycji danych w ramach drugiej bazy zastosowano zredukowany zestaw elektrod, wybrany na podstawie analiz wskazujących konfigurację umożliwiającą skuteczną rejestrację sygnałów EEG oraz artefaktów mięśniowych. Były to elektrody *O1*, *O2*, *Oz*, związane z rejestracją SSVEP, *Cz*, *Fp1*, związane z EOG oraz cztery elektrody EMG: *HEOG*, *Kark*, *Policzek* oraz *Szczęka*. Łącznie w celu utworzenia bazy wykorzystano dziewięć elektrod oraz elektrodę referencyjną przytwierdzaną do płatka ucha osoby badanej. Umieszczenie elektrod obrazuje rysunek 3.



Rysunek 3. Graficzne przedstawienie rozkładu elektrod podczas tworzenia drugiej bazy artefaktów.

W badaniu wykorzystano ten sam sprzęt, którym dokonano rejestracji bazy artefaktów opisywanej w punkcie 3.2. Parametry akwizycji oraz samo stanowisko uległo jednak zmianie. Po przeprowadzeniu analizy sygnałów zarejestrowanych z częstotliwością 4800 Hz

stwierdzono, że większość charakterystycznych cech artefaktów zawiera się w zakresie częstotliwości dobrze reprezentowanym przy znacznie niższej rozdzielczości czasowej. Dodatkowo, zdecydowana większość energii tych artefaktów koncentruje się w paśmie częstotliwości do około 100 Hz. W związku z tym, do dalszych eksperymentów przyjęto częstotliwość próbkowania równą 256 Hz. Pozwoliło to na znaczną redukcję objętości danych oraz uproszczenie procesu analizy, bez utraty istotnych informacji niezbędnych do skutecznej identyfikacji i przetwarzania zarówno sygnałów EEG, jak i artefaktów. Do akwizycji wykorzystano utworzone do tego celu stanowisko badawcze składające się z panelu z diodami LED na którym wyświetlane były bodźce o określonej częstotliwości wywołujące SSVEP. Pomieszczenie, w którym prowadzono akwizycję, było dobrze izolowane akustycznie, a oświetlenie zredukowane, aby minimalizować wpływ czynników mogących rozpraszać uwagę uczestników. Podczas wykonywania eksperymentu osoba nadzorująca miała wgląd w rejestrowane sygnały i mogła kontrolować ich jakość. Stanowisko badawcze zaprezentowano na rysunku 4.



Rysunek 4. Stanowisko badawcze.

Przed rozpoczęciem eksperymentu uczestnik był szczegółowo informowany o jego przebiegu i miał możliwość zadawania dodatkowych pytań dotyczących samego procesu badawczego. Przed badaniem każda osoba proszona była o wypełnienie i podpisanie kwestionariusza, w którym znajdowały się szczegółowe informacje o badaniu oraz jego przebiegu. Uczestnik składał również pisemne oświadczenie, że nie cierpi na choroby

neurologiczne, nie jest pod wpływem alkoholu ani substancji odurzających. Przed przystąpieniem do kolejnych etapów badania uczestnik pytany był kontrolnie o komfort i samopoczucie. Następnie osobie badanej zakładano czepek EEG z elektrodami aktywnymi (*O1, O2, Oz, Cz, Fp1*) umieszczonymi na skórze głowy, a także przyklejano elektrody EMG przy pomocy naklejek na twarzy i karku (*HEOG, Kark, Policzek* oraz *Szczęka*). Aby umożliwić kontakt elektrod ze skórą, aplikowano żel przewodzący między elektrodę, a skórę. Kolejnym krokiem była weryfikacja jakości zarejestrowanych sygnałów. W dalszym etapie osoba poproszona była o wykonanie następujących czynności: siedzenie w spokojnej pozycji i obserwowanie wyświetlanego na monitorze „Krzyża fiksacji”, a następnie zaciskanie szczęki. Każda z wymienionych czynności trwała 60 sekund. W kolejnym etapie eksperymentu uczestnikowi prezentowano panel z diodami LED, z których każda emitowała impulsy świetlne o jednej z losowo wybranych częstotliwości: 6Hz, 7Hz, 8Hz, 9Hz lub 25Hz. Następnie osoba ponownie proszona była o zaciskanie szczęki. Wszystkie wykonywane czynności były rejestrowane podczas obserwacji monitora. Łączny czas akwizycji sygnału bez pobudzenia oraz z pobudzeniem wynosił 240 sekund. Osoba badana mogła przerwać eksperyment w dowolnym momencie, jeśli poczułaby dyskomfort. Po zakończeniu eksperymentu, uczestnik proszony był o ocenę swojego komfortu oraz informację, czy jego samopoczucie uległo zmianie w porównaniu do stanu sprzed badania. Czas trwania całego badania, łącznie z wyjaśnieniem celu badania, wypełnieniem kwestionariusza, nałożeniem czepka EEG, naklejeniem elektrod EMG oraz przeprowadzeniem eksperymentu, wynosił 30 minut. Po zakończeniu akwizycji uczestnikowi delikatnie zdejmowano elektrody, a pozostałości żelu były usuwane. Opis poszczególnych etapów badania zamieszczono w tabeli 3.

Do akwizycji danych wykorzystano oprogramowanie opracowane w środowisku Matlab, które umożliwiło precyzyjne zbieranie, przetwarzanie oraz wizualizację sygnałów podczas badania. W celu zapewnienia wysokiej jakości danych, zastosowano specjalistyczne filtry. Filtr środkowo-zaporowy (Butterwortha czwartego rzędu) został użyty do eliminacji zakłóceń sieciowych o częstotliwości 50Hz, obejmując zakres 48–52Hz. Dodatkowo, do przetwarzania sygnału EEG zastosowano filtr pasmowy (Butterwortha ósmego rzędu) z zakresem 1–100Hz, co pozwoliło na skuteczne zachowanie istotnych komponentów sygnału mózgowego. Zestawienie parametrów technicznych badania zaprezentowano w tabeli 4.

Podczas akwizycji zgromadzono 48 sygnałów z różnymi częstotliwościami SSVEP, pochodzących z 48 rejestracji przeprowadzonych z udziałem czternastu z siedemnastu badanych użytkowników. W tabeli 5 zestawiono liczbę zarejestrowanych sygnałów SSVEP odpowiadających poszczególnym częstotliwościom pobudzenia: 6Hz, 7Hz, 8Hz, 9Hz i 25Hz.

Tabela 3. Opis etapów eksperymentu związanych z akwizycją bazy artefaktów i SSVEP.

Etap eksperymentu	Opis etapu	Czas
Rozmowa wstępna	Omówienie celu i przebiegu eksperymentu oraz odpowiedzi na pytania uczestnika.	5 minut
Kwestionariusz dotyczący badania	Wypełnienie formularza informacyjnego i oświadczeń dotyczących stanu zdrowia.	2 minuty
Przygotowanie uczestnika	Założenie czepka EEG i umieszczenie elektrod EMG.	10 minut
Kontrola sygnałów	Sprawdzenie jakości sygnałów i ewentualne korekty.	2 minuty
Spoczynkowe EEG	Rejestracja sygnałów w stanie spoczynku.	1 minuta
Stymulacja SSVEP	Prezentacja bodźców świetlnych wywołujących SSVEP.	1 minuta
Wykonywanie artefaktów	Rejestracja sygnałów podczas wykonywania zaciskania szczęki.	1 minuta
Wykonywanie artefaktów z jednoczesnym SSVEP	Rejestracja sygnałów podczas stymulacji SSVEP z jednoczesnym wykonywaniem zaciskania szczęki.	1minuta
Zdejmowanie elektrod	Delikatne zdejmowanie elektrod i usuwanie pozostałości żelu.	5 minut
Zakończenie badania	Ocena komfortu uczestnika i podsumowanie badania.	2 minuty

Tabela 4. Parametry techniczne badania.

Parametr	Opis
Częstotliwość próbkowania	256Hz
Elektrody użyte w badaniu	Aktywne elektrody g.LADYBIRD: O1, Oz, O2, Cz, Fp1, HEOG, Kark, Policzek, Szczęka
Filtry zakłóceń	Eliminacja zakłóceń sieciowych 50Hz (48–52Hz) – środkowo-zaporowy filtr Butterwortha 4-go rzędu
Filtr sygnału	Pasma 1–100Hz – filtr Butterwortha 8-go rzędu
Liczba uczestników	17

Tabela 5. Liczba zarejestrowanych sygnałów SSVEP zarejestrowanych dla poszczególnych częstotliwości pobudzenia.


Częstotliwość pobudzenia SSVEP	Liczba sygnałów
6	6
7	14
8	13
9	6
25	9

W przypadku trzech z siedemnastu uczestników eksperymentu, nie udało się uzyskać SSVEP, w związku z czym osoby te zostały wyłączone z eksperymentu i zestawienia wyników. Uczestnicy ci zostali poproszeni o generowanie różnych artefaktów fizjologicznych, takich jak

zaczyskanie szczęki, grymas twarzy, mruganie, przełykanie śliny, ruchy oczu oraz inne. Warto zaznaczyć, że wymienione artefakty mogły być wykonywane równocześnie, co wprowadziło wyjątkowo trudne warunki do rejestracji sygnałów EEG. Mimo, że zarejestrowane sygnały nie zawierały odpowiedzi typu SSVEP, okazały się przydatne do oceny skuteczności wybranych metod oczyszczania w obecności silnych artefaktów. Czas trwania rejestracji artefaktów wynosił 60 sekund.

3.4. Generator sygnałów EEG oraz artefaktów mięśniowych

Rzeczywiste sygnały elektroencefalograficzne są często zanieczyszczone różnorodnymi artefaktami powstającymi podczas przeprowadzania badań, co utrudnia ich prawidłową analizę i interpretację. Brak dostępu do sygnału odniesienia, który reprezentowałby wzorcowy sygnał EEG, stanowi istotne wyzwanie w ocenie efektywności metod oczyszczania. W celu przeprowadzenia oceny efektywności metod eliminacji artefaktów, opracowano oprogramowanie umożliwiające generowanie syntetycznych sygnałów EEG pozbawionych zakłóceń oraz symulację artefaktów mięśniowych. Dzięki zaproponowanej procedurze, możliwe było porównanie skuteczności różnych metod oczyszczania sygnałów, gdyż dysponujemy zarówno zanieczyszczonym sygnałem EEG, jak i jego czystym odpowiednikiem, który powinien zostać uzyskany po zastosowaniu procesu oczyszczania. Dane uzyskane z generatora umożliwiły również przeprowadzenie treningu sieci neuronowej. Ogólny schemat blokowy generatora zaprezentowany został na rysunku 5. Generator sygnałów EEG oraz artefaktów składa się z dwóch bloków funkcjonalnych: Generatora sygnałów EEG oraz Generatora artefaktów mięśniowych. W tym podrozdziale zamieszczony został szczegółowy opis działania każdego z bloków, analiza porównawcza generowanych sygnałów z sygnałami rzeczywistymi, a także zastosowanie generatora w uczeniu maszynowym.



Rysunek 5. Schemat blokowy generatora sygnałów EEG z artefaktami.

3.4.1. Generator sygnałów EEG

Efektem działania generatora jest uzyskanie jednokanałowego sygnału EEG, który ma jak najbardziej przybliżać rzeczywistą aktywność mózgu pozbawioną artefaktów. Generowanie rozpoczyna się od wyselekcjonowania fragmentów sygnałów EEG bez artefaktów. Do tego celu wybrano rejestracje EEG, podczas których badana osoba siedziała nieruchomo z otwartymi oczami. Sygnały selekcjonowane były na podstawie inspekcji wizualnej jako okna 1 sekundowe (przy częstotliwości próbkowania równej 256Hz) i na potrzeby generacji wybrano

jedynie sygnały z trzech elektrod EEG ($O1$, Oz , $O2$). W celu prawidłowego generowania sygnałów, okna zastosowane w generatorze dobrano w oparciu o przeprowadzoną analizę artefaktów mięśniowych i sygnałów EEG oraz konsultacje ze specjalistą z zakresu neurofizjologii. Sztucznie generowane sygnały zawierały 256 próbek.

Proces generowania syntetycznych sygnałów rozpoczynał się od etapu augmentacji. Na losowo wybranym, jednosekundowym fragmencie sygnału EEG zastosowano odpowiednie przekształcenia mające na celu zwiększenie jego różnorodności. Augmentacja obejmowała operacje zarówno w dziedzinie czasu, jak i częstotliwości, a wartości i zakresy współczynników modyfikujących dobrane zostały eksperymentalnie podczas porównań generowanych sygnałów syntetycznych z sygnałami rzeczywistymi.

Przekształcenia sygnału EEG w dziedzinie częstotliwości realizowano z wykorzystaniem FFT (szybkiej transformaty Fouriera). Proces ten umożliwiał przekształcenie sygnału z dziedziny czasu do dziedziny częstotliwości, co pozwoliło na modyfikację jego charakterystyk widmowych i fazowych. W pierwszym kroku każdy kanał sygnału EEG poddawano transformacji FFT. Następnie, w dziedzinie częstotliwości dokonywano losowych zmian zarówno amplitudy, jak i fazy poszczególnych składowych częstotliwościowych. Amplitudy skalowano przez losowe współczynniki z określonego zakresu (od 0,8 do 1,2), a do fazy każdej składowej dodawano losowe przesunięcie (w zakresie od $-\pi$ do π). Po wprowadzeniu modyfikacji, zmienione widmo przekształcano z powrotem do dziedziny czasu za pomocą IFFT (odwrotnej transformaty Fouriera). Na koniec sygnał był normalizowany, aby jego amplituda odpowiadała oryginalnej skali.

W ramach augmentacji zastosowano również przesunięcie sygnału EEG w czasie. Wykorzystano przesunięcie cykliczne, polegające na przemieszczeniu sygnału o losowo wybraną liczbę próbek w zakresie od -20 do 20. Przesuwano dane w taki sposób, aby zachować ich ciągłość. Próbkę wypadającą z jednej strony sygnału były przenoszone na jego przeciwny koniec.

Kolejną operacją zastosowaną w procesie augmentacji było dodanie szumu o rozkładzie Gaussa. Tego rodzaju zakłócenia odzwierciedlają zmiany amplitudy sygnału typowe dla rzeczywistych rejestracji EEG, wynikające m.in. z szumów termicznych aparatury, artefaktów czujników oraz zakłóceń elektrycznych obecnych w otoczeniu pomiarowym [79]. Proces ten przebiegał dwuetapowo. Najpierw generowano szum o rozkładzie normalnym, którego amplituda była skalowana względem odchylenia standardowego analizowanego sygnału (na poziomie 10%). Następnie tak przygotowany szum dodawano do sygnału EEG, co pozwalało

na wprowadzenie kontrolowanych zniekształceń odwzorowujących warunki rejestracji w środowisku rzeczywistym.

Po dokonaniu augmentacji uzyskiwano syntetyczny sygnał EEG, który odwzorowywał aktywność mózgową i nie zawierał artefaktów pochodzenia mięśniowego ani okulograficznego. W kolejnych etapach procesu, sygnał pełnił rolę zmiennej przewidywanej.

3.4.2. Generator artefaktów mięśniowych

Proces generacji sygnałów EMG przebiegał podobnie do zastosowanego w przypadku sygnałów EEG. Wykorzystano fragmenty przebiegów pochodzące z pięciu elektrod EMG wybranych w wyniku przeprowadzonych wcześniej analiz. Na podstawie wizualnej oceny dokonano selekcji fragmentów sygnału EMG odpowiadających naturalnej, niewymuszonej aktywności mięśniowej. Wybrane fragmenty sygnałów EMG zostały wykorzystane do utworzenia zbioru danych, który następnie poddano przekształceniom mającym na celu zwiększenie jego różnorodności. Przekształcenia obejmowały transformację Fouriera (FFT), przesunięcia czasowe oraz dodanie szumu.

W kolejnym etapie do zróżnicowanego zbioru sygnałów EMG, reprezentujących naturalną aktywność mięśniową, dodano syntetyczne sygnały EMG, odwzorowujące artefakty towarzyszące zaciskaniu szczęki. Ten typ artefaktu został wybrany na podstawie szczegółowej analizy, która wykazała, że zaciskanie szczęki to najsilniejszy artefakt, powodujący powstawanie zakłóceń w szerokim paśmie częstotliwości. Generowanie sztucznych artefaktów przebiegało w dwóch etapach i bazowało na charakterystykach oraz parametrach statystycznych rzeczywistych artefaktów, które posłużyły jako wzorzec. Pierwszym krokiem była parametryzacja, która polega na ustaleniu kluczowych właściwości artefaktów, takich jak czas trwania, amplituda oraz parametry rozkładu częstotliwości (średnia i odchylenie standardowe). W kolejnym kroku generowany był sygnał artefaktu poprzez sumowanie sygnałów sinusoidalnych o różnych częstotliwościach (od 0 do 128Hz) i fazach zgodnie z ustalonymi parametrami (od 0 do 2π). Możliwość modyfikacji tych parametrów pozwala na symulowanie różnych przebiegów artefaktów, odpowiadających różnym źródłom zakłóceń. Następnie, wygenerowany wstępnie sygnał modyfikowany był przez okno czasowe o kształcie Gaussa, celem zachowania natury artefaktu zaciskania szczęki jakim jest jego charakterystyczne narastanie i wygaszanie. Parametry krzywej dzwonowej były losowe (odchylenie standardowe w zakresie od 10 do 80 i średnia w zakresie od 1 do 255). Następnie, oprócz standardowego działania generatora artefaktów mięśniowych, w 20% przypadków dodawany był dodatkowy efekt tzw. „pływania elektrod”. Efekt polegał na wprowadzeniu do

sygnału powolnych oscylacji o niskich częstotliwościach (1–3Hz), które symulowały ruchy elektrod względem skóry. Działanie to zrealizowane zostało poprzez dodanie do sygnału EEG sinusoid o losowej częstotliwości z zakresu 1–3Hz i fazie z przedziału $0-2\pi$. Każda sinusoida była dodatkowo skalowana przez dwa czynniki: losową wartość z przedziału 0–2 oraz zakres amplitudy danego kanału EEG (różnicę między wartościami maksymalną i minimalną). Tak przekształcone sinusoidy dodawane były niezależnie do każdego kanału. Efektem działania generatora było uzyskanie syntetycznych sygnałów EMG z dodanymi artefaktami zaciskania szczęki, które odzwierciedlały rzeczywiste zakłócenia obserwowane w sygnałach.

3.4.3. Syntetyczne zapisy EEG z artefaktami mięśniowymi

W poprzednich etapach wygenerowano zbiór sygnałów EEG i sygnałów EMG reprezentujących artefakty mięśniowe imitujące zaciskanie szczęki. W celu uzyskania syntetycznych zapisów EEG zawierających artefakty, do sygnałów EEG wprowadzono zapisy mięśniowe odpowiadające wcześniej wygenerowanym sygnałom EMG. Proces ten ma na celu symulowanie sytuacji rzeczywistych, w których zakłócenia z kanałów EMG wpływają na sygnały rejestrowane na elektrodach EEG. Na początku utworzony zostaje artefakt będący sumą ważoną pięciu sztucznych sygnałów EMG. Artefakt ten propagowany jest docelowo na kanał EEG, jednak zanim to nastąpi przeprowadza się skalowanie i pozycjonowanie artefaktu. W etapie skalowania artefakt jest mnożony przez losowy współczynnik (od 0,5 do 1), który dostosowuje jego amplitudę do pożądaných wartości. Kolejnym etapem jest określenie próbki sygnału EEG, od której rozpoczyna się dodawanie artefaktu. Wybór próbki jest dowolny i może obejmować cały zakres sygnału. Tak przygotowany artefakt jest sumowany z sygnałem EEG. Dzięki kontroli nad skalowaniem, czasem wystąpienia artefaktu i wykorzystaniu losowych współczynników propagacji, możliwe jest generowanie realistycznych zakłóceń, które wiernie odwzorowują rzeczywiste warunki pomiarowe. Kolejnym etapem jest zestawienie sygnału EEG z artefaktami z pięcioma wygenerowanymi sygnałami EMG, co pozwala na uzyskanie macierzy o wymiarach 6×256 , obejmującej sygnały z artefaktami.


Podsumowując, proces generowania syntetycznych danych EEG z artefaktami mięśniowymi polega na tworzeniu par sygnałów: oryginalnego, wolnego od zakłóceń EEG oraz jego zakłóconej wersji zestawionej z komponentami EMG zawierającymi artefakty zaciskania szczęki. Tak przygotowany zestaw może zostać wykorzystany jako dane uczące dla sieci głębokich.

Zaproponowany sposób generacji został zaprojektowany tak, aby generowane sygnały w jak największym stopniu odzwierciedlały sygnały otrzymane podczas rzeczywistych akwizycji.


Wykorzystane podejście zapewnia także różnorodność danych dzięki zastosowaniu wielu losowych modyfikacji współczynników. Jest to bardzo istotne z punktu treningu modeli uczenia maszynowego, gdyż pomaga uniknąć ich przeuczenia podczas procesu nauki. Ponadto generator pozwala na łatwe skalowanie procesu generacji umożliwiające wygenerowanie dowolnej liczby sygnałów. Niewątpliwą zaletą generatora jest możliwość tworzenia dużych zbiorów danych z niewielkiej liczby sygnałów wejściowych, co znacznie redukuje koszty i czas związany z pozyskiwaniem rzeczywistych sygnałów EEG.

3.4.4. Porównanie sygnałów zarejestrowanych i syntetycznych

Porównanie danych rzeczywistych, pozyskanych podczas akwizycji sygnałów, z danymi wygenerowanymi za pomocą generatora, ma na celu ocenę ich jakości i zgodności. Na obu rysunkach (6 i 7), zaprezentowano sygnały EEG i EMG. Rysunek 6 przedstawia fragment sygnałów rzeczywistych. Bardzo dobrze widoczny jest na nim artefakt zaciskania szczęki. Przedstawiono tam również widmo elektrody Oz. Łatwo zauważyć, że wszystkie elektrody EEG zakłócone są przez artefakt mięśniowy związany z zaciskaniem szczęki. Na rysunku 7 przedstawiono syntetyczne sygnały EEG z artefaktami mięśniowymi.



Rysunek 6. Fragment rzeczywistego sygnału EEG zarejestrowanego podczas sesji pomiarowej wraz z widocznym artefaktem zaciskania szczęki.



Rysunek 7. Fragment sztucznie wygenerowanego sygnału z artefaktem mięśniowym.

Analizując przebiegi i widma (rysunki 6 i 7), można zauważyć, że generator tworzy przebiegi zbliżone do rzeczywistych. W celu porównania generowanych sygnałów w odniesieniu do rzeczywistych sprawdzono wizualne podobieństwo i porównano szereg parametrów statystycznych dla wielu okien, między innymi średnią arytmetyczną, odchylenie standardowe, współczynnik skośności, kurtozę oraz przeanalizowano otrzymane widma. Na potrzeby treningu sieci neuronowej postanowiono wygenerować dane, które obejmą szerszy zakres wartości w porównaniu do sygnałów rzeczywistych. Wygenerowane dane EEG/EMG charakteryzowały się rozszerzonym marginesem wartości maksymalnych i minimalnych. Rozszerzony zakres danych treningowych pozwala uniknąć nadmiernego dopasowania modelu do ściśle określonego, wąskiego zbioru danych, co mogłoby ograniczać jego zdolności predykcyjne w bardziej zróżnicowanych warunkach. W celu porównania danych rzeczywistych i wygenerowanych, przedstawiono parametry sygnałów obliczone dla 1000 jednosekundowych okien. Tabela 6 zawiera obliczone parametry dla danych rzeczywistych, natomiast tabela 7 dotyczy danych wygenerowanych przy użyciu generatora. Wszystkie okna dotyczą przebiegów z artefaktami. Średnia moc w dziedzinie czasu została obliczona z wykorzystaniem wzoru (3.1)

$$P_x = \frac{1}{N} \sum_{n=0}^{N-1} |x[n]|^2 \quad (3.1)$$

gdzie N to liczba próbek w oknie, a $x[n]$ to wartość n -tej próbki.

Tabela 6. Parametry sygnałów obliczone dla 1000 jednosekundowych okien z sygnałów rzeczywistych.

Kanał	Średnia	Std	Mediana	Min	Max	Skośność	Kurtoza	Moc
EEG	-0,77	24,17	-0,69	-169,1	277,3	0,09	5,4	584,9
Fp1	-2,23	97,67	1,59	-764,6	620,2	-0,44	11,0	9544,8
HEOG	-0,03	38,60	2,97	-228,8	329,3	-0,10	6,1	1490,2
Kark	-0,83	30,31	-3,24	-159,0	197,2	1,21	5,7	919,4
Policzek	-1,20	43,63	1,87	-245,5	394,3	0,36	6,5	1904,9
Szczeka	-1,83	72,28	-2,89	-479,7	427,2	0,09	3,0	5228,0

Tabela 7. Parametry sygnałów obliczone dla 1000 jednosekundowych okien utworzonych z wykorzystaniem generatora sygnałów.


Kanał	Średnia	Std	Mediana	Min	Max	Skośność	Kurtoza	Moc
EEG	1,80	34,70	0,84	-297,75	395,23	0,16	5,50	1207,0
Fp1	1,53	60,25	0,57	-728,92	751,55	0,08	10,90	3632,7
HEOG	1,19	59,51	0,41	-704,76	779,22	-0,03	11,02	3542,9
Kark	5,33	91,02	0,64	-767,89	911,27	0,33	6,92	8313,8
Policzek	1,36	63,51	0,48	-731,55	686,88	-0,02	11,25	4035,4
Szczeka	-1,81	61,65	-0,66	-826,92	729,61	-0,02	10,97	3803,5

Analiza parametrów przedstawionych w tabelach 6 i 7 wskazuje, że dane syntetyczne generowane przez model charakteryzują się szerszym zakresem wartości niż dane rzeczywiste zarejestrowane podczas eksperymentów. Zostało to celowo uwzględnione na etapie projektowania generatora, aby zapewnić większą różnorodność danych wykorzystywanych do treningu sieci neuronowej. Ujęcie również silniejszych zakłóceń umożliwia modelowi lepsze uogólnienie i przygotowanie do sytuacji, w których artefakty przyjmują bardziej ekstremalne formy, np. w warunkach silnego napięcia mięśniowego czy zakłóceń technicznych. W tabeli 8 przedstawiono parametry dotyczące 1000 okien sygnałów EEG pozbawionych artefaktów dla danych rzeczywistych i syntetycznych. Rzeczywiste sygnały EEG zarejestrowane podczas prezentacji „Krzyża fiksacji” zestawiono z sygnałami generowanymi przez generator jako sygnały pozbawione artefaktów.

Tabela 8. Parametry sygnałów obliczone dla 1000 jednosekundowych okien bez artefaktów z sygnałów rzeczywistych oraz wygenerowanych za pomocą generatora.

Sygnał	Średnia	Std	Mediana	Min	Max	Skośność	Kurtoza	Moc
Rzeczywisty	0,02	9,24	0,04	-64,7	68,6	0,09	2,4	85,4
Generator	0,26	9,65	0,15	-79,68	79,67	0,24	2,97	93,2

Na rysunku 8 przedstawiony został histogram próbek rzeczywistych oraz generowanych (bez artefaktów).




Rysunek 8. Histogramy porównawcze rozkładów sygnałów EEG bez artefaktów: rzeczywistych oraz generowanych za pomocą generatora.

Analiza histogramów przedstawionych na rysunku 8 wskazuje istotne podobieństwo pomiędzy rzeczywistymi sygnałami EEG a sygnałami syntetycznymi. Rozkłady danych generowanych cechują się szerszym zakresem amplitud, co miało na celu zwiększenie ich różnorodności na potrzeby treningu sieci neuronowej. Takie podejście umożliwia lepsze uogólnienie modelu i zwiększa jego odporność na zakłócenia o zmiennym i nieprzewidywalnym charakterze.

3.4.5. Zastosowanie generatora sygnałów w uczeniu maszynowym

Generator sygnałów może być wykorzystywany do oceny skuteczności metod usuwania artefaktów, a także do trenowania modeli uczenia maszynowego, dzięki możliwości tworzenia zbiorów danych obejmujących zarówno niezakłócone, jak i celowo zanieczyszczone sygnały EEG. Dane pochodzące z generatora umożliwiają trening sieci CNN-LSTM zaproponowanej w celu usuwania artefaktów zgodnie ze schematem przedstawionym na rysunku 9. Na wejście sieci wprowadzany jest jeden kanał sygnału EEG z zakłóceniami oraz kanały EMG, które zawierają informacje o aktywności mięśniowej. Na wyjściu sieci CNN-LSTM uzyskiwany jest jeden kanał oczyszczonego sygnału EEG, pozbawiony zakłóceń.



Rysunek 9. Idea zaproponowanej sieci CNN-LSTM do usuwania artefaktów.

Kluczowym wyzwaniem w przedstawionym podejściu był dobór architektury i odpowiednich parametrów poszczególnych warstw sieci CNN-LSTM. Skuteczność działania sieci CNN-LSTM w oczyszczaniu rzeczywistych sygnałów EEG w dużej mierze zależy od jakości i reprezentatywności danych treningowych. Podczas implementacji generatora dołożono więc wszelkich starań, aby tworzone syntetyczne sygnały EEG i EMG jak najwierniej odwzorowywały rzeczywiste właściwości tych sygnałów, w tym ich charakterystykę czasowo-częstotliwościową.

4. Metody badawcze

W rozdziale przedstawiono metody badawcze zastosowane w procesie oczyszczania sygnałów EEG z artefaktów. Zaprezentowane zostały niezbędne procedury i techniki przetwarzania danych, a także szczegółowo opisano algorytmy i parametry wykorzystane do eliminacji zakłóceń. Przedstawione zostały tutaj zarówno tradycyjne, jak i nowoczesne podejścia wykorzystujące zaawansowane algorytmy i techniki uczenia głębokiego. Wybór metod omawianych w pracy doktorskiej uwarunkowany jest uwzględnieniem kanałów EMG, które reprezentują źródła zakłóceń. Takie podejście pozwala na wykorzystanie dodatkowych informacji dotyczących artefaktów i daje nadzieję na lepsze oczyszczanie sygnałów EEG. Istotnym problemem poruszonym w rozdziale jest także ocena jakości i skuteczności oczyszczania sygnałów EEG oraz sposoby weryfikacji uzyskiwanych wyników.

4.1. Metody usuwania artefaktów

Podrozdział zawiera opis wybranych metod eliminacji artefaktów. Analiza porównawcza algorytmów miała na celu ocenę ich skuteczności oraz identyfikację mocnych i słabych stron poszczególnych podejść. W ramach przeprowadzonych badań porównano sześć różnych metod oczyszczania sygnałów EEG: analizę składowych niezależnych, regresję liniową, filtry adaptacyjne RLS i LMS, filtrację tradycyjną oraz autorską sieć neuronową CNN-LSTM. Sieć CNN-LSTM została opracowana na podstawie analizy różnych wariantów architektur hybrydowych łączących warstwy konwolucyjne i rekurencyjne. Model był trenowany na danych syntetycznych uzyskanych przy użyciu utworzonego generatora sygnałów EEG i artefaktów. Skuteczność zaproponowanej sieci CNN-LSTM porównano z pozostałymi metodami zarówno dla syntetycznych danych pochodzących z generatora, jak również dla rzeczywistych danych z SSVEP. Analiza uzyskanych wyników wskazuje na wysoką efektywność zaproponowanego rozwiązania w zakresie redukcji artefaktów, przy minimalnej ingerencji w istotne komponenty sygnału EEG.

4.1.1. Sieć neuronowa o architekturze CNN-LSTM


Konwolucyjne sieci neuronowe [80], wykorzystywane są najczęściej w problemach związanych z wizją komputerową oraz przetwarzaniem języka naturalnego. Sieci CNN można wykorzystać nie tylko w problemach związanych z klasyfikacją, ale również z regresją. Cechą charakterystyczną sieci konwolucyjnych w porównaniu z tradycyjnymi sieciami neuronowymi jest fakt, że podczas swojego działania CNN skupiają się na ekstrakcji cech i redukcji liczby parametrów [80]. Każda sieć konwolucyjna składa się z czterech podstawowych warstw:

warstwy konwolucyjnej (występują w niej filtry o zadanych kształtach pozwalające na ekstrakcję cech, dane wyjściowe podlegają przepuszczeniu przez funkcję aktywacji), pooling layer (wyróżniamy kilka rodzajów warstw typu pooling, na przykład Max Pooling lub Average Pooling służą zmniejszeniu rozmiaru analizowanych danych), fully connected layer (polegająca na połączeniu neuronów z warstwy poprzedniej z neuronami z warstwy kolejnej) i loss layer (odpowiedzialna za wyliczanie błędów między aktualnym oraz pożądanym wyjściem sieci). Istnieje bardzo wiele struktur sieci CNN, które mogą różnić się liczbą warstw, kształtem oraz wymiarem filtrów, funkcjami aktywacji i innymi parametrami. Przykładami bardzo popularnych sieci mogą być AlexNet, GoogLeNet oraz VGGNet [80], [81].

Sieci LSTM (Long Short-Term Memory) [82] stanowiące rozwinięcie klasycznych RNN (rekurencyjnych sieci neuronowych), zostały zaprojektowane z myślą o modelowaniu danych sekwencyjnych, takich jak tekst, mowa czy przebiegi czasowe. W odróżnieniu od tradycyjnych RNN, LSTM potrafią efektywnie przechowywać i wykorzystywać informacje z dłuższych przedziałów czasowych dzięki zastosowaniu specjalnych jednostek pamięci oraz mechanizmów bramek: zapominania, wejściowej i wyjściowej [83]. Każda z bramek pełni określoną funkcję w sterowaniu przepływem informacji, umożliwiając sieci „pamiętanie” lub „zapominanie” określonych danych w zależności od ich istotności dla zadania. Taka konstrukcja pozwala na przezwycięzenie problemu zanikającego gradientu typowego dla standardowych RNN [83]. Sieci LSTM wykorzystywane są zarówno w klasyfikacji, jak i regresji [84]. Znajdują szerokie zastosowania w prognozowaniu i analizie szeregów czasowych, przetwarzaniu języka naturalnego NLP (Natural Language Processing), analizie tekstu i wielu innych [85]. Przykładem powszechnie stosowanej architektury opartej na LSTM jest architektura Seq2Seq (Sequence-to-Sequence) [86], szeroko wykorzystywana w zadaniach dotyczących tłumaczenia języka.

Tematyka prowadzonych badań dotyczyła wykorzystania połączenia sieci konwolucyjnych i rekurencyjnych CNN-LSTM na użytek oczyszczania sygnałów EEG z artefaktów. Warstwy konwolucyjne odpowiadają za identyfikację wzorców przestrzennych, natomiast LSTM umożliwia modelowanie zależności czasowych. Dodatkowo, w odróżnieniu od części istniejących metod, uwzględniono zależności przestrzenne pomiędzy kanałami dzięki zastosowaniu konwolucji dwuwymiarowej, co może przyczynić się do poprawy jakości oczyszczonego sygnału. Schemat przedstawiający postępowanie umożliwiające osiągnięcie zamierzonego efektu przedstawiono na rysunku 10. Sieć trenowana i walidowana była na syntetycznych danych wygenerowanych przez generator (podrozdział 3.4). Tak przygotowany

model umożliwił usuwanie artefaktów z sygnałów rzeczywistych. Bardzo istotną kwestią był wybór architektury, parametrów treningu oraz sposób oceny jakości oczyszczanych sygnałów.



Rysunek 10. Etapy przetwarzania sygnałów z wykorzystaniem sieci CNN-LSTM.

Dobór struktury sieci nadającej się do realizacji zadania eliminacji artefaktów wymagał przeprowadzenia wielu badań, w trakcie których skupiono się na zapewnieniu kompromisu między czasem działania, a skutecznością oczyszczania sygnału z zakłóceń.

W ramach przeprowadzonych eksperymentów badawczych przetestowano wiele różnych architektur sieci neuronowych, obejmujących różnorodne typy warstw, takie jak konwolucyjne: jedno i dwuwymiarowe, LSTM, warstwy gęsto połączone (Dense) oraz uśredniające, a także różne funkcje aktywacji. Zaobserwowano, że szczególnie dobre rezultaty przynosi połączenie przetwarzania zarówno w wymiarze przestrzennym, jak i czasowym. Z tego względu w projektowanych modelach uwzględniono nie tylko warstwy konwolucyjne, ale również warstwy rekurencyjne (LSTM) oraz gęsto połączone. Wykazano również, że skuteczne uwidocznienie amplitudy prążka widma odpowiadającego częstotliwości SSVEP w oczyszczonych sygnałach zależy od odpowiedniej liczby cech przekazywanych z warstw konwolucyjnych do warstwy LSTM. Zbyt mała liczba filtrów skutkowała osłabieniem sygnału SSVEP względem jego wersji przed oczyszczaniem. Dobór liczby jednostek w warstwie LSTM był bardzo istotny, gdyż wpływał znacząco na skomplikowanie modelu. Zbyt mało jednostek powodowało znaczące uproszczenie modelu przez co charakterystyczny dla sygnałów EEG kształt w dziedzinie czasowej i częstotliwościowej był znacznie uproszczony i pozbawiony szczegółów. Określono, że liczba kilkunastu jednostek LSTM wystarcza do zachowania niezbędnych wzorców. Ostatnią warstwą zawsze była warstwa gęsto połączona z liniową funkcją aktywacji celem predykcji oczyszczonego sygnału w dziedzinie czasu.

Uczenie i testowanie modeli przeprowadzono na danych syntetycznych, uzyskanych za pomocą opracowanego generatora sygnałów EEG i artefaktów. Wygenerowane przez generator sygnały były dzielone losowo na treningowe (70%), walidacyjne (15%) i testowe (15%). Liczba przykładów treningowych została wyznaczona w oparciu o treningi i testy na różnej wielkości

zbiorach. Dla 150 000 przykładów treningowych proces uczenia sieci trwał długo, a jakość oczyszczanych sygnałów była porównywalna, jak w przypadku modeli trenowanych na mniejszych zbiorach treningowych. W końcowym modelu zdecydowano o wyborze 80 000 przykładów (56000 treningowych, 12000 walidacyjnych i 12000 testowych). Informacje dotyczące podziału wygenerowanych danych zestawiono w tabeli 9.

Tabela 9. Podział danych wygenerowanych na użytek trenowania, walidacji i testowania CNN-LSTM.

Podzbiór danych	Liczba sygnałów	Procent danych	Zastosowanie
Trening	56000	70%	Dane używane do nauki sieci, w celu optymalizacji wag.
Walidacja	12000	15%	Dane używane podczas treningu do monitorowania wydajności modelu.
Testy	12000	15%	Dane służące do oceny jakości modelu po zakończeniu nauki.

Zbiór danych syntetycznych składał się z sześciu kanałów, w tym z kanału EEG, którego sygnał zawierał artefakty wynikające z propagacji zakłóceń z pięciu kanałów EMG. Dodatkowo, ten sam kanał EEG, w wersji pozbawionej zakłóceń, pełnił funkcję odniesienia do oceny efektywności procesu oczyszczania oraz stanowił docelowy sygnał dla sieci neuronowej, umożliwiając jej naukę usuwania artefaktów.

Do dostosowywania wag sieci neuronowej podczas treningu wykorzystano algorytm Adam (Adaptive Moment Estimation). Wybrany algorytm adaptacyjny pozwala na dynamiczną modyfikację współczynników uczenia, co umożliwia szybsze i bardziej stabilne osiągnięcie zbieżności. Parametry wybranego algorytmu optymalizacji wag przedstawiono w tabeli 10.

Tabela 10. Parametry algorytmu optymalizacji Adam.

Parametr	Wartość	Opis
Współczynnik uczenia	0.001	Kontroluje, jak duże zmiany są wprowadzane do wag modelu w każdej iteracji.
beta_1	0.9	Współczynnik wygładzania pierwszego momentu kontroluje wpływ wcześniejszych gradientów na bieżącą aktualizację.
beta_2	0.999	Współczynnik wygładzania drugiego momentu kontroluje wpływ wcześniejszych kwadratów gradientów.
epsilon	1e-07	Zapewnienia stabilność numeryczną zapobiegając dzieleniu przez zero lub bardzo małe liczby.

Funkcją straty był błąd MSE (średni błąd kwadratowy), który określa różnicę między przewidywanym i rzeczywistym sygnałem (pozbawionym artefaktów otrzymanym z generatora). Optymalizacja polega na minimalizacji błędu.

Trening modelu przeprowadzono z wykorzystaniem zbioru treningowego podzielonego na partie (batch) o rozmiarze 32. Jako batch rozumiana jest niewielka porcja danych, na której

model wykonuje pojedynczą aktualizację wag, co pozwala na efektywny trening nawet przy dużych zbiorach danych. Model trenowano maksymalnie przez 50 epok, ale zastosowano mechanizm Early Stopping, który monitorował stratę na zbiorze walidacyjnym. Jeśli przez 3 kolejne epoki nie odnotowano poprawy, trening był przerywany, a wagi modelu przywracano do stanu, w którym uzyskano najlepszy wynik walidacyjny.

W trakcie trwania badań testowano różne architektury sieci neuronowych, zarówno złożone (liczące kilkanaście milionów parametrów) jak i prostsze [87], [88], [89]. Struktura oznaczona jako numer 1, przedstawiona w tabeli 11, stanowiła punkt wyjścia. Proces wyboru najlepszego modelu polegał na modyfikacji sieci bazowej i systematycznej obserwacji błędów treningowych oraz testowych. Ostatecznie udało się znacząco zmniejszyć liczbę parametrów z ponad 17 000 000 do niespełna 600 000 przy zachowaniu jakości oczyszczania sygnałów EEG. W tabeli 11 przedstawiono skrócone oznaczenia architektury sieci neuronowej, w których każda warstwa została opisana zgodnie z następującą konwencją: typ warstwy, liczba jednostek lub filtrów, a w odpowiednich przypadkach także wymiary jądra filtra. Conv2D oznacza dwuwymiarową warstwę konwolucyjną, gdzie w nawiasie podano liczbę filtrów oraz wymiary filtra. Conv1D odnosi się do jednowymiarowej warstwy konwolucyjnej, dla której w nawiasie wskazano liczbę filtrów oraz długość filtra. Dla warstwy LSTM liczba podana w nawiasie określa liczbę jednostek w tej warstwie. Z kolei w warstwie Dense liczba w nawiasie wskazuje na liczbę neuronów wyjściowych. Oznaczenie GAP dotyczy warstwy Global Average Pooling. Dokładne architektury poszczególnych modeli z tabeli 11 zgodnie z przyjętą numeracją zestawiono w formie kodów w języku Python (pakiet tensorflow) i zamieszczono w Załączniku 8.2 na końcu pracy.

Tabela 11. Zestawienie testowanych modeli CNN-LSTM wraz z wartościami błędu dla zbioru treningowego i testowego dla danych syntetycznych.

Numer modelu	Struktura	MSE trening	MSE test	Epoki	Liczba parametrów
1	Conv2D(128, 1x6) → Conv1D(256) → LSTM(256) → Flatten → Dense(256)	0,155	0,278	9	17 336 704
2	Conv2D(128, 1x6) → Conv1D(256) → Flatten → Dense(256)	0,291	0,380	6	16 811 392
3	Conv2D(128, 1x6) → Conv1D(256, 6) → LSTM(256) → Flatten → Dense(256)	0,201	0,281	9	17 500 544
4	Conv2D(128, 16x6) → Conv1D(256) → LSTM(256) → Flatten → Dense(256)	0,252	0,288	6	17 332 864
5	Conv2D(128, 1x6) → LSTM(256) → Flatten → Dense(256)	0,154	0,268	9	17 172 608

6	Conv2D(128, 1x6) → Flatten → Dense(256)	0,357	0,466	10	8 389 760
7	Conv2D(64, 32x6) → LSTM(1) → Flatten → Dense(256)	0,301	0,307	14	79 688
8	Conv2D(128, 1x6) → Conv1D(256, 64) → LSTM(256) → Flatten → Dense(256)	0,284	0,320	13	19 401 088
9	Conv2D(128, 16x6) → Conv1D(256, 32) → LSTM(256) → Flatten → Dense(256)	0,242	0,266	8	17 380 992
10	Conv1D(256) → Conv2D(128, 1x6) → Flatten → Dense(256)	0,346	0,387	17	8 586 112
11	Conv1D(256) → Conv2D(128, 1x6) → LSTM(256) → Flatten → Dense(256)	0,213	0,289	10	17 368 960
12	Conv1D(256, 6) → LSTM(256) → Flatten → Dense(256)	0,158	0,257	8	17 304 576
13	Conv1D(256, 6) → Flatten → Dense(256)	0,364	0,460	8	16 779 264
14	Conv1D(128, 6) → LSTM(256) → Flatten → Dense(256)	0,171	0,261	8	17 172 608
15	Conv1D(256, 6) → Reshape(256, 256) → LSTM(16) → Flatten → Dense(256)	0,243	0,279	18	1 068 096
16	Conv1D(256, 6) → Reshape(256, 256) → LSTM(256) → GAP → Flatten → Dense(256)	0,479	0,488	26	592 896
17	Conv2D(32, 32x6) → Conv1D(256, 6) → LSTM(16) → Flatten → Dense(256)	0,217	0,245	12	1 121 888
18	Conv2D(256, 32x6) → Conv1D(256, 6) → LSTM(16) → Flatten → Dense(256)	0,208	0,238	12	1 509 184
19	Conv2D(32, 16x6) → Conv1D(256, 6) → LSTM(16) → Flatten → Dense(256)	0,209	0,242	15	1 118 816
20	Conv2D(32, 16x6) → Conv1D(128, 6) → LSTM(16) → Flatten → Dense(256)	0,211	0,244	15	1 085 920
21	Conv2D(32, 32x6) → Conv1D(128, 6) → LSTM(16) → Flatten → Dense(256)	0,195	0,237	35	1 088 992
22	Conv2D(32, 8x6) → Conv1D(128, 6) → LSTM(16) → Flatten → Dense(256)	0,206	0,239	19	1 084 384
23	Conv2D(32, 32x6) → Conv1D(256, 6) → Conv1D(256, 6) → LSTM(16) → Flatten → Dense(256)	0,206	0,240	17	1 515 360
24	Conv2D(32, 32x6) → Conv1D(256, 6) → LSTM(8) → Flatten → Dense(256)	0,206	0,230	27	588 608
25	Conv2D(32, 32x6) → Conv1D(256, 6) → LSTM(1) → Flatten → Dense(256)	0,261	0,269	18	122 408

Najniższym błędem uzyskanym dla danych testowych znormalizowanych charakteryzował się model 24, który trenowany był przez 27 epok i to właśnie ten model został wybrany jako docelowy (CNN-LSTM). W porównaniu z modelem 1, stanowiącym punkt wyjścia do dalszych analiz, ostatecznie wybrana architektura cechowała się niemal 30-krotnie mniejszą liczbą parametrów oraz skuteczniejszym uwydatnianiem amplitudy prążka widma odpowiadającego częstotliwości SSVEP w oczyszczanych sygnałach. Najgorzej wypadł model 16, w którym wykorzystano warstwę Global Average Pooling. Redukcja warstw konwolucyjnych do jedynie jednowymiarowych (model 13) również wpływa negatywnie na działanie modelu. Objawiało się to bardzo dużym tłumieniem amplitud sygnałów oczyszczonych. W tabeli 12 przedstawiono strukturę modelu CNN-LSTM wybranego do dalszych badań oraz krótki opis poszczególnych warstw.

Tabela 12. Struktura sieci neuronowej CNN-LSTM wraz z opisem i kształtem wyjść poszczególnych warstw.

Warstwa	Rozmiar wejściowy	Rozmiar wyjściowy	Parametry	Opis działania
Input	(256, 6, 1)	(256, 6, 1)	-	Wejście zawierające sygnały z artefaktami.
Conv2D	(256, 6, 1)	(256, 6, 32)	32 filtry o rozmiarze (32, 6), padding „valid”, funkcja aktywacji ReLU	Analizuje zależności między kanałami za pomocą 32 filtrów (32, 6).
Conv1D	(256, 6, 32)	(256, 1, 256)	256 filtrów o rozmiarze 6, padding „valid”, funkcja aktywacji ReLU	Dokonuje dalszej ekstrakcji cech na danych otrzymanych z warstwy poprzedniej.
Reshape	(256, 1, 256)	(256, 256)	-	Przygotowuje dane do analizy sekwencyjnej w warstwie LSTM.
LSTM	(256, 256)	(256, 8)	8 jednostek LSTM, aktywacja bramek: funkcja sigmoidalna, obliczanie stanów: tangens hiperboliczny	Uczy się zależności czasowych w danych, wykorzystując kontekst przeszłych próbek.
Flatten	(256, 8)	(2048, 1)	-	Przekształca dane w jednowymiarowy wektor cech dla warstwy Dense.
Dense	(2048, 1)	(256, 1)	Liczba neuronów 256, liniowa funkcja aktywacji	Ostateczne odszumienie sygnału w kanale EEG za pomocą w pełni połączonych neuronów.

W dalszej części pracy przedstawiono szczegółowy opis każdej z warstw sieci neuronowej CNN-LSTM, przebieg procesu treningu, a także sposób wykorzystania modelu do oczyszczania sygnałów EEG.

Pierwsza warstwa to Conv2D (dwuwymiarowa warstwa konwolucyjna). Na warstwę podawane są dane w formie jednosekundowych okien (256 próbek) z sześciu kanałów (EEG i 5 dodatkowych kanałów EMG rejestrujących zakłócenia). Dane treningowe pochodzą z opisywanego generatora. Warstwa konwolucyjna ma na celu analizowanie przestrzennych zależności w sygnale EEG. Zastosowano do tego celu 32 filtry o rozmiarach (32, 6), które przetwarzają dane wejściowe wzdłuż osi czasowej po 32 próbki z każdego z kanałów. Dzięki wybranym parametrom, warstwa kontroluje okno 32 danych ze wszystkich elektrod w danym momencie czasowym. Zastosowane podejście pozwoliło na wychwycenie wspólnych cech sygnałów pochodzących z różnych kanałów, biorąc pod uwagę stosunkowo krótki horyzont czasowy (32 próbki). Wybraną funkcją aktywacji była funkcja ReLU (Rectified Linear Unit), która wprowadza nieliniowość do modelu i przyspiesza jego naukę.

Druga warstwa to Conv1D (warstwa konwolucyjna jednowymiarowa), operująca na danych pozyskanych z poprzedniej warstwy. W Conv1D zastosowano 256 filtrów o rozmiarze 6 i oznacza to, że filtr obejmuje całą oś długości 6 i przetwarza wszystkie 32 próbki jednocześnie. W efekcie liczba kanałów zostaje zredukowana do jednego, a dotychczasowe 32 cechy zostają przekształcone w 256 nowych cech. Działanie takie może pomóc w wychwyceniu artefaktów występujących w krótkich okresach czasu. Tutaj również zastosowano funkcję aktywacji ReLU.

Kolejna warstwa to warstwa Reshape, czyli warstwa zmieniająca kształt danych. Warstwa Reshape ma na celu przekształcenie danych wyjściowych z warstwy poprzedniej (Conv1D), aby mogły zostać przekazane do kolejnej warstwy LSTM. Po operacji zmiany kształtu danych, każda próbka czasowa ma swoją reprezentację w postaci wektora 256 wymiarowego.

Warstwa LSTM jest kluczowa w przetwarzaniu danych sekwencyjnych. LSTM jest specjalnym rodzajem rekurencyjnej sieci neuronowej, zaprojektowanej do pracy z danymi o długiej zależności czasowej. LSTM przechowuje informacje z poprzednich próbek, co umożliwia analizę zależności czasowych. W przypadku EEG, LSTM pozwala modelowi na uchwycenie zależności między różnymi fazami sygnału. W efekcie działania warstwy złożonej z 8 jednostek LSTM, dla każdej próbki czasowej (256 wymiarów z poprzedniej warstwy), generowane jest nowe wyjście o wymiarze 8. Do aktywacji bramek wykorzystano funkcję sigmoidalną, a do obliczania stanów jednostek LSTM wybrano funkcję tangens hiperboliczny.

Po warstwie LSTM, dane muszą zostać spłaszczone do jednego wektora, aby mogły zostać przekazane do warstwy gęsto połączonej zapewniającej regresję. Warstwa Flatten spłaszcza dane, które mają formę wielowymiarową, do jednego wymiaru, a cała informacja o czasie i cechach zostaje zebrana w jednowymiarowy wektor ($256 \times 8 \rightarrow 2048$).


Ostatnią warstwą jest warstwa gęsto połączona, a funkcja aktywacji jest funkcją liniową. Celem funkcji jest przewidywanie wartości ciągłej, jaką w naszym przypadku jest sygnał EEG oczyszczony z artefaktów. Na wyjściu otrzymujemy 256 próbek odpowiadających danym oczyszczonym z kanału EEG. Całkowita liczba parametrów utworzonego modelu wyniosła 588 608.

Podsumowując, warstwy konwolucyjne zapewniają ekstrakcję cech międzykanałowych (Conv2D, Conv1D), a warstwa LSTM umożliwia analizę zależności czasowych. Warstwa Flatten umożliwia wprowadzenie danych na warstwę Dense, która odpowiada za generowanie oczyszczonego sygnału EEG.

Zastosowany mechanizm Early Stopping podczas treningu, pozwolił modelowi na uniknięcie nadmiernego dopasowania do danych treningowych, a finalna liczba epok równa 27, była znacznie niższa od maksymalnej. Błędy treningu i walidacji sieci CNN-LSTM dla każdej z epok zamieszczono w tabeli 13 i zaprezentowano na rysunku 11.

Tabela 13. Błędy treningu i walidacji w każdej z epok treningu sieci CNN-LSTM.

Epoka	Błąd treningu (MSE)	Błąd walidacji (MSE)	Epoka	Błąd treningu (MSE)	Błąd walidacji (MSE)
1	0,503	0,33	15	0,226	0,24
2	0,301	0,293	16	0,223	0,237
3	0,276	0,269	17	0,224	0,236
4	0,267	0,267	18	0,22	0,234
5	0,258	0,278	19	0,219	0,233
6	0,252	0,256	20	0,219	0,232
7	0,247	0,255	21	0,218	0,235
8	0,244	0,25	22	0,215	0,24
9	0,242	0,259	23	0,215	0,232
10	0,237	0,243	24	0,212	0,228
11	0,234	0,242	25	0,212	0,23
12	0,232	0,24	26	0,212	0,231
13	0,229	0,237	27	0,211	0,229
14	0,227	0,238			



Rysunek 11. Przebieg treningu sieci CNN-LSTM.

Trening sieci CNN-LSTM wykonany został z wykorzystaniem karty graficznej GeForce GTX 1660 Ti i trwał około 30 minut. Po zakończonym treningu sprawdzony został błąd dla danych testowych który wyniósł 0,230, co wskazuje na poprawnie przeprowadzony proces uczenia.

Sieć neuronowa została zaprojektowana do oczyszczania sygnału EEG w oknach o długości jednej sekundy. Na jej wejście podawane są jednocześnie dane z sześciu kanałów: jeden kanał EEG (podlegający oczyszczaniu) oraz pięć kanałów EMG (reprezentujących zakłócenia). Każdy kanał zawiera 256 próbek, co odpowiada jednej sekundzie sygnału przy częstotliwości próbkowania 256 Hz. W przypadku sygnałów rzeczywistych oczyszczanie odbywa się w sposób sekwencyjny, z zastosowaniem jednosekundowych okien przesuwanych wzdłuż całego przebiegu czasowego.

4.1.2. Regresja liniowa

Regresja jest popularną metodą stosowaną do usuwania artefaktów elektrookulograficznych, a jej wykorzystanie sięga lat 90., głównie ze względu na prostą implementację oraz niskie wymagania obliczeniowe [90]. W obecnych czasach, regresja jest nadal popularną i często wykorzystywaną metodą usuwania artefaktów [90], [91]. Metoda wymaga dodatkowych elektrod pomocniczych służących do akwizycji zakłóceń. Bardzo często elektrody te znajdują się w pobliżu oczu lub mięśni celem rejestracji artefaktów elektrookulograficznych i mięśniowych. Metoda regresji zakłada, że każdy kanał pomiarowy EEG jest sumą pewnego niezanieczyszczonego sygnału źródłowego (aktywność mózgowa) oraz kombinacją liniową

sygnałów rejestrowanych za pomocą elektrod pomocniczych [12], [90]. Aktywność mózgowa pozostaje niezależna od elektrod rejestrujących aktywność związaną z artefaktami. Celem regresji jest estymacja optymalnej wartości współczynnika propagacji dla każdej z elektrod pomocniczych, realizowana za pomocą metody najmniejszych kwadratów. Korekcja zanieczyszczonego sygnału EEG polega na odejmowaniu od niego (z uwzględnieniem wyznaczonych współczynników) sygnałów pochodzących z elektrod rejestrujących aktywność związaną z artefaktami, co pozwala na uzyskanie sygnału oczyszczonego.

Zakładając, że mamy zbiór sygnałów EEG z n elektrodami pomocniczymi, sygnał $EEG(t)$ z elektrody EEG podlegającej oczyszczaniu z artefaktów możemy zapisać jako (4.1)

$$EEG(t) = \sum_{i=1}^n w_i * REF_i(t) + EEG_{clear}(t) \quad (4.1)$$

gdzie $EEG(t)$ to sygnał z elektrody EEG przed oczyszczaniem, zawierający zarówno aktywność mózgową jak i artefakty, w_i to i -ty współczynnik propagacji (waga regresji) określający jak silnie i -ta elektroda pomocnicza wpływa na sygnał EEG. Jako $EEG_{clear}(t)$ oznaczono sygnał EEG oczyszczony z artefaktów, a więc jest to sama aktywność mózgowa. $REF_i(t)$ to sygnał pochodzący z i -tej elektrody pomocniczej rejestrującej aktywność związaną z artefaktami.

Aby usunąć artefakty, należy obliczyć odpowiednie wagi w_i , które najlepiej odwzorowują zależność między sygnałami pochodzącymi z elektrod pomocniczych rejestrujących aktywność związaną z artefaktami, a sygnałem $EEG(t)$, przy czym $EEG_{clear}(t)$ jest traktowane jak składnik, który należy zachować. Regresja polega więc na wyizolowaniu składnika związanego z artefaktami i odjęciu go od całego sygnału $EEG(t)$ zgodnie ze wzorem (4.2).

$$EEG_{clear}(t) = EEG(t) - \sum_{i=1}^n w_i * REF_i(t) \quad (4.2)$$

Zakładając REF jako macierz sygnałów z elektrod rejestrujących aktywność związaną z artefaktami oraz w , jako wektor wag regresji ostateczny wzór przyjmuje postać (4.3).

$$EEG(t) = REF * w + EEG_{clear}(t) \quad (4.3)$$

Następnie wyznaczamy wagi z wykorzystaniem metody najmniejszych kwadratów zgodnie ze wzorem (4.4).

$$w = (REF^T * REF)^{-1} * REF^T * EEG \quad (4.4)$$

Po wyznaczeniu wag możliwa jest ekstrakcja artefaktu z sygnału EEG, modelowanego jako liniowa kombinacja sygnałów pochodzących z elektrod rejestrujących aktywność związaną z artefaktami (4.5).

$$REF_{art}(t) = REF * w \quad (4.5)$$

Na koniec wracamy do wzoru (4.3) i przekształcając go otrzymujemy wynikowy sygnał EEG pozbawiony artefaktów, czyli sygnał mózgowy (4.6).

$$EEG_{clear}(t) = EEG(t) - REF_{art}(t) \quad (4.6)$$

Regresja, jako metoda oczyszczania sygnałów EEG, charakteryzuje się kilkoma istotnymi zaletami, które czynią ją bardzo popularnym narzędziem w analizie danych neurofizjologicznych. Po pierwsze, jest to prosta i wydajna obliczeniowo metoda, która nie wymaga zaawansowanych algorytmów. Sprawia to, że regresja jest szybka i łatwa w implementacji. Metoda uzyskuje wysoką efektywność w analizach obejmujących duże zbiory danych, szczególnie w przypadkach, gdy istotnym czynnikiem jest czas przetwarzania, jak ma to miejsce w analizach w czasie rzeczywistym. Kolejną niewątpliwą zaletą regresji jest szeroka stosowalność metody w przypadku artefaktów, które mają wyraźne i liniowe powiązanie z sygnałami pochodzącymi z elektrod pomocniczych rejestrujących aktywność związaną z artefaktami, na przykład ruchami gałek ocznych. Mimo licznych zalet, regresja ma również pewne ograniczenia. Jednym z głównych założeń modelu jest przyjęcie, że artefakty są liniową kombinacją sygnałów z elektrod pomocniczych rejestrujących zakłócenia, co jest istotnym ograniczeniem metody. W rzeczywistości, artefakty mogą być znacznie bardziej złożone i nieliniowe, a takie przypadki mogą sprawić, że regresja nie będzie wystarczająca do skutecznego oczyszczania sygnału. Niemniej jednak, regresja stanowi efektywną metodę oczyszczania sygnałów EEG i znajduje zastosowanie do dnia dzisiejszego, szczególnie w przypadkach wymagających szybkich obliczeń.

Podczas badań, w metodzie regresji jako elektrody pomocnicze wykorzystano wszystkie elektrody EMG/EOG rejestrujące artefakty (*Fp1*, *HEOG*, *Kark*, *Policzek* oraz *Szczęka*). Skupiono się na oczyszczaniu sygnałów z elektrod *O1*, *Oz*, *O2* oraz *Cz*. Oczyszczanie każdej z analizowanych elektrod przeprowadzano w sposób sekwencyjny, wykorzystując kanały pomocnicze rejestrujące artefakty. Regresję przeprowadzono z wykorzystaniem okien czasowych, a nie jednorazowo dla całej długości danych. Oznacza to, że model regresji działał na mniejszych, przesuwających się fragmentach sygnałów (oknach), co pozwoliło na uwzględnienie lokalnych zależności i zmienności w czasie. Okno wykorzystywane do obliczeń w metodzie regresji zostało eksperymentalnie dobrane i miało długość 1 sekundy. Zbyt szerokie okno zawierało jednocześnie wiele artefaktów i fragmentów sygnałów bez zakłóceń, a zbyt wąskie nie obejmowało nawet pojedynczych artefaktów.

4.1.3. Analiza składowych niezależnych

Metoda analizy składowych niezależnych jest również bardzo popularną techniką stosowaną w oczyszczaniu sygnałów EEG z artefaktów. Jej główną zaletą jest zdolność do separacji sygnałów na niezależne składniki, bez potrzeby wykorzystania sygnałów pochodzących z elektrod pomocniczych rejestrujących aktywność związaną z artefaktami [12], [92]. Z tego powodu ICA jest często stosowana w przypadkach, gdy dane nie zawierają elektrod pomocniczych, niezbędnych w metodach takich jak regresja. Celem metody ICA jest rozkład sygnału rejestrowanego przez elektrody na niezależne komponenty, których liczba jest zadana przez użytkownika i nie może przekroczyć liczby elektrod wykorzystanych podczas akwizycji zadanego sygnału. W założeniu, wśród komponentów znajdują się takie, które odpowiadają za źródła zakłóceń (artefakty, jak np. mruganie oczami, napięcia mięśniowe, pracę serca czy inne). Komponenty zawierające artefakty są odrzucane w sposób automatyczny lub przez eksperta, a następnie dokonywane jest odtworzenie sygnału poprzez mieszanie komponentów uzyskanych w rozkładzie ICA. W efekcie otrzymujemy sygnały pozbawione artefaktów. Problem może zostać przedstawiony jako (4.7) [12]

$$X = W * S \quad (4.7)$$

gdzie X jest macierzą sygnałów zarejestrowanych przez elektrody pomiarowe, W to macierz mieszająca, a S to macierz sygnałów źródłowych. Po przekształceniu równania otrzymujemy (4.8). W tym przypadku S zawiera komponenty, które są niezależne od siebie. Celem ICA jest znalezienie takiej macierzy mieszającej W , która umożliwi uzyskanie jak najbardziej

niezależnych składników sygnałowych. W tym celu można wykorzystać różne algorytmy iteracyjne takie jak na przykład FastICA. Bardzo istotnym krokiem w algorytmie FastICA jest wybielanie (whitening), które polega na przekształceniu danych w taki sposób, aby miały jednostkową wariancję oraz były niezależne. Proces wybielania upraszcza rozwiązanie problemu mieszania sygnałów, eliminując korelacje pomiędzy komponentami. W praktyce oznacza to, że przed rozpoczęciem właściwego procesu ICA, sygnały EEG są przekształcane do postaci, w której ich współczynniki korelacji są zerowe.

$$S = W^{-1} * X \quad (4.8)$$

Wyznaczenie macierzy W wymaga więc przyjęcia pewnych założeń. Wśród założeń metody ICA [12] jest między innymi statystyczna niezależność sygnałów źródłowych. Oznacza to, że sygnały, które stanowią źródła zakłóceń (artefakty) oraz aktywność mózgową, muszą być statystycznie niezależne, a więc wszelkie statystyki (średnia, wariancja, skośność, kurtoza) tych sygnałów nie powinny być powiązane. Jak podano w [12], jednym z założeń jest brak więcej niż jednego sygnału źródłowego o rozkładzie normalnym (gaussowskim). Po zastosowaniu algorytmu ICA na zarejestrowanych sygnałach EEG/EMG, uzyskujemy zadaną przez nas liczbę niezależnych komponentów, które mogą zawierać zarówno składniki związane z aktywnością mózgową, jak i artefakty mięśniowe. Aby usunąć artefakty, należy zidentyfikować komponenty, które odpowiadają za źródła zakłóceń, a następnie wyzerować odpowiednie wagi w macierzy W . Po usunięciu komponentów związanych z artefaktami, sygnał jest rekonstruowany przez ponowne zmieszanie pozostałych komponentów za pomocą zmodyfikowanej macierzy mieszającej W_m (4.9), czyli macierzy mieszającej po wyzerowaniu wag odpowiadających za artefakty.

$$X = W_m * S \quad (4.9)$$


W przeciwieństwie do innych metod, takich jak regresja, ICA nie wymaga wykorzystania elektrod pomocniczych rejestrujących aktywność związaną z artefaktami. Metoda ICA może być stosowana do różnych typów artefaktów, w tym tych związanych z ruchami gałek ocznych, napięciami mięśniowymi, pracą serca, a także do innych zakłóceń [93]. Mimo swoich licznych zalet, metoda ICA ma pewne ograniczenia. Założenie o niezależności sygnałów jest jednym z głównych problemów. ICA zakłada, że sygnały źródłowe są statystycznie niezależne, co może nie być prawdą. Na przykład, w przypadkach, w których artefakty mają silne powiązanie

z aktywnością mózgową, może być trudno przeprowadzić skuteczną separację komponentów, co obniża efektywność metody. Kolejnym problemem jest trudność w separacji komponentów o rozkładzie normalnym. ICA ma trudności z separowaniem sygnałów, które mają rozkład gaussowski. Jednakże najbardziej istotnym ograniczeniem są trudności w identyfikacji artefaktów. Choć ICA potrafi oddzielić komponenty, to w niektórych przypadkach identyfikacja tych, które odpowiadają za artefakty, może być bardzo trudna, szczególnie jeśli artefakty są podobne do aktywności mózgowej. Nawet, gdy komponenty związane z artefaktami są wyodrębnione przez ICA poprawnie, w celu ich wskazania wymagany jest ekspert lub algorytm. W przypadku błędnego wyboru komponentów do odrzucenia prowadzi to do sytuacji, w której artefakty nie zostaną skutecznie wyeliminowane, a aktywność mózgową zostanie zmodyfikowana. Analizę przeprowadzono z wykorzystaniem ogólnodostępnego pakietu MNE, dedykowanego do analizy sygnałów neurofizjologicznych. Do separacji składowych niezależnych zastosowano algorytm FastICA. Liczbę komponentów dopasowano do liczby kanałów. Parametry algorytmu FastICA zostały zestawione w tabeli 14.

Tabela 14. Parametry algorytmu FastICA.

Parametr	Wartość	Opis
Liczba komponentów niezależnych	6	Liczba komponentów, które mają zostać wyodrębnione z danych.
Wybielanie	Jednostkowa wariancja, wykorzystanie SVD	Przekształcenie danych, aby miały jednostkową wariancję, z użyciem rozkładu SVD (wartości osobliwych).
Funkcja negentropii	Logarytm cosinusa hiperbolicznego	Funkcja wykorzystywana do przybliżania negentropii, mająca na celu maksymalizację niezależności komponentów.
Maksymalna liczba iteracji	200	Maksymalna liczba iteracji, którą algorytm wykona, zanim uzna, że osiągnął wynik.
Tolerancja	0.0001	Algorytm kończy iteracje, jeśli zmiana w macierzy rozdzielania (odwrotność macierzy mieszającej) między dwiema iteracjami jest mniejsza niż zadana wartość tolerancji.

Odrzucanie komponentów zawierających artefakty przeprowadzono za pomocą inspekcji wzrokowej, polegającej na wizualnej ocenie zawartości komponentów i ich wpływu na sygnał. Oczyszczanie przeprowadzano na całej długości sygnału, osobno dla każdej elektrody EEG, z uwzględnieniem kanałów EMG. Przykładowe przebiegi komponentów po dokonaniu transformacji ICA fragmentu sygnału rzeczywistego zamieszczone zostały na rysunku 12.



Rysunek 12. Komponenty ICA otrzymane po dekompozycji przykładowego sygnału z bazy.

4.1.4. Filtracja adaptacyjna

Filtracja adaptacyjna jest techniką przetwarzania sygnałów, której celem jest oczyszczanie sygnałów z zakłóceń lub artefaktów poprzez dynamiczną aktualizację wag filtru. Proces polega na estymacji zakłóceń na podstawie sygnałów pochodzących z elektrod pomocniczych rejestrujących aktywność związaną z artefaktami i ich odejmowaniu od sygnału obserwowanego, co pozwala na odzyskanie sygnału pozbawionego zakłóceń. W kontekście analizowanych algorytmów, sygnał wejściowy $d(t)$ reprezentuje obserwowany sygnał (sygnał EEG z zakłóceniami), który zawiera zarówno informacje użyteczne, jak i artefakty. Zadaniem filtru jest oszacowanie zakłóceń $y(t)$ na podstawie sygnałów pomocniczych $x(t)$ (np. sygnałów z elektrod EMG), a następnie usunięcie ich z sygnału wejściowego $d(t)$. Wynikiem opisanego procesu jest sygnał oczyszczony $e(t)$ wyrażony w postaci wzoru (4.10)

$$e(t) = d(t) - y(t) \quad (4.10)$$

gdzie sygnał $e(t)$ to wynikowy sygnał po filtracji, który powinien jak najlepiej odzwierciedlać rzeczywisty sygnał pozbawiony zakłóceń. Proces jest iteracyjny, co oznacza, że wagi filtru są dynamicznie dostosowywane w czasie. W filtracji adaptacyjnej najczęściej stosuje się dwa algorytmy:

- Least Mean Squares to algorytm prosty w implementacji, ale wolniejszy w adaptacji i bardziej wrażliwy na dobór parametrów,

- Recursive Least Squares to algorytm bardziej złożony obliczeniowo, ale oferujący szybszą zbieżność.

Poniżej omówiono szczegółowo oba podejścia, z uwzględnieniem ich matematycznych podstaw i interpretacji.

LMS to prosty, iteracyjny algorytm minimalizacji błędu średniokwadratowego pomiędzy sygnałem oczekiwanym $d(t)$ a wyjściem filtru $y(t)$. Jego istotną zaletą jest niewielka złożoność obliczeniowa, co czyni go powszechnie stosowanym w aplikacjach czasu rzeczywistego. Filtr LMS wymaga inicjalizacji wag $w(0)$, które zazwyczaj przyjmują wartości zerowe lub losowe. Wyjście filtru $y(t)$, czyli estymowane zakłócenia wyznaczone są zgodnie ze wzorem (4.11).

$$y(t) = w^T(t-1) * x(t) \quad (4.11)$$

Następnie, iteracyjnie aktualizowane są wagi zgodnie z regułą (4.12).

$$w(t) = w(t-1) + \mu * e(t) * x(t) \quad (4.12)$$

We wzorze przyjmujemy, że μ to współczynnik uczenia, kontrolujący szybkość adaptacji filtru, $e(t)$, to błąd pomiędzy sygnałem oczekiwanym a wyjściem filtru (4.10). Aby algorytm mógł poprawnie estymować zakłócenia w przypadku sygnałów pochodzących z wielu elektrod pomocniczych rejestrujących aktywność związaną z artefaktami (np. wielu elektrod EMG), sygnały te są reprezentowane w postaci wektora opóźnień (4.13)

$$x(t) = [x_1(t), x_1(t-1), \dots, x_1(t-M+1), \dots, x_N(t), \dots, x_N(t-M+1)]^T \quad (4.13)$$

gdzie N to liczba kanałów pomocniczych (np. elektrod EMG), a M to liczba opóźnień (rzęd filtru). Wektor $x(t)$ ma wymiar $(N \cdot M) \times 1$. Każda iteracja algorytmu pozwala na otrzymanie oczyszczonej próbki sygnału wejściowego $e(t)$. Liczba iteracji algorytmu jest zatem równa liczbie próbek czasowych w zarejestrowanym sygnale. Dobór współczynnika uczenia μ jest kluczowy dla stabilności i szybkości zbieżności algorytmu. Zbyt duża wartość μ może spowodować niestabilność, a zbyt mała wolną adaptację. Zastosowanie filtru o wysokim rzędzie może prowadzić do zmniejszenia reakcji na szybkie zmiany sygnału, charakterystyczne

dla artefaktów. Zbyt mały rząd może utrudnić uchwycenie zależności długoterminowych. Algorytm LMS jest prosty w implementacji i nie ma dużych wymagań obliczeniowych, jednak jest wrażliwy na dobór parametrów, szczególnie współczynnika uczenia μ , gdyż to on wpływa na adaptację wag. Częstym problemem filtrów adaptacyjnych jest także trudność w osiągnięciu konwergencji przy silnie zmieniających się sygnałach.

Filtracja adaptacyjna RLS jest bardziej zaawansowaną metodą, której celem jest minimalizacja błędu kwadratowego za pomocą algorytmu rekurencyjnego. Algorytm RLS oferuje szybszą zbieżność niż LMS, szczególnie w przypadku niestacjonarnych sygnałów, ale wiąże się z wyższą złożonością obliczeniową. W odróżnieniu od filtra LMS, który dostosowuje wagi na podstawie bieżącego błędu, RLS uwzględnia również wcześniejsze próbki sygnału, co umożliwia lepsze śledzenie zmian sygnału. Wyjście filtra $y(t)$ opisane jest w taki sam sposób jak w przypadku LMS, zgodnie z (4.11). RLS, analogicznie do LMS również wymaga inicjalizacji wag $w(0)$, które zazwyczaj przyjmują wartości zerowe lub losowe. Algorytm opiera się na iteracyjnej aktualizacji wag zgodnie ze wzorem (4.14).

$$w(t) = w(t - 1) + k(t) * e(t) \quad (4.14)$$

We wzorze przyjmujemy te same oznaczenia co w przypadku LMS ($e(t)$, to błąd pomiędzy sygnałem oczekiwanym a wyjściem filtra (4.10), a $x(t)$ to wektor opóźnień dla chwili t (4.13)). Wektor $k(t)$ to wektor współczynnika adaptacyjnego wyrażony wzorem (4.15).

$$k(t) = \frac{P(t - 1) * x(t)}{\lambda + x^T(t) * P(t - 1) * x(t)} \quad (4.15)$$

Do wyznaczenia $k(t)$ potrzebna jest odwrotna macierz autokorelacji $P(t)$, która początkowo inicjalizowana jest jako zgodnie ze wzorem (4.16)

$$P(0) = \delta * I \quad (4.16)$$

gdzie jako δ oznaczono parametr skalujący, a I oznacza macierz jednostkową. Parametr skalujący bardzo często przyjmuje wartość równą 1, a początkowa postać macierzy P jest wówczas macierzą jednostkową. Współczynnik λ we wzorze (4.15) oznacza parametr nazywany „współczynnikiem zapominania”. Współczynnik λ kontroluje szybkość adaptacji, czyli określa jak szybko algorytm zapomina o wcześniejszych próbkach. Z racji iteracyjnego

charakteru procesu, odwrotna macierz autokorelacji aktualizowana jest zgodnie ze wzorem (4.17).

$$P(t) = \frac{1}{\lambda} * (P(t-1) - k(t) * x^T(t) * P(t-1)) \quad (4.17)$$

W algorytmie RLS również przyjęto, że N to liczba kanałów pomocniczych (np. elektrod EMG), a M to liczba opóźnień (rzęd filtra). Wektor $x(t)$ ma wymiar $(N \cdot M) \times 1$ co oznacza, że dla każdego kroku czasowego t , wektor $x(t)$ zawiera próbki sygnałów pochodzących z elektrod pomocniczych rejestrujących aktywność związaną z artefaktami, z uwzględnieniem opóźnień. Macierz kowariancji $P(t)$, która jest kluczowym elementem algorytmu, ma wymiary $(N \cdot M) \times (N \cdot M)$. Tak jak w przypadku LMS, każda iteracja algorytmu pozwala na otrzymanie oczyszczonej próbki sygnału wejściowego $e(t)$. Liczba iteracji algorytmu jest zatem równa liczbie próbek czasowych w zarejestrowanym sygnale.

W badaniach realizowanych w ramach pracy doktorskiej wykorzystano filtr LMS oraz RLS. Wybór filtrów związany jest z ich zróżnicowanym działaniem, które umożliwia porównanie dwóch odmiennych podejść do eliminacji artefaktów. Implementacja polegała na oczyszczaniu wszystkich kanałów EEG z wykorzystaniem sygnałów pochodzących z elektrod pomocniczych rejestrujących aktywność związaną z artefaktami, analogicznie jak w przypadku regresji. Jako sygnały pomocnicze wykorzystano dane z elektrod EMG ($N = 5$, zgodnie z pięcioma elektrodami EMG). Zastosowanie filtra adaptacyjnego pozwala na dynamiczną korekcję sygnału, poprzez iteracyjne odejmowanie estymowanych przez filtr zakłóceń od oczyszczanego sygnału. Parametry filtrów zostały ustalone w sposób eksperymentalny, na podstawie obserwacji jakości oczyszczonych sygnałów EEG. W obu algorytmach zastosowano rząd filtra M równy 8. Wartość współczynnika uczenia μ dla LMS ustawiona została na 0,5. Oznacza to, że filtr adaptacyjny reaguje na zmiany w danych wejściowych w stosunkowo wolny sposób. Wolniejsze tempo uczenia pomaga zapewnić, że filtr będzie bardziej stabilny i dokładny w dłuższej perspektywie czasowej. W przypadku RLS, ustawiono współczynnik zapominania λ na 0,99999. Zaproponowana wartość λ jest duża i oznacza, że filtr zapamiętuje dane przez dłuższy czas (długa pamięć). W efekcie adaptacja przebiega wolniej, ale pozwala to na zachowanie większej stabilności. Ostatnim zadaniem parametrem były początkowe wagi filtrów, które zarówno dla algorytmu LMS, jak również RMS ustawiono jako wektory zerowe. W przypadku algorytmu RLS, początkową postać macierzy P ustawiono jako macierz jednostkową ($\delta = 1$).

4.1.5. Filtracja cyfrowa

Filtracja klasyczna obejmuje stosowanie filtrów FIR i IIR, które pozwalają na przepuszczanie określonych pasm częstotliwości, jednocześnie eliminując niepożądane składowe sygnałów, takie jak zakłócenia i artefakty. Do najczęściej stosowanych typów filtrów należą filtry dolno i górno-przepustowe, pasmowo-przepustowe oraz środkowo-zaporowe. Podczas przeprowadzonych akwizycji sygnałów EEG, filtracja klasyczna była stosowana do eliminacji zakłóceń, takich jak składowe sieciowe o częstotliwości 50Hz. Przykładem jest zastosowanie filtru środkowo-zaporowego Butterwortha 4-go rzędu, który skutecznie eliminował zakłócenia w zakresie 48-52Hz (zakłócenia sieciowe), a jednocześnie nie ingerował w istotne pasma sygnałów. Z kolei, dla ogólnego ograniczenia zakresu badanych sygnałów, stosowany był filtr pasmowo-przepustowy Butterwortha 8-go rzędu, który przepuszczał częstotliwości w zakresie od 1Hz do 100Hz, eliminując składowe poniżej 1Hz i powyżej 100Hz. Takie podejście miało na celu usunięcie niepożądanych artefaktów, zwłaszcza tych z zakresu niskich częstotliwości, oraz zakłóceń pochodzących z otoczenia. Pomimo zastosowania filtrów o określonych pasmach, klasyczna filtracja napotyka ograniczenia przy eliminacji artefaktów, gdyż mogą one występować w szerokim zakresie częstotliwości. Filtry pasmowe, choć skuteczne w usuwaniu wybranych zakłóceń, nie są w stanie dokładnie oczyścić całego pasma sygnału EEG, ponieważ częstotliwości artefaktów bardzo często pokrywają się z pasmem sygnału mózgowego, zwłaszcza w przypadku artefaktów mięśniowych. W związku z tym, klasyczna filtracja okazuje się niewystarczająca jako narzędzie do kompleksowego usuwania artefaktów. Jej zastosowanie ograniczało się głównie do zadań takich jak eliminacja zakłóceń sieciowych (np. 50/60Hz) oraz wstępne ograniczenie pasma sygnału do pożądanych zakresów, np. 1-100Hz.

4.2. Metody oceny skuteczności usuwania artefaktów

Do oceny skuteczności oczyszczania sygnałów, szczególnie w kontekście sygnałów generowanych przez generator i ocenianych w ramach treningu, zastosowano klasyczne miary błędu, takie jak *RMSE*, *MAPE* (Mean Absolute Percentage Error) oraz współczynnik determinacji R^2 . Wybrane miary umożliwiły rzetelną ocenę jakości oczyszczania, ponieważ dysponowano odniesieniem w postaci sztucznie wygenerowanych sygnałów EEG bez artefaktów. *MAPE* (4.18) określa średni procentowy błąd między próbkami sygnału docelowymi (EEG), a oczyszczonymi przez algorytm. Wyliczany jest jako średnia arytmetyczna sumy wartości bezwzględnych różnic między próbkami z sygnału rzeczywistego, a oczyszczonego, odniesiona do wartości rzeczywistych

$$MAPE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=1}^{n_{samples}} \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (4.18)$$

gdzie jako $n_{samples}$ oznaczono liczbę próbek wejściowych, y_i oznacza rzeczywistą wartość dla i -tej próbki, natomiast $\hat{y}_i$ to przewidywana przez model wartość dla i -tej próbki.

Błąd $RMSE$ to pierwiastek błędu średniokwadratowego (MSE) (4.19a). Obliczany jest jako pierwiastek ze średniej arytmetycznej sumy kwadratów różnic między próbkami sygnału docelowego (EEG), a sygnału oczyszczonego przez daną metodę.

$$MSE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=1}^{n_{samples}} (y_i - \hat{y}_i)^2 \quad (4.19)$$

$$RMSE(y, \hat{y}) = \sqrt{MSE(y, \hat{y})} \quad (4.19a)$$

Oznaczenia przyjęto analogicznie do tych ze wzoru (4.18). Błędy $MAPE$ i MSE powinny być jak najmniejsze. Współczynnik determinacji R^2 opisany jest wzorem (4.20) i pozwala na zbadanie jak oczyszczony sygnał odwzorowuje sygnał oryginalny. Jako $\bar{y}$ oznaczono średnią wartość rzeczywistego sygnału.

$$R^2 = \frac{\sum_{i=1}^{n_{samples}} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{n_{samples}} (y_i - \bar{y})^2} \quad (4.20)$$

Dodatkowo, w celu uzyskania bardziej szczegółowego obrazu oczyszczania, w analizach uwzględniono także takie miary, jak skośność, kurtoza, odchylenie standardowe sygnałów, moc oraz wartości minimalne i maksymalne. Wyznaczone parametry pozwalają na porównanie rozkładu sygnałów przed i po oczyszczaniu, uwzględniając zarówno zmiany w amplitudzie, jak i w strukturze sygnału.

Ocena wizualna sygnałów była ważnym elementem wstępnej analizy, ale nie stanowiła miarodajnej metody oceny efektywności oczyszczania. Dostarczyła jedynie ogólnych wskazówek dotyczących usunięcia artefaktów, ale nie dawała pełnego obrazu rzeczywistych zmian w sygnale. Dlatego też w analizach oparto się głównie na miarach ilościowych, które

pozwoły na bardziej precyzyjną ocenę działania poszczególnych metod, a ocenę wizualną wykorzystano jedynie jako narzędzie uzupełniające.

W prowadzonych badaniach dotyczących analizy i oczyszczania sygnałów rzeczywistych, szczególną uwagę skupiono na elektrodzie *Oz*. Elektroda *Oz* odgrywa kluczową rolę w systemach BCI (mózg-komputer) opartych o potencjały wywołane bodźcami wzrokowymi w stanie ustalonym. SSVEP powstają jako reakcja elektryczna mózgu na bodźce wizualne wyświetlane z określoną częstotliwością. Typowy zakres częstotliwości wykorzystywanych w interfejsach mózg-komputer do generowania stymulacji świetlnej wywołującej SSVEP to 3,5-75Hz [94], [95]. Potencjały mogą być wykorzystane do sterowania różnorodnymi urządzeniami zewnętrznymi. Istotne jest, aby sygnał rejestrowany na elektrodzie *Oz* był wolny od zakłóceń, ponieważ mogą prowadzić do zniekształcenia zawartej w nim informacji. Takie zakłócenia mogą powstawać na skutek propagacji artefaktów na elektrodę *Oz* z innych elektrod i ich poprawna eliminacja jest niezbędna. W przypadku rzeczywistych sygnałów EEG zawierających odpowiedzi typu SSVEP, brak jednoznacznego wzorca odniesienia utrudnia obiektywną ocenę skuteczności procesu oczyszczania sygnału. W celu oceny jakości przetworzonych sygnałów zaproponowano miarę, jaką jest widmowy współczynnik stosunku sygnału do szumu (SNR_{SSVEP}). W przeciwieństwie do tradycyjnych miar oceny jakości oczyszczonego sygnału EEG, takich jak R^2 , $RMSE$ czy $MAPE$, które wymagają sygnału odniesienia i są przede wszystkim stosowane do analizy sygnałów syntetycznych, współczynnik SNR_{SSVEP} nie wymaga istnienia wzorca. Dzięki temu może być wykorzystany do oceny rzeczywistych sygnałów EEG zawierających SSVEP, dla których brak jest danych porównawczych. Ta właściwość czyni SNR_{SSVEP} szczególnie użytecznym narzędziem do oceny skuteczności metod oczyszczania, z uwzględnieniem zachowania charakterystycznych komponentów sygnału jakimi są prążki SSVEP. Ponadto, z uwagi na ograniczoną liczbę dostępnych miar jakości stosowanych w analizie rzeczywistych danych EEG, SNR_{SSVEP} może pełnić funkcję kryterium oceny jakości sygnału w badaniach dotyczących SSVEP.

Współczynnik SNR_{SSVEP} określa relację między amplitudą widma sygnału EEG odpowiadającą częstotliwości stymulacji f_{base} (charakterystycznej dla odpowiedzi SSVEP), a przeciętnym poziomem aktywności EEG w zakresie 1-100Hz. Wartości umożliwiające wyznaczenie SNR_{SSVEP} uzyskiwane są z widma sygnału wyznaczonego za pomocą FFT (transformaty Fouriera), gdzie każdej częstotliwości odpowiada konkretny prążek spektralny. Współczynnik wyraża się wzorem (4.21)

$$SNR_{SSVEP} = \frac{A_{SSVEP}}{A_{EEG}} \quad (4.21)$$

gdzie $A_{SSVEP} = |FFT(f_{base})|$ oznacza amplitudę widma przy częstotliwości stymulacji f_{base} , a A_{EEG} to średnia amplituda widma sygnału EEG w zakresie częstotliwości 1-100Hz, obliczana według wzoru (4.22)

$$A_{EEG} = \frac{1}{N} \sum_{f=1}^{100} |FFT(f)| \quad (4.22)$$

gdzie N oznacza liczbę punktów widmowych w analizowanym paśmie (w tym przypadku $N = 100$).

Wysoka wartość współczynnika SNR_{SSVEP} świadczy o wyraźnej dominacji potencjału SSVEP względem tła EEG, co wskazuje na skuteczne uwydatnienie odpowiedzi wywołanej stymulacją wzrokową. Z kolei niskie wartości współczynnika sugerują, że potencjał SSVEP jest słabo widoczny na tle ogólnej aktywności mózgowej, co może być efektem obecności zakłóceń lub ograniczonej skuteczności zastosowanej metody filtracji.

Ocena na podstawie tylko tego współczynnika mogłaby być niewystarczająca, ponieważ nie dostarcza pełnej informacji o tym, czy sam sygnał uległ znaczącym zmianom. Należy podkreślić, że w przypadku oczyszczania sygnałów rzeczywistych często dochodziło do modyfikacji sygnału, a więc obserwacja jedynie jednego współczynnika mogłaby prowadzić do mylnych wniosków na temat jakości oczyszczania. W związku z tym, do kompleksowej oceny skuteczności oczyszczania, należało monitorować również inne opisywane wcześniej współczynniki, takie jak wartości minimalne, maksymalne, moc, czy zmiany w strukturze sygnału przed i po oczyszczaniu.


W celu dokładniejszej analizy skuteczności oczyszczania wybranych metod, porównania przeprowadzono nie tylko dla całego sygnału, ale również dla dwóch zestawów jednosekundowych okien sygnału wybranych na podstawie wizualnej inspekcji. Pierwszy zestaw składał się z okien zawierających artefakty zaciskania szczęki, a drugi z fragmentów ich pozbawionych. Podczas selekcji dokonano wszelkich starań, aby okna bez artefaktów były jak najbardziej zbliżone do czystego sygnału EEG. Niestety nie zawsze było to możliwe z powodu występowania innych naturalnych artefaktów. Taki podział umożliwił ocenę działania metod oczyszczania w przypadkach, gdy sygnał nie wymagał modyfikacji (okna bez artefaktów), oraz w sytuacjach, gdy oczyszczanie było niezbędne (okna z artefaktami).

5. Rezultaty i dyskusja

W pierwszej części rozdziału przedstawiono analizę wpływu różnorodnych artefaktów na sygnały EEG, ze szczególnym uwzględnieniem identyfikacji źródeł zakłóceń oraz określenia tych, które mają największy wpływ na jakość rejestracji sygnałów EEG. W dalszej części rozdziału przedstawiono skuteczność eliminacji artefaktu zidentyfikowanego jako najbardziej istotne źródło zakłóceń. W tym celu wykorzystano tradycyjne metody, takie jak analiza niezależnych komponentów, regresja oraz filtracja adaptacyjna, a także zaproponowaną metodę hybrydową opartą na połączeniu konwolucyjnej sieci neuronowej i rekurencyjnej sieci LSTM. Dodatkowo, zaprezentowano porównanie metod w kontekście ich wpływu na dalszą analizę sygnałów EEG, w tym analizę SSVEP i ich klasyfikację [96]. Zarejestrowane dane zostały opracowane w formie tabel, wykresów, wyznaczonych parametrów sygnałów oraz współczynnika SNR_{SSVEP} .


5.1. Analiza wpływu artefaktów na sygnały EEG

W pierwszej kolejności zaprezentowano przebiegi sygnałów zarejestrowanych podczas tworzenia autorskiej bazy zawierającej jedenaście typów artefaktów. Wśród artefaktów wyróżniono grymas twarzy, mruganie, ruchy oczu (prawo, lewo), ruchy oczu (góra, dół), zaciskanie szczęki, ruchy językiem, napinanie mięśni karku, nadymanie policzków, mrużenie oczu, oddychanie i przełykanie śliny. Dodatkowo w celu zarejestrowania sygnału EEG pozbawionego artefaktów ruchowych i mięśniowych, uczestnik proszony był o skupienie wzroku na wyświetlanym na ekranie białym krzyżu (tzw. „Krzyżu fiksacji”). Metoda ta jest powszechnie stosowana w badaniach EEG [97] i umożliwia ograniczenie artefaktów wynikających z ruchów gałek ocznych. Przebiegi sygnałów zawierające wszystkie z jedenaście wymienionych artefaktów wykonywane przez jednego z użytkowników podczas przykładowej rejestracji przedstawiono na rysunku 13.




Rysunek 13. Fragment sygnałów zarejestrowanych podczas wykonywania 11 wybranych artefaktów przez jednego z użytkowników.

Na rysunku 13 można zauważyć, że artefakty różnią się od siebie zarówno amplitudą, jak i źródłem ich powstawania. Część artefaktów powoduje propagację na wiele elektrod, a niektóre z nich występują jedynie na kilku konkretnych elektrodach. Propagacja artefaktów na elektrodę *Oz* jest wyraźnie widoczna na rysunku 13 w oknach czasowych rozpoczynających się odpowiednio w 80, 130, 250 oraz 350 sekundzie przebiegu. Rysunek 14 przedstawia wybrane jednosekundowe okna z elektrody *Oz* dla „Krzyża fiksacji” oraz artefaktów.



Rysunek 14. Przedstawienie wybranych jednosekundowych okien dla „Krzyża fiksacji” oraz artefaktów na elektrodzie *Oz*.


Można zauważyć, że artefakty takie jak grymas twarzy, przełykanie śliny, napinanie karku czy zaciskanie szczęki są bardzo silnie propagowane na elektrodę *Oz* i zakłócają rejestrowaną na niej aktywność mózgową. Część artefaktów takich jak mrużenie oczu, oddychanie, mruganie, nadymanie policzków nie wprowadza istotnych zakłóceń w sygnale rejestrowanym na elektrodzie *Oz*. Analiza widmowa sygnałów umożliwia zaobserwowanie częstotliwości, które są zakłócone przez dany artefakt. Na rysunku 15 zaprezentowano widma, które zostały uśrednione dla każdego rodzaju artefaktu na podstawie zapisów z elektrody *Oz*, pochodzących od 12 użytkowników. Kolorem niebieskim zaznaczono widmo sygnałów zarejestrowanych w sesji „Krzyż fiksacji”, który pozwala zaobserwować jak wygląda sygnał w dziedzinie częstotliwości bez wykonywania jakichkolwiek artefaktów. „Krzyż fiksacji” stanowi pomocne odniesienie w ocenie stopnia zakłóceń sygnału EEG przez dany artefakt.



Rysunek 15. Uśrednione widma sygnałów artefaktów (kolor czarny) i „Krzyża fiksacji” (kolor niebieski) dla elektrody *Oz*.

Obserwując przebiegi widm na rysunku 15 możemy zauważyć, że każdy z artefaktów w pewnym stopniu różni się od sygnału odniesienia, którym jest „Krzyż fiksacji” (kolor niebieski). Niektóre z artefaktów zakłócają jedynie fragmenty użytecznych dla SSVEP częstotliwości, na przykład zakłócenia wywoływane ruchami oczu, mruganiem lub oddychaniem dotyczą częstotliwości 0-50Hz, a powyżej nich nie mają wpływu na widmo. Najmniej zakłócającym typem artefaktu jest artefakt mrużenia oczu, który subtelnie zakłóca jedynie bardzo niskie częstotliwości. Istnieją jednak artefakty, które wprowadzają bardzo widoczne zakłócenia praktycznie w całym zakresie widma. Są to napinanie karku, grymas twarzy, przełykanie śliny oraz zaciskanie szczęki. Potwierdza to obserwacje dokonane podczas

analizy sygnałów czasowych. Artefakt powodujący największe zakłócenia to artefakt zaciskania szczęki. Artefakty zaciskania szczęki występują w całym zakresie widma i przewyższają amplitudowo artefakt przełykania śliny. Pozostałe dwa artefakty, a więc grymas twarzy i napinanie karku zakłócają niskie częstotliwości. Celem przedstawienia zakresów zmienności poszczególnych artefaktów w zależności od użytkownika, dla każdego z okien wyznaczono widmo i obliczono jego energię. Rysunek 16 przedstawia widmową gęstość energii dla każdego z artefaktów w formie wykresu pudełkowego dla elektrody *Oz* w zakresie 1-100Hz. W analizie uwzględniono po 120 okien sygnałowych pochodzących od różnych uczestników (10 okien na osobę) dla każdego z artefaktów.



Rysunek 16. Widmowa gęstość energii dla elektrody *Oz* każdego z artefaktów.

Rozkład widmowej gęstości energii w formie wykresów pudełkowych (rysunek 16) pokazuje różnice między zakresami energii poszczególnych artefaktów. Dla niektórych typów zakłóceń można zaobserwować wartości odstające, które mogą sugerować zróżnicowanie w sposobie ich wykonywania. Niektóre z osób mogły wykonywać artefakty bardziej intensywnie, a inne mniej. Spowodowane to może być również inną budową mięśniową każdej z badanych osób. Niemniej jednak, da się wyróżnić charakterystyczne zakresy energii dla każdego z artefaktów. Zaciskanie szczęki i napinanie karku, uzyskują podobne wartości energii widmowej. Oba artefakty mają szeroki zakres energetyczny, co czyni je bardzo zróżnicowanymi. Mimo szerokiego zakresu energetycznego dla obu artefaktów, na podstawie

wcześniejszych analiz można wskazać, że to zaciskanie szczęki zawiera silniejsze i bardziej równomierne zakłócenia w całym zakresie częstotliwości użytecznych w EEG.

Jednoczesna akwizycja SSVEP wraz z artefaktami wymaga możliwości ciągłej obserwacji prezentowanego bodźca świetlnego podczas ich wykonywania. Artefakt zaciskania szczęki charakteryzuje się silnymi zakłóceniami propagowanymi na elektrodę *Oz*, a dodatkowo nie wymaga poruszania głową lub oczami, co umożliwia ciągłą obserwację prezentowanych bodźców wywołujących SSVEP.

Artefakt związany z zaciskaniem szczęki został wybrany jako reprezentatywny przykład zakłócenia sygnału EMG ze względu na swoje charakterystyczne właściwości oraz przydatność do testowania skuteczności metod oczyszczania sygnałów EEG. Zaciskanie mięśni żuchwy generuje sygnał o dużej amplitudzie, co sprawia, że jego wpływ na EEG jest wyraźny i łatwy do zaobserwowania. Dodatkowo, artefakt ten ma szerokie pasmo częstotliwości, obejmujące zarówno niskie, jak i średnie zakresy, przez co zakłóca wiele istotnych pasm EEG, takich jak theta, alfa czy beta.

Zaciśnięcie szczęki aktywuje duże grupy mięśni twarzy i szyi, w szczególności mięsień żwacz, który jest jednym z najsilniejszych mięśni ludzkiego ciała. Powoduje to powstanie rozległego artefaktu elektromiograficznego, dobrze odzwierciedlającego typowe zakłócenia związane z aktywnością mięśniową, taką jak mimika, mówienie czy ruchy głowy. Ze względu na łatwość identyfikacji momentu wystąpienia, artefakt ten stanowi dobry punkt odniesienia do oceny skuteczności metod oczyszczania. Co istotne, skuteczne usunięcie tego rodzaju zakłócenia może świadczyć o zdolności danej metody do redukcji również innych artefaktów mięśniowych, o podobnym charakterze i zakresie widmowym. Z tego względu zacisk szczęki został wybrany jako modelowy przykład artefaktu mięśniowego, który w dalszej części pracy poddano szczegółowej analizie oraz eliminacji z sygnałów EEG za pomocą wybranych metod oczyszczania.

5.2. Identyfikacja źródeł wybranych artefaktów

Inną istotną kwestią dotyczącą artefaktów zakłócających sygnały EEG jest określenie ich pochodzenia. Stanowi to kluczowy element w zrozumieniu mechanizmów powstawania artefaktów. W poprzednim podrozdziale opisano wybór najsilniej zakłócającego artefaktu, jednak poznanie źródła jego powstawania jest również bardzo istotne. Zrozumienie, skąd dokładnie pochodzą artefakty, pomaga nie tylko w ich skutecznej eliminacji, ale także umożliwia ich modelowanie. Ułatwia to również ocenę przydatności poszczególnych elektrod w analizie sygnału EEG. Niektóre elektrody rejestrują jednocześnie wiele rodzajów zakłóceń,


co czyni je szczególnie wartościowymi w procesie identyfikacji i usuwania artefaktów. Inne natomiast wykazują niską podatność na sygnały zakłócające, co może ograniczać ich zastosowanie, na przykład jako źródło sygnałów pomocniczych rejestrujących aktywność związaną z artefaktami, gdyż artefakty mięśniowe praktycznie na nich nie występują. W celu wyznaczenia źródeł artefaktów dla każdego z okien zawierających artefakty i każdej elektrody wyznaczono średnią wartość logarytmu mocy sygnału [μV^2] w paśmie 1-100Hz. Średnia moc w dziedzinie czasowej została obliczona z wykorzystaniem wzoru (3.1), a wyznaczone wartości zostały zlogarytmowane i zamieszczone w tabeli 15.


Tabela 15. Zlogarytmowane wartości średniej mocy sygnałów dla okien zawierających artefakty oraz dla „Krzyża fiksacji”.

	Oz	P4	P3	Cz	F4	F3	F9	Fp1	Kark	Pod okiem	Obok oka	Broda	Usta	Nos	Policzek	Szczęka
Krzyż fiksacji	2,31	1,71	1,60	1,73	1,82	1,71	1,49	1,75	2,82	1,51	1,49	2,49	1,60	1,46	1,55	1,64
Grymas Twarzy	3,09	2,90	2,84	2,90	3,63	4,69	4,16	6,07	3,22	3,82	3,70	6,36	6,02	3,99	4,24	3,91
Zaciskanie szczęki	3,47	3,54	3,73	3,68	4,10	3,98	3,99	3,73	3,34	3,98	4,11	3,22	3,39	3,70	4,08	4,73
Ruchy języka	2,70	2,21	2,12	2,23	2,52	2,54	3,06	3,72	3,03	3,10	3,26	3,80	2,98	2,77	2,72	2,74
Napinanie karku	3,31	2,93	2,83	2,77	2,82	2,75	3,06	2,90	3,44	3,17	3,31	3,76	3,01	2,93	2,98	3,19
Mruganie	2,94	2,34	2,30	2,68	3,63	3,86	5,05	5,33	2,88	3,62	4,04	2,51	2,60	3,11	2,47	2,10
Mrużenie oczu	3,10	2,22	2,20	2,35	3,08	3,36	4,47	5,53	2,92	4,62	4,43	2,84	4,67	3,16	2,79	2,48
Oddychanie	3,09	2,00	1,88	2,01	2,20	2,08	2,51	2,81	2,82	2,75	2,84	2,56	2,96	2,70	2,45	2,13
Nadymanie policzków	2,92	2,39	2,27	2,39	2,75	2,55	3,35	3,75	2,94	3,32	3,63	4,68	3,73	3,15	3,17	2,93
Przelykanie śliny	3,57	3,61	3,41	3,76	3,80	3,96	3,94	4,22	3,42	3,98	4,07	3,75	3,64	3,78	4,03	4,53
Ruchy oczu (G/D)	3,02	2,52	2,51	2,81	3,24	3,40	2,72	4,56	2,81	3,91	3,53	2,70	2,83	3,34	2,74	2,16
Ruchy oczu (L/P)	3,13	3,04	2,58	2,88	3,48	2,38	4,35	3,66	3,14	3,89	4,52	2,82	3,25	3,28	3,71	3,46

Analizując wartości zamieszczone w tabeli 15 można zauważyć, które z elektrod rejestrują najsilniejsze sygnały dla każdego z artefaktów. W przypadku artefaktu „Zaciskania szczęki” jest to elektroda *Szczęka* (4,73), a w przypadku artefaktu „Nadymania policzków”, elektroda *Broda*. Niektóre z artefaktów uzyskują porównywalną moc na kilku elektrodach, na przykład artefakt „Grymas twarzy” na elektrodach *Fp1* (6,07), *Usta* (6,02) oraz *Broda* (6,36). Analizując dane można również wskazać uniwersalną elektrodę EMG rejestrującą silne sygnały niezależnie od artefaktu. Jest to elektroda *Obok oka* charakteryzująca się najwyższą średnią mocą i dostarczająca istotnych informacji niezależnie od rodzaju rejestrowanego artefaktu. Obliczenie zlogarytmowanych wartości mocy sygnałów dla każdej z elektrod umożliwiło ich

odwzorowanie na powierzchni modelu głowy. W tym celu odwzorowano rozmieszczenie elektrod w modelu zgodnie z ich rzeczywistym położeniem anatomicznym, a następnie dokonano wizualizacji przestrzennego rozkładu mocy sygnałów w zależności od rodzaju generowanych artefaktów. Otrzymane rozkłady zlogarytmowanych wartości średnich mocy dla poszczególnych artefaktów przedstawiono na rysunku 17.






Rysunek 17. Rozkład zlogarytmowanych wartości średnich mocy sygnałów dla poszczególnych artefaktów.

Na podstawie wyników przedstawionych w tabeli 15 oraz przestrzennych rozkładów zlogarytmowanych mocy sygnałów zaprezentowanych na rysunku 17, możliwa była identyfikacja głównych źródeł poszczególnych artefaktów. Za źródło danego artefaktu przyjęto elektrodę, dla której wyznaczono najwyższe wartości logarytmu średniej mocy sygnału. Należy jednak zaznaczyć, że artefakty mięśniowe nie ograniczają się wyłącznie do jednej lokalizacji, lecz propagują się przestrzennie, wpływając na sygnały rejestrowane przez sąsiednie elektrody. Pomimo zauważalnej złożoności, przyjęto kryterium maksymalnej mocy jako podstawę do wyznaczenia elektrod źródłowych. Na podstawie wykonanych obliczeń określono przybliżone

lokalizacje źródłowe dla poszczególnych artefaktów. Podczas grymasów twarzy, ruchów języka, napinania karku i nadymania policzków najwyższą aktywność rejestrowano na elektrodzie *Broda*. Zaciskanie szczęki oraz przełykanie śliny przypisano do sygnałów rejestrowanych przez elektrodę *Szczęka*. Artefakty elektrookulograficzne, takie jak mruganie, mrużenie oczu oraz ruchy gałek ocznych (zarówno w osi góra-dół, jak i lewo-prawo), były najbardziej widoczne w sygnale z elektrody *Fpl* oraz w obszarze zlokalizowanym obok oka. Oddychanie natomiast było rejestrowane głównie w obrębie elektrody umieszczonej w okolicy ust. W bardzo wielu przypadkach elektrodą źródłową jest elektroda *Broda*, *Szczęka* oraz elektroda *Fpl*. Spowodowane jest to najprawdopodobniej lokalizacją dużych grup mięśniowych w okolicach wymienionych elektrod. Na rysunku 18 zaprezentowane zostaną przykładowe sygnały artefaktów z elektrod, które określone zostały jako źródłowe. Przedstawione sygnały umożliwiają ocenę kształtu zakłóceń generowanych przez pobliskie mięśnie.




Rysunek 18. Prezentacja artefaktów rejestrowanych na ich elektrodach źródłowych.

Analiza źródeł artefaktów pozwoliła zredukować liczbę elektrod EMG do takiej, która umożliwia rejestrację najważniejszych informacji. Do akwizycji docelowej bazy artefaktów zaciskania szczęki poza elektrodami EEG wybrano elektrodę *Fpl* oraz elektrody EMG *Szczęka*, *Obok oka*, *Policzek* oraz *Kark*. Elektroda *Fpl* pozwala na akwizycję artefaktów elektrookulograficznych, które występują mimowolnie i związane są z bezwarunkowymi odruchami człowieka. Elektroda *Szczęka* jest elektrodą uznaną za źródłową i jest kluczowa w akwizycji tego typu artefaktów. Elektrody *Policzek* oraz *Pod okiem* rejestrują najsilniejsze

zakłócenia powstające podczas zaciskania szczęki, a elektroda *Kark* pozwala na rejestrację artefaktów pochodzących z dużych grup mięśniowych zlokalizowanych w okolicach szyi.


5.3. Badanie użyteczności zarejestrowanej bazy SSVEP z artefaktami

Po określeniu artefaktu generującego największe zakłócenia oraz ograniczeniu zestawu elektrod do dziewięciu (*O1*, *Oz*, *O2*, *Cz*, *Fp1*, *Szczęka*, *Obok oka*, *Policzek*, *Kark*), przystąpiono do rejestracji sygnałów rzeczywistych od ochotników. Umożliwiło to przeprowadzenie dalszych badań dotyczących eliminacji artefaktów i porównania wybranych do tego celu metod. Oczyszczaniu podlegały sygnały zarejestrowane na elektrodach EEG: *O1*, *Oz*, *O2* i *Cz*. Elektrody *O1*, *Oz* i *O2* umożliwiły rejestrację SSVEP, poza akwizycją typowej aktywności mózgowej. W pierwszych dwóch etapach badania rejestrowano sygnały podczas obserwacji „Krzyża fiksacji” oraz w trakcie celowego zaciskania szczęki, mającego na celu wywołanie artefaktu. Po przeprowadzaniu wstępnej rejestracji każdemu z uczestników badania prezentowane były bodźce świetlne o określonej częstotliwości (6, 7, 8, 9 i 25Hz). Podczas prezentacji bodźców świetlnych, badani siedzieli nieruchomo i obserwowali panel z pulsującymi diodami LED, a następnie jednocześnie z ich obserwacją, wykonywali artefakt zaciskania szczęki. Każda z pojedynczych rejestracji nie przekraczała 60 sekund, a łączny czas badania nie przekraczał 30 minut. Niestety, u wielu uczestników badania nie udało się wywołać odpowiedzi SSVEP dla częstotliwość 25Hz. Większość osób poprawnie reagowała jednak na bodźce o niższych częstotliwościach. Na rysunku 19 zaprezentowano przykładową rejestrację sygnałów trwającą 60 sekund. Rejestracja dotyczy „Krzyża fiksacji” podczas którego uczestnik siedział nieruchomo i wpatrywał się w wyświetlony na ekranie krzyż. Jako sygnał wolny od zakłóceń, „Krzyż fiksacji” stanowi punkt odniesienia umożliwiający ocenę, czy artefakty wywoływane przez badanego w kolejnych etapach eksperymentu prowadziły do istotnych zmian w zapisie EEG. Ponadto, sygnał może stanowić podstawę do porównań z sygnałem oczyszczonym z artefaktów, co pozwala na ocenę efektywności procesu oczyszczania danych.



Rysunek 19. Sygnały EEG zarejestrowane podczas trwania „Krzyża fiksacji”.


Obserwując przebiegi zamieszczone na rysunku 19 można zauważyć, że pomimo starań osoby badanej, niektórych artefaktów nie da się wyeliminować, na przykład związanych z mruganiem. Jest ono odruchem bezwarunkowym, a więc nie jest możliwe do zatrzymania. W prezentowanym przykładzie jest ono widoczne głównie na elektrodzie *Fp1* oraz *Obok oka*. Kolejny rysunek (20), prezentuje 30 sekundowy fragment rejestracji podczas której użytkownik proszony był o wykonywanie artefaktu zaciskania szczęki w 2-3 sekundowych odstępach.



Rysunek 20. Sygnały EEG zarejestrowane podczas wykonywania artefaktów zaciskania szczęki.


Wykonywanie artefaktu zaciskania szczęki (rysunek 20) powoduje znaczące zaburzenia w przebiegach sygnałów EEG na elektrodach *O1*, *Oz*, *O2*, *Cz*, a także innych. Artefakt jest

bardzo silnie propagowany z elektrody *Szczęka* na pozostałe elektrody. Potrzeba oczyszczania elektrod istotnych dla interfejsów mózg-komputer jest więc silnie uzasadniona i to na tych elektrodach skupiono się podczas oczyszczania sygnałów. Jako najbardziej reprezentatywną wybrano elektrodę *Oz* umieszczoną pośrodku tylnej części głowy, pomiędzy elektrodami *O1* i *O2*. Zamieszczenie wszystkich wyników w treści pracy nie byłoby czytelne, więc zdecydowano o wyborze i prezentacji tych najbardziej istotnych. Na rysunku 21 przedstawiono porównanie widm wyznaczonych dla rejestracji z „Krzyżem fiksacji” oraz z artefaktem zaciskania szczęki dla elektrody *Oz*.




Rysunek 21. Porównanie widm wyznaczonych dla rejestracji z „Krzyżem fiksacji” oraz z artefaktem zaciskania szczęki.

Na rysunku 21 zaprezentowano różnice w amplitudach obu rejestracji i zaprezentowano w jaki sposób artefakt zaciskania szczęki zakłóca widmo sygnału praktycznie w całym zakresie częstotliwości (w sposób najbardziej znaczący powyżej 3Hz). Widmo wyznaczone dla rejestracji z zaciskaniem szczęki dotyczy również tych fragmentów, które nie zawierają samego artefaktu (odstępów między kolejnymi zaciśnięciami). Aby skupić się dokładniej na samym artefakcie dokonano wizualnego wyboru okien z każdej sesji pomiarowej. Wybierano okna z artefaktami oraz bez artefaktów. Przykładowe okna z artefaktami i bez zaznaczone zostały na rysunku 22, a ich widmo dla elektrody *Oz* przedstawiono na rysunku 23.



Rysunek 22. Wybór okien z rejestracji z zaciskaniem szczęki.




Rysunek 23. Zestawienie widm dla okien z artefaktami (kolor czerwony) i bez artefaktów (kolor niebieski).

Na rysunku 22 kolorem czerwonym zaznaczono przykładowe okno z artefaktem, a kolorem niebieskim bez artefaktu. Widoczne różnice między poszczególnymi oknami obrazują widma zaprezentowane na rysunku 23. Wybór takich okien umożliwia łatwiejsze i bardziej spójne porównanie efektywności oczyszczania sygnału. Między różnymi rejestracjami (np. „Krzyż fiksacji” i zaciskanie szczęki) warunki pomiarowe i skupienie badanej osoby może ulec niewielkiej zmianie. Elektrody mogą się delikatnie przemieścić na skutek relaksu/rozluźnienia po rejestracji lub osoba może nie zachować podobnego skupienia w obu sesjach pomiarowych z powodu znużenia. Już delikatna zmiana warunków badania spowoduje różnice w sygnałach.

W przypadku podejścia z oknami pochodzącymi z tej samej rejestracji (okna bez artefaktów i z artefaktami selekcjonowane wizualnie), opisywany problem zostaje rozwiązany. Okna z artefaktami po oczyszczeniu powinny przypominać okna bez artefaktów. Dodatkowo wszelkie stosowane metody nie powinny modyfikować widm sygnałów w oknach bez artefaktów. Po przeprowadzeniu wstępnej analizy oraz wizualnej inspekcji sygnałów EEG, zarejestrowana baza danych została uznana za odpowiednią do dalszych etapów badań dotyczących porównania metod oczyszczania sygnałów.

5.4. Porównanie metod oczyszczania na danych syntetycznych


W tej części rozdziału zaprezentowane zostanie działanie metod oczyszczania na syntetycznych danych testowych, wygenerowanych przy użyciu zaprojektowanego generatora sygnałów EEG oraz artefaktów. W tym przypadku możliwe jest wyznaczenie parametrów służących do oceny jakości oczyszczania, ponieważ generator dostarcza również wersję sygnału przed dodaniem zakłóceń. Zastosowane podejście pozwala na obliczenie błędu RMSE, który odzwierciedla stopień zgodności sygnału oczyszczonego z referencyjnym. Na rysunku 24 przedstawiono sygnał ze zbioru testowego pochodzący z generatora. Zaprezentowano na nim sztucznie generowane przebiegi ze wszystkich elektrod wraz z artefaktem zaciskania szczęki.




Rysunek 24. Sztucznie wygenerowany sygnał artefaktu związanego z zaciskaniem szczęki, pochodzący ze zbioru testowego.

Wygenerowany zestaw danych obejmuje również sygnał EEG przed nałożeniem zakłóceń (docelowy przebieg sygnału po oczyszczeniu). Sygnał pozbawiony zakłóceń, zestawiony z jego

wersją po nałożeniu zakłóceń, przedstawiono na rysunku 25, natomiast odpowiadające im widma zaprezentowano na rysunku 26.




Rysunek 25. Syntetyczny sygnał z kanału EEG przed i po dodaniu artefaktu zaciskania szczęki.



Rysunek 26. Widmo sztucznego sygnału z kanału EEG przed i po dodaniu artefaktu zaciskania szczęki.

Dla wygenerowanego sygnału zostały zastosowane wybrane metody oczyszczania: sieć CNN-LSTM, ICA, regresja liniowa oraz filtracja adaptacyjna LMS i RLS. W przypadku ICA niezbędna była selekcja wizualna komponentów. Parametry filtrów LMS i RLS zostały ustawione eksperymentalnie zgodnie ze wcześniejszym opisem w rozdziale dotyczącym metod

badawczych. Wyniki oczyszczania (oznaczone kolorem czerwonym) względem pożądanego sygnału (oznaczonego kolorem niebieskim) przedstawiono na rysunku 27.



Rysunek 27. Oczyszczone sygnały uzyskane z wykorzystaniem wybranych metod (czerwony), zestawione z oczekiwanym przebiegiem referencyjnym (niebieski).

Na etapie analizy sygnału w dziedzinie czasu widoczne są różnice w oczyszczaniu sygnału EEG z wykorzystaniem badanych metod. Filtracja adaptacyjna mimo wielokrotnych prób nie radzi sobie tak dobrze z usuwaniem artefaktów jak pozostałe metody. Regresja liniowa niekiedy dosyć dalece odbiega od przebiegu idealnego, ale zachowuje podobny kształt sygnału. Metoda ICA radzi sobie dobrze, ale tutaj również możemy zauważyć różnice między wzorcem, a oczyszczonym sygnałem. Oczyszczanie sygnału z wykorzystaniem sieci CNN-LSTM pozwala na skuteczne usunięcie artefaktów przy jednoczesnym braku modyfikacji jego

niezakłóconych fragmentów. Model nie ingeruje w czysty sygnał, co jest istotne w dalszej analizie EEG. Na rysunku 27 widoczne są pewne różnice pomiędzy sygnałem oczyszczonym a docelowym. Mają one charakter miejscowy i nie wpływają znacząco na przydatność sygnału. CNN-LSTM wypada bardzo dobrze w zadaniu eliminacji artefaktów z sygnału EEG, przewyższając pod tym względem pozostałe analizowane metody. Należy jednak pamiętać, że na podstawie samej oceny wizualnej trudno jednoznacznie określić jakość oczyszczania. Aby uzyskać obiektywną miarę różnic między poszczególnymi sygnałami oczyszczonymi a sygnałem docelowym, można wyznaczyć błąd RMSE. Dla sygnałów z rysunku 27 przedstawiono go w tabeli 16.

Tabela 16. Błędy RMSE dla sygnałów z rysunku 27.

	CNN-LSTM	ICA	LR	LMS	RLS
RMSE	3,83	4,97	6,72	13,36	9,67


W kolumnach tabeli 16 znajdują się wyniki RMSE dla każdej z metod wykorzystanych do oczyszczania sygnału EEG z artefaktem. Każda z metod redukuje znacząco artefakty (względem sygnału wejściowego), jednak zdecydowanie najgorszą skutecznością charakteryzuje się filtracja adaptacyjna LMS oraz RLS. Oba typy filtracji charakteryzują się najwyższymi błędami RMSE. Pozostawiają również dużo większe amplitudy sygnałów niż amplitudy obecne w sygnale docelowym EEG. Mimo redukcji artefaktów względem przebiegu wejściowego, filtracja adaptacyjna nie redukuje ich całkowicie, a różnice między przebiegiem docelowym są dużo większe niż dla pozostałych metod. Metody CNN-LSTM, ICA i regresja uzyskują lepsze wyniki, jednakże najniższym błędem wyróżnia się model CNN-LSTM. Potwierdza to obserwacje dokonane w trakcie analizy sygnałów w dziedzinie czasu.

Podczas zaprezentowanej analizy dokonano dokładnego przedstawienia wszystkich metod oczyszczania dla jednego z sygnałów testowych. Teraz zestawione zostaną średnie błędy RMSE dla wszystkich 12 000 sygnałów ze zbioru testowego. Z analizy wyłączono metodę składowych niezależnych, ponieważ wymaga ręcznego doboru użytecznych komponentów, co było niemożliwe w ramach tego badania. Otrzymane błędy RMSE wraz z odchyleniem standardowym (STD) dla CNN-LSTM, regresji liniowej i filtracji adaptacyjnej zestawiono w tabeli 17.

Tabela 17. Błędy RMSE dla 12 000 danych testowych dla CNN-LSTM, regresji liniowej i filtracji adaptacyjnej.

	CNN-LSTM	LR	LMS	RLS
RMSE	4,26	6,61	20,58	11,77
STD	1,45	3,71	7,03	4,23

Wartości błędów zamieszczone w tabeli 17 potwierdzają wcześniejsze obserwacje. Najniższy błąd uzyskuje sieć CNN-LSTM, a najwyższy filtracja adaptacyjna LMS. Metoda regresji liniowej również cechuje się niskim błędem, jednak z dużo większym odchyleniem standardowym. Dokładniejsze wyniki zostały przedstawione w postaci wykresów pudełkowych na rysunku 28.




Rysunek 28. Wykresy pudełkowe błędów dla danych testowych.

Regresja liniowa w porównaniu do CNN-LSTM cechuje się dużo większym rozproszeniem wyników, a wyznaczone błędy sporadycznie przekraczają wartości uzyskane dla filtracji LMS (wartości odstające).

5.5. Oczyszczanie sygnałów EEG zawierających potencjały SSVEP


W tej części rozdziału zaprezentowane zostanie działanie metod oczyszczania sygnałów na danych rzeczywistych. Podczas akwizycji zgromadzono łącznie 48 poprawnie zarejestrowanych sygnałów z artefaktami zaciskania szczęki oraz jednoczesnym wywoływaniem SSVEP o różnych częstotliwościach (6, 7, 8, 9, 25Hz). Analiza obejmowała zarówno całe sygnały, jak i wyselekcjonowane okna z artefaktami oraz pozbawione zakłóceń. Dla niektórych uczestników badania nie udało się wywołać wszystkich pięciu częstotliwości SSVEP (najbardziej problematyczne było 25Hz). Dla każdej z metod przedstawiono jej dokładne działanie na jednym wybranym sygnale, a następnie zestawiono wyniki dla wszystkich sygnałów w formie graficznej i tabelarycznej. Jako przykład została wybrana rejestracja z artefaktami zaciskania szczęki oraz SSVEP wywoływanym częstotliwością 9Hz. Decyzja o wyborze sesji pomiarowej motywowana jest obecnością silnych zakłóceń

związanych z zaciskaniem szczęki, które w widoczny sposób propagują się na elektrody EEG. Stwarza to odpowiednie warunki do prezentacji zastosowanych metod usuwania artefaktów, a także oceny ich skuteczności. Na rysunku 29 zaprezentowano fragment sygnału EEG pochodzącego z jednej z rejestracji, wybranej w celu ilustracji działania poszczególnych metod oczyszczania.



Rysunek 29. Fragment rejestracji z artefaktem zaciskania szczęki i SSVEP 9Hz.

Z zarejestrowanej sesji pomiarowej wybrano po 17 okien z artefaktami oraz bez artefaktów. Oczyszczaniu podlegały elektrody *O1*, *Oz*, *O2* oraz *Cz*, ale w dalszych analizach skupiono się głównie na elektrodzie *Oz* celem zredukowania liczby prezentowanych danych. Średnia wartość modułu widma dla poszczególnych okien sygnału dla elektrody *Oz* została przedstawiona na rysunku 30.




Rysunek 30. Średnia wartość modułu widma dla poszczególnych okien sygnału z artefaktem zaciskania szczęki i wolnych od artefaktu.

Obserwując sygnały na rysunku 29 możemy zauważyć w jaki sposób artefakty zaciskania szczęki zakłócają przebiegi sygnałów EEG. Dobrze widoczna jest również propagacja artefaktów z elektrody *Szczęka* na pozostałe elektrody, w szczególności na elektrody EEG (*O1*, *Oz* i *O2*). Rysunek 30 przedstawia uśrednione widma dla okien z artefaktami i bez. Można zauważyć, że zaciskanie szczęki powoduje zakłócenia w widmie w praktycznie całym paśmie częstotliwości. Warto zaobserwować również prążek 9Hz, który został wywołany prezentowanymi bodźcami wizualnymi i w przypadku okien bez artefaktów jest dobrze wyeksponowany ponad całe tło widma. Dla okien z artefaktami pojawia się wiele prążków z dużymi amplitudami i interesujący nas prążek SSVEP zanika pośród całego widma. Ważne jest więc, aby metody oczyszczania po usunięciu artefaktów nie usunęły również istotnych informacji i przywróciły odpowiednią widoczność prążków związanych z SSVEP. Do oceny jakości oczyszczania zostaną wykorzystane wizualizacje, wyznaczone parametry sygnałów, a także opisywany wcześniej widmowy współczynnik stosunku sygnału do szumu (SNR_{SSVEP}). W kolejnych podrozdziałach przedstawiono efekty oczyszczania sygnału EEG zaprezentowanego na rysunku 29, z wykorzystaniem każdej z analizowanych metod. Skupiono się głównie na elektrodzie *Oz*, a uśrednione parametry zbiorcze dla okien z artefaktami oraz bez artefaktów zestawiono w dalszej części pracy po prezentacji oczyszczania przykładowego sygnału.


5.5.1. Sieć neuronowa CNN-LSTM

Efekt oczyszczania sygnału z wykorzystaniem sieci CNN-LSTM został zaprezentowano na rysunku 31.




Rysunek 31. Efekt oczyszczania sygnału z wykorzystaniem CNN-LSTM.

Wizualna analiza sygnałów zaprezentowanych na rysunku 31 sugeruje, że artefakty z elektrod EEG zostały usunięte. Część artefaktów nadal była obserwowana na elektrodzie Cz. Na podstawie obserwacji przebiegów z rysunku 31 nie jesteśmy jednak w stanie ocenić jak dokładnie przebiegło oczyszczanie. W tym celu na rysunku 32 zaprezentowany został fragment sygnału z artefaktem zaciskania szczęki z elektrody Oz oraz jego oczyszczony przebieg za pomocą CNN-LSTM występujący około 10 sekundy rejestracji. Prezentacja całego sygnału jest nieczytelna i nie pozwala zobrazować kluczowych aspektów oczyszczania. Analiza sygnału w zawężonym oknie czasowym pozwala na uwidocznienie istotnych szczegółów i dokładniejszą ocenę oczyszczonego przebiegu.




Rysunek 32. Fragment sygnału z artefaktem zaciskania szczęki przed i po jego oczyszczaniu z wykorzystaniem CNN-LSTM..

Na rysunku 32, przedstawiono powiększony fragment sygnału z artefaktem oraz efekt jego oczyszczania z wykorzystaniem sieci CNN-LSTM. Artefakt został usunięty, a otrzymany przebieg stanowi płynną kontynuację sygnału bez artefaktów. Ponadto fragmenty pozbawione artefaktów nie zostały zmodyfikowane. Modyfikacje sygnału EEG przez sieć CNN-LSTM występują wyłącznie w obecności zakłóceń, co świadczy o jej selektywnym działaniu. Celem potwierdzenia obserwacji na rysunkach 33 i 34 zostały zaprezentowane średnie wartości modułu widma dla poszczególnych okien sygnału bez artefaktów oraz z artefaktami dla elektrody *Oz*.



Rysunek 33. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów: sygnał rzeczywisty i oczyszczony za pomocą CNN-LSTM.




Rysunek 34. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów i z artefaktami: sygnał rzeczywisty i oczyszczony za pomocą CNN-LSTM.

Analiza średnich wartości modułu widma dla okien pozbawionych artefaktów (rysunek 33) pokazuje, że sieć CNN-LSTM wprowadza w ich przypadku jedynie minimalne modyfikacje. W przypadku okien z artefaktami widoczna jest duża redukcja amplitud, jednakże amplituda prążka widma odpowiadającego częstotliwości SSVEP (9Hz) pozostała niezmienną. Rysunek 34 zawiera także dodany przebieg ze średnim widmem dla okien bez artefaktów, aby zaprezentować jak wyglądają widma okien z artefaktami po oczyszczaniu względem okien bez artefaktów. W oczyszczonym sygnale, metoda CNN-LSTM doprowadziła do nieznacznego obniżenia amplitudy w zakresie 20–40Hz, przy zachowaniu ogólnego kształtu widma. Średnie wartości mocy sygnału w oknach pozbawionych artefaktów przed oczyszczeniem ($121,68 \mu V^2$) były porównywalne do tych uzyskanych po oczyszczaniu za pomocą sieci neuronowej ($116,65 \mu V^2$), co sugeruje, że samo oczyszczanie nie miało istotnego wpływu na moc sygnału w tych fragmentach. Potwierdza to, że sieć CNN-LSTM nie wprowadza istotnych zmian w sygnałach pozbawionych artefaktów. Minimalne i maksymalne amplitudy wyznaczone dla okien z artefaktami ($-62,89 \mu V$ i $53,14 \mu V$) zostały znacząco zredukowane ($-32,42 \mu V$ i $25,09 \mu V$) i są zbliżone do tych, które charakteryzują okna bez artefaktów ($-32,95 \mu V$ i $27,89 \mu V$). Wyznaczone wartości parametrów świadczą o tym, że okna po oczyszczeniu są podobne do okien bez artefaktów. Widoczna jest natomiast redukcja mocy sygnału po oczyszczaniu dla okien z artefaktami (z $387,97 \mu V^2$ do $96,76 \mu V^2$) względem mocy wyznaczonej dla okien bez artefaktów ($121,68 \mu V^2$). Prawdopodobnie jest to spowodowane redukcją amplitud na częstotliwościach 20-40Hz widoczną na rysunku 34. W analizowanych widmach dla obu

rodzajów okien, można zauważyć wyraźny prążek odpowiadający częstotliwości SSVEP (9Hz). W przypadku okien z artefaktami współczynnik SNR_{SSVEP} wyniósł 1,27, a po zastosowaniu CNN-LSTM dla tych okien wzrósł do wartości 2.43. Dla okien bez artefaktów nastąpiła zmiana z 2,06 na 2,16.


5.5.2. Analiza składowych niezależnych

Analiza wyników dla każdej z prezentowanych metod będzie przebiegała w pełni analogicznie do analizy wykonanej dla sieci CNN-LSTM w rozdziale 5.6.1. Na początku przedstawione zostaną oczyszczone sygnały EEG w dziedzinie czasu, co zaprezentowano na rysunku 35.




Rysunek 35. Efekt oczyszczania sygnału z wykorzystaniem ICA.

Porównując sygnały oczyszczone przy użyciu metody ICA (rysunek 35) z sygnałami przed oczyszczaniem (rysunek 29), można stwierdzić, że technika ta prowadzi do częściowego usunięcia artefaktów. Zauważalne jest, że niektóre zakłócenia spowodowane artefaktem zaciskania szczęki zostały jedynie osłabione, a nie całkowicie wyeliminowane. W porównaniu z wynikami uzyskanymi przy użyciu sieci CNN-LSTM, sygnały po zastosowaniu ICA zawierają więcej pozostałości artefaktów. Na rysunku 36 przedstawiono fragment sygnału zawierający artefakt zaciskania szczęki oraz rezultat jego eliminacji przez metodę ICA dla elektrody *Oz*.




Rysunek 36. Fragment sygnału z artefaktem zaciskania szczęki przed i po jego oczyszczaniu z wykorzystaniem ICA.

Analizując fragment sygnału zamieszczony na rysunku 36 możemy zauważyć, że ICA dobrze radzi sobie z zachowywaniem sygnału niezakłóconego. Uśredniona moc dla okien bez artefaktów po oczyszczaniu wyniosła $113,19 \mu V^2$. W przypadku wystąpienia artefaktów, ICA nie powoduje ich całkowitego usunięcia, a jedynie niewielką redukcję. Potwierdza to wyznaczona dla okien zawierających artefakty uśredniona wartość mocy równa $270,97 \mu V^2$. Podobne wnioski można wyciągnąć obserwując rysunki 37 oraz 38, na których zaprezentowano średnią wartość modułu widma dla poszczególnych okien sygnału dla okien bez artefaktów oraz z artefaktami dla elektrody Oz.



Rysunek 37. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów: sygnał rzeczywisty i oczyszczony za pomocą ICA.




Rysunek 38. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów i z artefaktami: sygnał rzeczywisty i oczyszczony za pomocą ICA.

Widma przedstawione na rysunkach 37 i 38 są zgodne z obserwacjami dokonanymi na podstawie sygnału EEG analizowanego w dziedzinie czasu. Sygnały EEG oczyszczone z wykorzystaniem metody ICA zachowują przebieg zbliżony do oryginału w przypadku okien pozbawionych artefaktów. Zarówno poziom amplitudy, jak i charakterystyka sygnału pozostają praktycznie niezmienione. Przykładowo, wartości maksymalne i minimalne dla takich okien po oczyszczaniu wynosiły odpowiednio $28,07 \mu\text{V}$ oraz $-32,02 \mu\text{V}$, co jest porównywalne z wartościami sprzed oczyszczania. W przypadku okien zawierających artefakty, zaobserwowano jedynie częściową redukcję ich amplitudy. Po zastosowaniu metody ICA, wartości maksymalne i minimalne wyniosły odpowiednio $44,75 \mu\text{V}$ i $-49,25 \mu\text{V}$, co wskazuje na ograniczoną skuteczność metody w eliminowaniu artefaktów zaciskania szczęki. Jednocześnie, średnie widmo sygnału dla okien z artefaktami po oczyszczaniu istotnie różni się od widma typowego dla okien wolnych od artefaktów (rysunek 38), co świadczy o ograniczonej skuteczności ICA w usuwaniu zakłóceń. Choć metoda ICA nie usuwa prążka odpowiadającego częstotliwości bodźca SSVEP (9Hz), to częściowe tłumienie artefaktów nie przekłada się na jego wyraźniejsze uwidocznienie ponad poziom tła. Dla okien bez artefaktów wskaźnik SNR_{SSVEP} wyniósł 2,2, natomiast dla okien z artefaktami 1,53. Potwierdza to, że metoda zachowuje strukturę sygnału w przypadku braku zakłóceń, natomiast jej skuteczność względem intensywnych artefaktów mięśniowych pozostaje ograniczona. Dodatkowo należy podkreślić, że skuteczne zastosowanie metody ICA wymaga eksperckiej wiedzy oraz ręcznego wyboru

odpowiednich komponentów, co może istotnie utrudniać proces oczyszczania i wpływać na brak powtarzalności dalszych analiz.


5.5.3. Regresja liniowa

Kolejną z analizowanych metod jest regresja liniowa (LR). Oczyszczone z jej pomocą sygnały przedstawiono na rysunku 39.




Rysunek 39. Efekt oczyszczania sygnału z wykorzystaniem regresji liniowej (LR).

Na podstawie przebiegów przedstawionych na rysunku 39 można stwierdzić, że model regresji liniowej pozwala na skuteczniejszą redukcję artefaktów niż metoda ICA. Artefakty są widocznie zredukowane (uśredniona moc dla okien z artefaktami wyniosła $224,89 \mu V^2$), jednak na elektrodach EEG nadal da się zauważyć miejsca w których występowały przed ich usuwaniem. Przybliżony fragment jednego z sygnałów zawierający artefakt zaciskania szczęki i jego redukcję z wykorzystaniem regresji dla elektrody *Oz* zaprezentowano na rysunku 40.




Rysunek 40. Fragment sygnału z artefaktem zaciskania szczęki przed i po jego oczyszczeniu z wykorzystaniem LR.

Podobnie jak poprzednio analizowane metody, regresja liniowa zdaje się nie modyfikować przebiegów bez artefaktów (moc $113,65 \mu V^2$). W przypadku napotkania artefaktu zostaje on zredukowany, ale mimo usuwania nadal widoczne są jego fragmenty. Model nie usuwa artefaktów tak dobrze jak CNN-LSTM. Średnie wartości modułu widma dla poszczególnych okien sygnału bez artefaktów i z artefaktami dla elektrody *Oz* przedstawione zostały na rysunkach 41 i 42.



Rysunek 41. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów: sygnał rzeczywisty i oczyszczony za pomocą LR.




Rysunek 42. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów i z artefaktami: sygnał rzeczywisty i oczyszczony za pomocą LR.

Analiza średnich wartości modułu widma dla okien sygnału wolnych od artefaktów (rysunek 41) wskazuje, że model regresji liniowej powoduje redukcję niskoczęstotliwościowych składowych sygnału. Taka zmiana jest niepożądana, ponieważ ingeruje w okna sygnału, które nie zawierają artefaktów. Pozostała część widma jest jednak odwzorowana prawidłowo. Średnia wartość modułu widma dla okien z artefaktami (rysunek 42) pokazuje znaczną rozbieżność między sygnałem oczyszczonym a sygnałami pochodzącymi z okien wolnych od artefaktów. Wskazuje to, że model regresji nie usunął artefaktów całkowicie, pozostawiając je w całym zakresie częstotliwości. Artefakty są jednak mniej widoczne niż w przypadku metody ICA. Współczynnik SNR_{SSVEP} dla okien wolnych od artefaktów pozostał niezmienny i wyniósł 2,06, natomiast dla okien z artefaktami wzrósł do 1,75. Metoda regresji powoduje niezamierzone zwiększenie amplitudy prążka widma odpowiadającego częstotliwości SSVEP, co jest problematyczne, ponieważ w przypadku obecności artefaktów w całym widmie, amplituda tego prążka powinna zostać obniżona po skutecznej eliminacji zakłóceń. Zwiększenie amplitudy prążka jest nieuzasadnione, ponieważ artefakty powinny obniżyć intensywność większości komponentów widma. Model regresji liniowej nie wprowadza istotnych zmian w oknach wolnych od artefaktów, gdzie wartości minimalna i maksymalna wynoszą odpowiednio $-32,05 \mu V$ i $27,07 \mu V$. W przypadku okien z artefaktami, model częściowo redukuje amplitudy artefaktów (wartości minimalna i maksymalna: $-46,08 \mu V$ i $41,13 \mu V$). Mimo to, parametry dla oczyszczonych okien z artefaktami są nadal znacząco różne niż parametry wyznaczone dla okien wolnych od zakłóceń. Skuteczność modelu regresji

liniowej jest wyższa niż metody ICA, lecz niższa niż modelu CNN-LSTM. Istotnym mankamentem metody regresji jest zmiana amplitudy prążka widma odpowiadającego częstotliwości SSVEP (9Hz), co jest nieakceptowalne. Z drugiej strony, model regresji działa automatycznie i nie wymaga ręcznego wyboru komponentów, jak miało to miejsce w przypadku ICA.


5.5.4. Filtracja adaptacyjna LMS

Sygnał oczyszczony z wykorzystaniem filtracji LMS został zaprezentowany na rysunku 43. Parametry filtru zostały dobrane eksperymentalnie i zostały opisane w rozdziale 4.1.4.




Rysunek 43. Efekt oczyszczania sygnału z wykorzystaniem filtracji LMS.

Porównując oczyszczone sygnały z rysunku 43 z tymi uzyskanymi przy użyciu wcześniej omawianych metod, można stwierdzić, że zastosowana metoda eliminacji artefaktów jest mało efektywna. Na rysunku 44 przedstawiono fragment sygnału z elektrody *Oz* zawierający artefakt zaciskania szczęki oraz efekt jego oczyszczania za pomocą filtracji LMS.




Rysunek 44. Fragment sygnału z artefaktem zaciskania szczęki przed i po jego oczyszczaniu z wykorzystaniem filtracji LMS.

Analiza sygnału przedstawionego na rysunku 44, wskazuje na niską skuteczność filtracji LMS w eliminacji artefaktu zaciskania szczęki. Metoda ta nie ingeruje znacząco w sygnał wolny od zakłóceń, co jest efektem pożądanym, jednak nie usuwa artefaktu w sposób skuteczny. Zakłócenia pozostają wyraźnie widoczne, a ich amplitudy zostały jedynie częściowo zredukowane. Zakres amplitud dla okien bez artefaktów zawierał się w zakresie od $-32,75 \mu\text{V}$ do $28,5 \mu\text{V}$, a dla okien z artefaktami od $-48,61 \mu\text{V}$ do $42,15 \mu\text{V}$. Średnie wartości modułu widma dla okien bez artefaktów oraz zawierających artefakty dla elektrody *Oz* przedstawiono odpowiednio na rysunkach 45 i 46.



Rysunek 45. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów: sygnał rzeczywisty i oczyszczony za pomocą filtracji LMS.




Rysunek 46. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów i z artefaktami: sygnał rzeczywisty i oczyszczony za pomocą filtracji LMS.

Analiza średnich wartości modułu widma przedstawionych na rysunkach 45 i 46 pokazuje, że filtracja LMS prowadzi do niewielkich zmian widma sygnału w przypadku okien wolnych od artefaktów, głównie w zakresie niskich częstotliwości. W oknach zawierających zakłócenia zaobserwowano redukcję amplitud artefaktów na poziomie zbliżonym do uzyskanego przy użyciu metody ICA. W odróżnieniu od regresji liniowej, filtracja LMS nie powoduje sztucznego wzmocnienia amplitudy prążka widma odpowiadającego częstotliwości SSVEP. Dodatkowo, w przeciwieństwie do ICA, metoda ta nie wymaga ręcznej selekcji komponentów. W sygnałach wolnych od zakłóceń wpływ działania filtracji LMS jest minimalny. Średnia moc sygnału po oczyszczeniu spadła nieznacznie do $120,89 \mu V^2$. Dla okien z artefaktami zaobserwowano również spadek mocy (średnio $246,16 \mu V^2$), co wskazuje na częściową redukcję zakłóceń. Efektywność redukcji jest jednak niższa niż w przypadku sieci CNN-LSTM oraz modelu regresji liniowej. Wartość współczynnika SNR_{SSVEP} po oczyszczaniu zmniejszyła się do 2,03 dla okien bez artefaktów, natomiast dla okien z artefaktami wzrosła do 1,62.


5.5.5. Filtracja adaptacyjna RLS

Kolejnym podejściem zastosowanym do oczyszczania sygnału była filtracja adaptacyjna RLS. Efekt oczyszczania sygnału z wykorzystaniem filtracji RLS został zaprezentowany na rysunku 47.



Rysunek 47. Efekt oczyszczania sygnału z wykorzystaniem filtracji RLS.


Sygnały EEG oczyszczone za pomocą filtracji RLS przedstawione na rysunku 47, zawierają widoczne pozostałości artefaktów. Obecność zakłóceń wskazuje, że choć metoda RLS umożliwia redukcję artefaktów, nie prowadzi do ich całkowitego usunięcia. W sygnale wciąż można zidentyfikować miejsca odpowiadające wcześniej występującym artefaktom. Fragment przykładowego sygnału zawierającego artefakt zaciskania szczęki oraz efekt jego oczyszczania dla elektrody *Oz* przedstawiono na rysunku 48.




Rysunek 48. Fragment sygnału z artefaktem zaciskania szczęki przed i po jego oczyszczaniu z wykorzystaniem filtracji RLS.

Analiza przebiegu sygnału po filtracji RLS (rysunek 48) potwierdza, że metoda ta w większym stopniu niż wcześniej omawiane techniki ingeruje w sygnał EEG wolny od

zakłóceń. Choć artefakty są częściowo redukowane, ich całkowite usunięcie nie następuje. Na rysunkach 49 i 50 przedstawiono średnie wartości modułu widma dla okien sygnału bez zakłóceń oraz zawierających artefakty zaciskania szczęki, przed i po oczyszczaniu z wykorzystaniem filtracji RLS dla elektrody *Oz*.



Rysunek 49. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów: sygnał rzeczywisty i oczyszczony za pomocą filtracji RLS.



Rysunek 50. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów i z artefaktami: sygnał rzeczywisty i oczyszczony za pomocą filtracji RLS.


Średnie wartości modułu widma dla wybranych okien, zaprezentowane na rysunkach 49 i 50, przedstawiają wpływ filtracji RLS na sygnał w dziedzinie częstotliwości. Analiza

parametrów wykazała, że metoda RLS modyfikuje także okna wolne od artefaktów. Wartość uśrednionej mocy dla okien bez artefaktów wynosi $122,88 \mu V^2$, co odróżnia RLS od wcześniej omawianych metod, ponieważ jako pierwsza prowadzi do wzrostu mocy w porównaniu do sygnału przed oczyszczaniem. Choć zmiany nie są znaczące, wskazują na to, że metoda RLS wprowadza pewne modyfikacje do sygnału pozbawionego zakłóceń. W przypadku okien bez artefaktów, współczynnik SNR_{SSVEP} uległ niewielkiemu osłabieniu, ale nie został całkowicie zredukowany (wartość 2,03). Z kolei dla okien z artefaktami, SNR_{SSVEP} wzrósł do wartości 1,61, co sugeruje, że filtracja przyczyniła się do lepszego uwidocznienia komponentu SSVEP względem tła. Wartość ta jest wyższa niż przed oczyszczaniem i porównywalna do wartości uzyskanej z wykorzystaniem filtracji LMS, lecz niższa niż w przypadku CNN-LSTM oraz regresji liniowej. Okna z artefaktami po filtracji różnią się pod względem wyznaczonych parametrów od okien wolnych od artefaktów, jednakże można zaobserwować osłabienie zakłóceń (uśredniona moc wynosi $230,52 \mu V^2$). Widma oczyszczonych okien z artefaktami różnią się znacząco od widm okien bez artefaktów. Choć filtracja skutkuje pewną redukcją artefaktów, nie prowadzi do ich całkowitego usunięcia. Ponadto, metoda RLS modyfikuje również okna wolne od artefaktów, co nie jest pożądane.

5.5.6. Metody transformacji międzykanałowej w oczyszczaniu sygnałów EEG

W celu porównania i poszerzenia wyników zastosowano również dwie proste metody transformacji międzykanałowej do oczyszczania sygnałów EEG: montaż bipolarny oraz filtrację Laplace'a. Analiza skupia się na sygnale z elektrody *Oz*. W przypadku montażu bipolarnego, oczyszczony sygnał uzyskiwano jako różnicę między przebiegiem z elektrody *Oz* a sygnałem z elektrody *O2* (analogicznie *O1* po odjęciu *Oz*). Filtracja Laplace'a polegała na odjęciu od sygnału z elektrody *Oz* średniej arytmetycznej sygnałów z sąsiadujących elektrod (*O1* i *O2*). Oba podejścia nie wymagają użycia kanałów EMG, jednak do ich zastosowania konieczne jest uzyskanie sygnałów z sąsiednich kanałów EEG.


Montaż bipolarny umożliwia uzyskanie oczyszczonego przebiegu jedynie dla wybranych elektrod, ponieważ każda z nich wymaga odpowiednio dobranego sąsiedniego kanału pomocniczego. W analizowanym przypadku, sygnał z elektrody *Oz* został przekształcony poprzez odjęcie przebiegu z elektrody *O2*. Efekt działania metody dla fragmentu sygnału zawierającego artefakt zaciskania szczęki zaprezentowano na rysunku 51.



Rysunek 51. Fragment sygnału z artefaktem zaciskania szczęki przed i po jego oczyszczaniu z wykorzystaniem montażu bipolarnego.

Zastosowanie montażu bipolarnego prowadzi do redukcji niektórych zakłóceń, jednak odbywa się to kosztem wyraźnej modyfikacji sygnału EEG, również w tych fragmentach, które były wolne od artefaktów. Uzyskany przebieg ma zmniejszoną amplitudę i wyraźnie odbiega od oczekiwanego. Choć artefakty ulegają częściowemu osłabieniu, brak kontroli nad zakresem modyfikacji sprawia, że jakość przetworzonego sygnału pozostaje niska. Wyznaczone wartości mocy sygnału pozwalają stwierdzić, że metoda ta prowadzi do znacznego osłabienia całkowitej energii, zarówno w oknach z artefaktami ($46,39 \mu V^2$), jak i bez artefaktów ($47,18 \mu V^2$). Współczynnik SNR_{SSVEP} uległ poprawie w przypadku obu rodzajów okien (odpowiednio 1,79 i 2,32), jednak nie wynika to z poprawnego oczyszczenia sygnału. Mimo zachowania amplitudy prążka widma odpowiadającego częstotliwości SSVEP, zakres modyfikacji w oknach bez artefaktów budzi wątpliwości co do jakości oczyszczonego sygnału. Metoda może zostać wykorzystana do uwydatnienia prążków, ale oczyszczanie sygnałów z jej pomocą może powodować błędne wyniki.

W przeprowadzonej analizie filtracja Laplace'a może być zastosowana jedynie do wybranych kanałów, a w tym przypadku skupiono się na elektrodzie *Oz*. Otrzymany efekt filtracji dla fragmentu sygnału EEG zawierającego artefakt zaciskania szczęki zaprezentowano na rysunku 52.



Rysunek 52. Fragment sygnału z artefaktem zaciskania szczęki przed i po jego oczyszczeniu z wykorzystaniem filtracji Laplace'a.

Analizując oczyszczony fragment sygnału z rysunku 52 możemy zauważyć, że filtracja Laplace'a prowadzi do znacznego spłaszczenia przebiegu oraz zauważalnych zniekształceń w jego strukturze. Obniżenie amplitudy jest widoczne w całym przefiltrowanym sygnale, zarówno we fragmentach zakłóconych, jak i pozbawionych artefaktów, co świadczy o braku selektywności działania filtru. Maksymalne i minimalne wartości amplitud są niskie (odpowiednio 8,98 i $-10,83 \mu\text{V}$ dla okien bez artefaktów, oraz 8,5 i $-9,54 \mu\text{V}$ dla okien z artefaktami). Uśredniona moc sygnału po filtracji spadła do wyjątkowo niskich wartości: $9,62 \mu\text{V}^2$ dla okien bez artefaktów i $8,84 \mu\text{V}^2$ dla okien z artefaktami. Jest to najbardziej radykalna redukcja spośród wszystkich testowanych metod. Amplituda prążka widma odpowiadającego częstotliwości SSVEP uległa wyraźnemu osłabieniu w obu typach okien, jednak tłumienie komponentów tła było jeszcze silniejsze. W efekcie współczynnik SNR_{SSVEP} dla okien z artefaktami nieznacznie wzrósł (1,63), a dla okien bez artefaktów utrzymał się na relatywnie wysokim poziomie (1,94). Mimo to wyznaczone wartości SNR_{SSVEP} są mylące, gdyż nie wynikają z poprawy jakości sygnału, lecz z globalnego spadku amplitudy. Zestawiając otrzymane SNR_{SSVEP} z uśrednioną mocą, ograniczonym zakresem amplitud oraz brakiem selektywności działania, należy uznać, że otrzymany sygnał nie jest użyteczny do dalszej analizy i dyskwalifikuje filtrację Laplace'a jako skuteczne narzędzie do oczyszczania danych EEG. Jej zastosowanie może prowadzić do znacznych zniekształceń i błędnych interpretacji w analizach sygnałów EEG.

5.5.7. Podsumowanie wyników oczyszczania sygnałów EEG za pomocą badanych metod usuwania artefaktów

W celu podsumowania wszystkich przeprowadzonych analiz, zestawiono tabele przedstawiające parametry sygnałów dla okien z artefaktami oraz bez artefaktów, uzyskane dla omawianych metod oczyszczania dla elektrody *Oz*. Wyniki odnoszące się do okien wolnych od artefaktów zostały zaprezentowane w tabeli 18, natomiast parametry dotyczące okien zawierających artefakty przedstawiono w tabeli 19.

Tabela 18. Parametry sygnałów dla okien bez artefaktów.

	Okna bez artefaktów	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
SNR_{SSVEP}	2,06	2,16	2,06	2,20	2,03	2,03	2,32	1,94
Min	-32,95	-32,51	-32,05	-32,02	-32,75	-32,91	-19,31	-10,83
Max	27,89	27,44	27,07	28,07	28,50	29,21	22,39	8,98
Std	10,99	10,76	10,61	10,59	10,96	11,04	6,80	3,05
Moc	121,68	116,65	113,65	113,19	120,89	122,88	46,39	9,62

Tabela 19. Parametry sygnałów dla okien z artefaktami.


	Okna z artefaktami	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
SNR_{SSVEP}	1,27	2,43	1,75	1,53	1,62	1,61	1,79	1,63
Min	-62,89	-32,42	-46,08	-49,25	-48,61	-46,43	-19,49	-9,54
Max	53,14	25,09	41,13	44,75	42,15	41,31	21,62	8,50
Std	19,47	9,79	14,90	16,27	15,57	15,08	6,84	2,92
Moc	387,97	96,76	224,89	270,97	246,16	230,52	47,18	8,84

Parametry zawarte w obu tabelach umożliwiają porównanie wyników dla różnych metod oczyszczania sygnału oraz zaobserwowanie różnic w zakresie analizowanych wartości (minimalna, maksymalna), współczynnika SNR_{SSVEP} oraz uśrednionej mocy sygnału. Na zakończenie prezentacji oczyszczania przykładowego sygnału, w tabeli 20 zostały zestawione parametry wyznaczone dla całego sygnału po oczyszczaniu za pomocą każdej z metod. Dodatkowo dołączone zostały parametry dla sesji pomiarowej z „Krzyżem fiksacji”, co umożliwiło porównanie rejestracji bez artefaktów z całą, oczyszczoną z artefaktów. Dane pozwoliły również na zobrazowanie różnic między każdą z metod nie tylko w oknach z artefaktami i bez, ale dla całego sygnału.

Tabela 20. Parametry wyznaczone dla całego sygnału.

	Krzyż fiksacji	Cały sygnał	CNN- LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
SNR_{SSVEP}	-	1,77	2,33	2,05	1,94	1,97	1,96	2,03	1,75
Min	-46,09	-91,91	-56,99	-61,3	-78,6	-69,64	-71,25	-29,77	-29,78
Max	36,47	92,64	49	51,45	81,38	61,34	66,5	30,62	18,55
Std	9,55	14,66	10,81	12,54	13,18	12,94	12,82	6,84	3,17
Moc	91,29	214,80	116,96	157,24	173,70	167,33	164,31	46,83	10,07

Wnioski dotyczące oczyszczania całego sygnału są spójne z wynikami uzyskanymi dla obu rodzajów okien. Sieć CNN-LSTM znacząco redukuje artefakty, a amplitudy sygnałów oczyszczonych pozostają na poziomie zbliżonym do tych, które uzyskano dla regresji liniowej przy jednocześnie niższej mocy. Parametry wyznaczone dla sieci CNN-LSTM są najbardziej zbliżone do parametrów odniesienia, jakim jest „Krzyż fiksacji”. Amplitudy (maksymalne i minimalne) oraz moc sygnału są nieco wyższe, ale należy pamiętać, że podczas akwizycji „Krzyża fiksacji” badana osoba siedziała nieruchomo, co minimalizowało obecność artefaktów ruchowych, które podczas rejestracji sygnałów z SSVEP i artefaktami były częściowo nieuniknione. Pozostałe metody eliminują artefakty w ograniczonym stopniu, a montaż bipolarny i filtracja Laplace’a dokonują znaczącego osłabienia sygnału. Na rysunku 53 zaprezentowano zestawienie modułów widm dotyczące całego sygnału dla każdej z metod oczyszczania (elektroda Oz).



Rysunek 53. Zestawienie modułu widma całego sygnału dla każdej z metod oczyszczania.

Analiza widm przedstawionych na rysunku 53 pozwala dostrzec różnice między sygnałem nieoczyszczonym (niebieski) a sygnałami oczyszczonymi (pozostałe przebiegi). Analiza


umożliwia również porównanie uzyskanych kształtów widm z widmem „Krzyża fiksacji”, który może służyć jako odniesienie pozbawione artefaktów. Widmo sygnału oczyszczonego z wykorzystaniem sieci CNN-LSTM cechuje się największym podobieństwem do widma odniesienia, zarówno pod względem kształtu, jak i położenia, co potwierdza wcześniejsze obserwacje dotyczące skutecznego usuwania artefaktów. Z kolei widma sygnałów poddanych montażowi bipolarnemu i filtracji Laplace’a różnią się wyraźnie i mają znacznie niższe amplitudy, a ich kształt odbiega od pozostałych analizowanych przebiegów. Wykorzystanie montażu bipolarnego stosunkowo dobrze uwydatnia amplitudę prążka widma odpowiadającego częstotliwości SSVEP, jednak analiza parametrów przedstawionych w tabeli 20 wskazuje, że lepsze wyniki w tym zakresie uzyskano przy użyciu sieci CNN-LSTM oraz regresji. Szczegółowe zestawienie wyników dla każdego z sygnałów (zarówno dla okien z artefaktami, jak i bez nich) byłoby bardzo obszerne, dlatego ograniczono się do prezentacji wybranych parametrów sygnałów. W tabelach 21, 22 i 23 przedstawiono podsumowanie procesu oczyszczania 48 sygnałów w formie wartości średniej i odchylenia standardowego mocy, wartości minimalnych i maksymalnych. Wyznaczone parametry stanowią minimalny, lecz wystarczający zestaw wskaźników umożliwiających ocenę jakości oczyszczania. Parametry obliczone zostały dla sygnałów EEG z elektrody *Oz* w trzech różnych przypadkach: dla okien bez artefaktów (tabela 21), okien z artefaktami (tabela 22) oraz dla całych sygnałów (tabela 23). Łącznie wybrano 798 okien z artefaktami oraz 798 okien bez artefaktów, pochodzących od 48 użytkowników.

Tabela 21. Wybrane parametry dla 798 okien bez artefaktów pochodzących z bazy 48 sygnałów.

	Okna bez artefaktu	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
Moc	83,0 ± 44,9	79,6 ± 42,6	70,5 ± 42,9	76,3 ± 45,4	76,2 ± 45,4	76,0 ± 46,2	22,9 ± 15,3	12,3 ± 10,6
Min	-26,1 ± 8,3	-25,8 ± 7,9	-24,0 ± 7,9	-24,8 ± 8,5	-25,0 ± 8,4	-24,8 ± 8,5	-12,9 ± 4,4	-9,7 ± 4,4
Max	24,1 ± 6,3	23,3 ± 5,9	22,0 ± 6,3	23,0 ± 6,7	22,9 ± 6,4	22,7 ± 6,6	13,1 ± 5,0	9,2 ± 3,6

Parametry przedstawione w tabeli 21, obliczone dla okien pozbawionych artefaktów pozwalają stwierdzić, że wiele z zastosowanych metod oczyszczania umożliwia uzyskanie wyników zbliżonych do tych obserwowanych w sygnale przed oczyszczaniem. Taki rezultat wskazuje, że metody nie ingerują w istotny sposób w niezakłócony sygnał, co jest zjawiskiem pożądanym. Najmniejszy wpływ na sygnał zaobserwowano w przypadku sieci CNN-LSTM, dla której parametry niemal w pełni pokrywają się z wartościami uzyskanymi dla okien bez artefaktów. Metody ICA i filtracji adaptacyjnej również nie wprowadziły istotnych zmian

w sygnałach wolnych od artefaktów, co potwierdza ich poprawne działanie w przypadku niezakłóconych sygnałów. Regresja liniowa w niewielkim stopniu modyfikuje niezakłócone okna powodując częściowe tłumienie sygnału, czego efektem jest obniżenie jego mocy i amplitudy po oczyszczaniu. Wyniki uzyskane przy użyciu montażu bipolarnego i filtracji Laplace'a, podobnie jak w poprzedniej analizie, odbiegały od oczekiwanych. Wykresy pudełkowe przedstawiające rozkład mocy w oknach bez artefaktów, uśrednione dla każdego z sygnałów, zaprezentowano na rysunku 54.




Rysunek 54. Wykresy pudełkowe przedstawiające średnią moc dla każdego z sygnałów dla okien bez artefaktów.

Analiza wykresów pudełkowych przedstawionych na rysunku 54 potwierdza wcześniejsze obserwacje dotyczące wpływu poszczególnych metod oczyszczania na sygnał EEG. Rozkłady mocy dla okien bez artefaktów są zbliżone do tych uzyskanych po oczyszczaniu metodami CNN-LSTM, ICA oraz filtracją adaptacyjną, co świadczy o niewielkim wpływie tych metod na strukturę niezakłóconego sygnału. Znaczące odchylenia względem pozostałych metod zaobserwowano w przypadku montażu bipolarnego oraz filtracji Laplace'a. Zakresy wąsów są najbardziej zbliżone do referencyjnych wartości w przypadku metody RLS. Pozostałe podejścia charakteryzują nieco niższe wartości mocy, jednak centralna część rozkładu nadal pozostaje zbieżna z wynikami dla okien bez artefaktów. Wyjątek stanowi regresja liniowa, która powoduje obniżenie mocy sygnału co skutkuje zauważalnym przesunięciem wykresu pudełkowego w dół względem sygnału niezakłóconego. Parametry dotyczące okien zawierających artefakty zostały zestawione w tabeli 22.

Tabela 22. Wybrane parametry dla 798 okien z artefaktami pochodzących z bazy 48 sygnałów.

	Okna z artefaktem	CNN- LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
Moc	488,6 ± 614,7	86,8 ± 31,8	154,2 ± 95,5	221,0 ± 155,7	190,1 ± 122,9	156,9 ± 98,9	26,5 ± 17,1	14,9 ± 16,6
Min	-65,9 ± 36,7	-26,8 ± 5,2	-36,5 ± 12,8	-45,0 ± 15,7	-41,5 ± 13,3	-37,0 ± 12,3	-14,3 ± 4,8	-10,2 ± 5,2
Max	61,8 ± 37,6	25,2 ± 4,6	34,4 ± 11,5	42,9 ± 16,0	39,3 ± 13,4	35,5 ± 12,1	14,1 ± 5,2	9,9 ± 4,6

W tabeli 22 przedstawiono parametry dotyczące okien zawierających artefakty, zarówno przed ich oczyszczeniem, jak i po zastosowaniu badanych metod oczyszczania. Wszystkie metody prowadzą do redukcji amplitud sygnałów oraz ich mocy, jednak istotne jest, aby uzyskane wartości parametrów były zbliżone do wartości obliczonych dla okien bez artefaktów. Najbardziej zbliżone wyniki uzyskano dla sieci CNN-LSTM. Pozostałe metody w znaczącym stopniu odbiegają od wartości uzyskanych dla okien bez artefaktów. Wykresy pudełkowe, przedstawiające rozkład uśrednionych mocy dla każdego z sygnałów z bazy w przypadku okien zawierających artefakty, zostały zaprezentowane na rysunku 55.



Rysunek 55. Wykresy pudełkowe przedstawiające średnią moc dla każdego z sygnałów dla okien z artefaktami.


Na rysunku 55, jako punkt odniesienia, przedstawiono wykres pudełkowy dla okien bez artefaktów, co umożliwia bezpośrednie porównanie skuteczności poszczególnych metod oczyszczania sygnału. Analiza wykresu potwierdza wcześniej wyciągnięte wnioski: sygnały oczyszczone z użyciem sieci CNN-LSTM charakteryzują się największym podobieństwem statystycznym do sygnałów referencyjnych, czyli okien bez artefaktów. Choć widoczne jest

nieznaczne tłumienie mocy w oknach oczyszczonych względem oryginalnych, to metoda CNN-LSTM nadal uzyskuje najbardziej zbliżone wartości. Metody montażu bipolarnego oraz filtracji Laplace’a charakteryzują się wyraźnie odmiennym rozkładem, co wskazuje na istotne różnice względem sygnału referencyjnego. Metoda uzyskująca najlepsze po CNN-LSTM wyniki to metoda regresji liniowej, jednakże różnica między wynikami jest znacząca na korzyść sieci neuronowej. Co istotne, regresja liniowa nie usuwa w pełni obecnych artefaktów, co znajduje potwierdzenie zarówno w wyznaczonych parametrach, jak i na wykresach pudełkowych. Oczyszczone w ten sposób okna charakteryzuje wyraźnie wyższa moc niż sygnał referencyjny. W przypadku pozostałych metod oczyszczania uzyskiwana jest porównywalna skuteczność, jednak w każdym przypadku część artefaktów nadal pozostaje w sygnale. W tabeli 23 zestawiono uśrednione parametry dotyczące przebiegów całych sygnałów, oczyszczonych przy użyciu poszczególnych metod, wraz z wynikami dla sygnału „Krzyża fiksacji” dla każdego z użytkowników.

Tabela 23. Wybrane parametry sygnałów pochodzących ze zgromadzonej bazy.

	Krzyż fiksacji	Cały sygnał	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
Moc	83,7 ± 94,2	201,0 ± 200,3	83,3 ± 38,8	96,1 ± 57,7	119,3 ± 70,6	108,6 ± 64,5	100,1 ± 61,1	24,1 ± 15,7	13,4 ± 12,4
Min	-43,0 ± 27,1	-109,6 ± 59,0	-43,6 ± 16,0	-56,2 ± 24,3	-71,0 ± 24,6	-69,5 ± 25,8	-57,8 ± 21,0	-22,4 ± 8,7	-16,2 ± 8,5
Max	39,9 ± 30,8	99,6 ± 69,9	38,5 ± 11,3	50,8 ± 21,0	65,5 ± 25,5	61,9 ± 23,5	54,9 ± 22,8	23,0 ± 9,8	15,8 ± 6,9

Analiza parametrów przedstawionych w tabeli 23, obejmujących całe przebiegi sygnałów EEG po zastosowaniu poszczególnych metod oczyszczania pokazuje, że każda z metod wpływa na amplitudę oraz moc sygnału. Obliczone wyniki można porównać z parametrami uzyskanymi dla sygnałów referencyjnych, tj. „Krzyża fiksacji”, które mimo że zostały zarejestrowane kilka minut wcześniej, a nie równocześnie z właściwymi sygnałami, mogą pełnić funkcję wiarygodnego punktu odniesienia pozbawionego artefaktów. Największe podobieństwo całych sygnałów do „Krzyża fiksacji” wystąpiło po oczyszczeniu sygnałów za pomocą sieci CNN-LSTM. Z kolei metody montażu bipolarnego oraz filtracji Laplace’a, zgodnie ze wcześniejszymi obserwacjami, charakteryzują się istotnymi różnicami względem pozostałych metod. Na rysunku 56 zaprezentowano wykresy pudełkowe średnich mocy sygnałów dla każdej z metod oczyszczania, sygnału nieoczyszczonego oraz „Krzyża fiksacji”.



Rysunek 56. Wykresy pudełkowe przedstawiające średnią moc dla każdego z sygnałów.

Wykresy pudełkowe przedstawione na rysunku 56 umożliwiają porównanie wybranych metod z sygnałem odniesienia („Krzyżem fiksacji”), pod względem średnich mocy całych sygnałów. Zgodnie z wcześniejszymi analizami, najbardziej zbliżone wartości uzyskano dla sygnałów oczyszczonych z wykorzystaniem sieci CNN-LSTM. Pozostałe metody charakteryzują się znacznie szerszymi zakresami mocy, a metody montażu bipolarnego oraz filtracji Laplace’a powodują uzyskanie wyraźnie niższych wartości, co wskazuje na nadmierne tłumienie sygnału..

Przeprowadzone analizy pozwalają na wyciągnięcie wniosków dotyczących każdej z zaprezentowanych metod. Metoda CNN-LSTM wydaje się najlepiej oczyszczać sygnały, co potwierdza największe podobieństwo okien po oczyszczaniu do tych pozbawionych artefaktów, zarówno w dziedzinie widmowej, jak i czasowej. Dodatkowo, metoda CNN-LSTM nie powoduje zaniku prążków widma odpowiadających częstotliwości SSVEP ani nie wpływa istotnie na okna, które nie zawierały artefaktów. Uśrednione widma dla okien zawierających artefakty, po oczyszczeniu z użyciem CNN-LSTM, są wyraźnie zbliżone do widm okien referencyjnych. Należy jednak zaznaczyć, że w przypadku analizowanego sygnału zaobserwowano osłabienie prążków widma w zakresie 20-40Hz. Metoda ICA uzyskała najniższy współczynnik SNR_{SSVEP} dla okien z artefaktami. Choć ICA nie ingeruje istotnie w sygnały pozbawione zakłóceń, jej skuteczność w zakresie pełnego usuwania artefaktów okazuje się niewystarczająca. Dodatkowym ograniczeniem metody jest konieczność ręcznego wyboru komponentów przeznaczonych do odrzucenia, co wymaga specjalistycznej wiedzy

z zakresu elektroencefalografii, a tym samym ogranicza jej zastosowanie w systemach automatycznych. Metoda regresji wprowadza zmiany w widmie sygnałów bez artefaktów, szczególnie w przypadku niższych częstotliwości. Ponadto, w oknach z artefaktami dla analizowanego sygnału, regresja zmodyfikowała amplitudę prążków widma odpowiadających częstotliwości SSVEP, zwiększając jej wartość względem poziomu sprzed oczyszczania. Oznacza to, że zamiast eliminować zakłócenia, metoda ta może je wzmacniać, prowadząc do pozornego uwydatnienia amplitud prążków związanych z SSVEP. Regresja pozwala uzyskać wysokie wartości współczynnika SNR_{SSVEP} , jednakże pozostawia fragmenty artefaktów w oczyszczanym sygnale. Filtracja adaptacyjna zarówno w wariancie LMS, jak i RLS prowadzi do bardzo zbliżonych rezultatów. Niemniej jednak, sygnały oczyszczone metodą LMS zawierają więcej pozostałości po artefaktach w porównaniu do filtracji RLS. Pomimo tych różnic, współczynnik SNR_{SSVEP} uzyskany przez obie metody pozostaje na porównywalnym poziomie. Metody transformacji międzykanałowej czyli montaż bipolarny oraz filtracja Laplace'a pozwoliły jedynie na oczyszczanie wybranych elektrod. Niewątpliwą zaletą obu metod jest fakt, że nie wymagają elektrod z rejestrowanymi zakłóceniami i działają wyłącznie na przebiegach EEG. Analiza została ograniczona do elektrody *Oz*, a otrzymane przebiegi znacząco różnią się od pożądaných. Obie metody prowadzą do znacznej redukcji amplitudy sygnałów, jednak montaż bipolarny skuteczniej uwydatnia amplitudę prążka widma odpowiadającego częstotliwości SSVEP. W przypadku zastosowania filtracji Laplace'a, prążek odpowiadający częstotliwości SSVEP w widmie oczyszczonego sygnału jest praktycznie niewidoczny, zanikając na tle innych prążków. Mimo że metody transformacji międzykanałowej nie przynoszą zadowalających rezultatów, montaż bipolarny może znaleźć zastosowanie w sytuacjach, gdzie celem jest jedynie wyeksponowanie amplitudy prążka widma odpowiadającego częstotliwości SSVEP, a pełna analiza kształtu sygnału nie jest wymagana.

5.6. Ocena eliminacji artefaktów na podstawie analizy SSVEP

W celu oceny skuteczności zastosowanych metod oczyszczania sygnałów EEG, jako punkt odniesienia wykorzystano potencjały SSVEP. Przyjęto, że skuteczna metoda eliminacji artefaktów powinna usuwać wyłącznie zakłócenia, zachowując odpowiedź wywołaną stymulacją wzrokową. W analizie posłużono się współczynnikiem SNR_{SSVEP} , który umożliwia ocenę, na ile oczyszczony sygnał zachowuje charakterystyczny komponent związany z odpowiedzią SSVEP.

W przypadku rzeczywistych danych EEG, dla których nie istnieje sygnał odniesienia, zastosowanie współczynnika SNR_{SSVEP} jest szczególnie zasadne, gdyż pozwala ocenić

skuteczność oczyszczania bez konieczności porównywania wyników z sygnałem wzorcowym. Z tego względu wykorzystano go jako główne kryterium analizy w niniejszym podrozdziale.

Wyniki uzyskane na podstawie współczynnika SNR_{SSVEP} zostały uzupełnione o dodatkowe wskaźniki statystyczne, takie jak średnia moc, odchylenie standardowe oraz wartości minimalna i maksymalna, co umożliwiło bardziej precyzyjną ocenę wpływu poszczególnych metod na strukturę sygnału EEG.

5.6.1. Współczynnik SNR_{SSVEP} dla niskich częstotliwości

W analizach uwzględniono częstotliwości 6, 7, 8 i 9 Hz. Liczba poszczególnych rejestracji dla każdej z częstotliwości została zestawiona w tabeli 5.

W pierwszym etapie analiz przedstawiono uśrednione wartości współczynników SNR_{SSVEP} dla niższych częstotliwości stymulacji. Zgodnie z podejściem przyjętym we wcześniejszych analizach, parametry obliczono dla trzech rodzajów sygnałów: okien pozbawionych artefaktów, okien zawierających artefakty oraz dla całego sygnału. W analizie uwzględniono sygnały z elektrody *Oz*, co umożliwiło porównanie skuteczności różnych metod oczyszczania, w tym technik montażu bipolarnego oraz filtracji Laplace'a. Wartości współczynnika SNR_{SSVEP} obliczonego dla uśrednionych widm w oknach bez artefaktów (dla elektrody *Oz*) zestawiono w tabeli 24.

Tabela 24. Zestawienie wartości średnich współczynników SNR_{SSVEP} dla okien bez artefaktów.

SSVEP	Okna bez artefaktu	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
6	2,68	2,68	2,75	2,86	2,87	2,99	1,61	2,06
7	2,61	2,62	2,78	2,71	2,82	2,86	1,56	2,41
8	2,80	2,83	2,89	3,01	2,96	3,06	1,75	2,36
9	3,87	4,06	4,04	4,07	4,05	4,14	1,92	2,98

Dla okien bez artefaktów oczekiwane są minimalne zmiany sygnału, ponieważ tego rodzaju dane nie zawierają istotnych zakłóceń i nie wymagają znaczącej modyfikacji. Na podstawie wartości współczynników SNR_{SSVEP} zamieszczonych w tabeli 24 stwierdzono, że najmniejsze zmiany amplitud prążków widma odpowiadających częstotliwościom SSVEP występują po zastosowaniu metody CNN-LSTM. Dla częstotliwości 9 Hz nieznacznie lepsze wyniki uzyskano przy zastosowaniu metod LMS i LR, jednak różnice są niewielkie. Dla pełnego zestawu danych przeprowadzono test t-Studenta porównujący wartości współczynnika SNR_{SSVEP} przed i po oczyszczaniu sygnału. Najwyższą wartość $p = 0,044$ uzyskano dla metody CNN-LSTM, co oznacza najmniejszą statystycznie istotną różnicę pomiędzy sygnałami przed i po oczyszczaniu ($p > 0,001$). Największe zmiany współczynnika SNR_{SSVEP} , a tym samym

największy wpływ na sygnały niewymagające oczyszczania, zaobserwowano po zastosowaniu filtracji bipolarnej ($p < 0,001$) oraz metody RLS ($p < 0,001$). Z przeprowadzonych badań wynika, że CNN-LSTM w najmniejszym stopniu modyfikuje sygnał w oknach wolnych od zakłóceń, a filtracja bipolarna i RLS wprowadzają w tych fragmentach istotne zmiany. Może to świadczyć o nadmiernej ingerencji tych metod w sygnał, nawet w przypadkach, gdy oczyszczanie nie jest konieczne. Ze względu na dużą liczbę analizowanych przypadków szczegółowe wartości współczynników SNR_{SSVEP} dla 39 sygnałów przedstawiono w tabeli 25. Współczynniki zamieszczone w tabeli 25 zostały uśrednione dla każdej z częstotliwości i zestawione w tabeli 26.

W zestawieniu w tabeli 26 można zaobserwować, że współczynniki SNR_{SSVEP} wyznaczone dla okien z artefaktami (przed oczyszczaniem) są dużo niższe, niż w przypadku okien bez artefaktów (tabela 24). Zestawione wyniki potwierdzają, że artefakty zaciskania szczęki rzeczywiście zakłócają wybrane częstotliwości SSVEP. Wyniki testu t-Studenta dla pełnego zestawu danych wskazują na istotne zróżnicowanie statystyczne między oknami bez artefaktów i tymi zawierającymi zakłócenia ($p < 0,001$). Zdecydowana większość metod oczyszczania zwiększa współczynniki względem okien z artefaktami (tabela 25 i 26), co oznacza że mimo usunięcia artefaktów metody pozostawiają pożądaną informację związaną z SSVEP. Sieć CNN-LSTM uzyskała najwyższe współczynniki SNR_{SSVEP} , jednakże istotne jest to, aby były zbliżone i nie większe niż współczynniki wyznaczone dla okien bez artefaktów w tabeli 24. Tutaj również najbardziej zbliżone wyniki uzyskała sieć neuronowa. Nieznaczące różnice w wyznaczonych współczynnikach SNR_{SSVEP} dla niektórych częstotliwości mogą wynikać z tłumienia w sieci CNN-LSTM lub nieco niższej zawartości SSVEP w sygnałach z artefaktami spowodowanej zwiększoną koncentracją osób na wykonaniu artefaktu niż obserwacji panelu z pulsującymi diodami. Dla wszystkich sygnałów największą wartość p w teście t-Studenta między oknami oczyszczonymi z artefaktów a oknami pozbawionymi artefaktów uzyskano dla modelu CNN-LSTM ($p = 0,203$), a następnie dla regresji liniowej ($p = 0,001$). Sygnały oczyszczone za pomocą modelu regresji i CNN-LSTM charakteryzują się najmniejszym statystycznie zróżnicowaniem względem okien bez artefaktów, co potwierdza ich zgodność z tymi niezakłóconymi przebiegami. Najgorzej w zadaniu uwidaczniania amplitudy prążka widma odpowiadającego częstotliwości SSVEP radzi sobie montaż bipolarny. Nieco lepsze wyniki otrzymano dla metod ICA oraz LMS, ale również nie są to satysfakcjonujące rezultaty. Filtracja Laplace’a (szczególnie dla 8Hz) oraz RLS pozwalają na uzyskanie wyników zbliżonych do regresji liniowej, która cechuje się drugim z kolei najlepszym uwydatnieniem amplitud prążków widma odpowiadających częstotliwości SSVEP (tuż po sieci CNN-LSTM).


Tabela 25. Zestawienie współczynników SNR_{SSVEP} dla okien z artefaktami.

SSVEP	Okna z artefaktem	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
7	1,13	2,21	2,03	1,57	1,68	1,89	0,88	1,18
7	0,61	1,07	0,69	0,90	0,70	0,80	0,94	1,01
6	1,70	2,23	2,35	2,06	2,18	2,27	1,29	3,57
7	1,55	2,23	1,79	1,66	2,08	2,23	1,60	2,70
8	1,12	1,54	1,40	1,13	1,33	1,48	1,22	2,09
8	0,78	1,58	1,20	1,12	1,01	1,25	0,77	1,09
7	1,06	2,02	1,73	1,40	1,46	1,70	0,62	1,20
8	0,71	1,27	1,19	1,04	1,02	1,22	0,91	1,34
6	1,37	2,24	1,94	1,72	1,68	1,71	1,05	0,97
6	1,05	1,98	1,59	1,53	1,50	1,83	1,49	1,42
6	1,24	1,96	1,78	1,61	1,67	1,85	1,27	1,22
6	2,22	3,03	2,99	2,59	2,73	2,88	1,59	1,44
7	1,38	2,46	2,14	1,79	1,95	2,20	1,32	0,94
8	0,91	1,39	1,22	1,10	1,13	1,19	0,81	0,65
6	0,80	2,26	1,17	0,98	0,92	1,17	2,17	1,50
7	0,89	2,27	2,25	1,25	1,63	1,90	1,47	1,32
8	0,78	2,28	2,02	1,81	1,44	1,83	1,45	1,07
7	1,43	2,51	2,07	1,50	1,64	1,85	1,07	1,80
8	2,52	4,06	4,09	3,73	3,07	3,89	2,25	2,66
7	1,33	2,24	2,19	1,33	1,97	2,25	3,82	4,80
8	1,96	3,06	3,02	2,38	2,58	3,06	3,95	5,92
7	3,60	4,16	3,94	3,69	3,65	3,90	1,37	2,30
8	2,75	3,08	3,36	2,79	2,98	3,35	1,53	1,79
9	4,64	4,69	4,52	4,64	4,63	4,64	1,59	2,26
7	3,10	4,61	4,52	3,89	3,55	4,20	1,52	4,26
8	3,42	5,18	5,50	4,23	4,06	4,70	1,71	4,88
9	2,73	4,85	4,72	4,28	3,76	4,57	1,99	3,45
7	1,60	2,19	1,72	1,71	1,74	1,70	1,87	1,47
8	1,31	2,06	1,60	1,32	1,64	1,63	2,17	1,77
9	1,27	2,43	1,75	1,53	1,62	1,61	1,79	1,63
7	3,97	4,63	4,85	3,99	4,12	4,62	1,73	4,46
8	3,66	4,32	4,26	3,97	3,83	4,09	1,83	5,22
9	4,16	5,30	5,39	4,57	4,72	5,21	1,99	6,07
7	1,48	2,06	1,68	1,65	1,67	1,75	2,17	1,58
8	1,35	2,08	1,50	1,51	1,63	1,66	1,75	1,42
9	2,31	2,84	2,58	2,39	2,58	2,69	2,14	1,62
7	0,83	2,06	1,15	1,06	1,24	1,33	0,86	2,15
8	0,79	2,37	1,51	1,03	1,50	1,66	0,96	1,88
9	0,77	2,31	1,52	1,23	1,55	1,58	1,07	2,16

Tabela 26. Zestawienie wartości średnich współczynników SNR_{SSVEP} dla okien z artefaktami.

SSVEP	Okna z artefaktami	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
6	1,40	2,29	1,97	1,75	1,78	1,95	1,48	1,69
7	1,71	2,62	2,34	1,96	2,08	2,31	1,52	2,23
8	1,70	2,64	2,45	2,09	2,09	2,38	1,64	2,44
9	2,65	3,74	3,41	3,11	3,14	3,38	1,76	2,87

Uśrednione wartości współczynników SNR_{SSVEP} wraz z odchyleniami standardowymi dla okien z artefaktami i bez artefaktów oraz dla każdej z metod ich oczyszczania zestawiono w formie wykresów słupkowych na rysunku 57.



Rysunek 57. Wartości współczynnika SNR_{SSVEP} dla okien z artefaktami i bez artefaktów oraz dla metod ich oczyszczania.

Interpretacja współczynników zaprezentowanych na rysunku 57 pokrywa się z obserwacjami uzyskanymi na wcześniejszych etapach analizy. Sieć CNN-LSTM uzyskuje współczynniki najbardziej zbliżone do tych, które dotyczą okien bez artefaktów. Sieć neuronowa pozostawia okna niewymagające oczyszczania bez zmian, natomiast w oknach z artefaktami skutecznie je usuwa, dzięki czemu współczynniki pozostają zbliżone do wartości obserwowanych dla okien wolnych od zakłóceń. Metoda regresji liniowej w niewielkim stopniu ingeruje w okna bez artefaktów, jednocześnie wyraźnie poprawiając wartość współczynnika SNR_{SSVEP} dla okien z artefaktami. Montaż bipolarny charakteryzował się najniższą efektywnością w zakresie poprawy współczynnika SNR_{SSVEP} dla obu typów okien. W tabeli 27 przedstawiono natomiast zestawienie uśrednionych współczynników SNR_{SSVEP} dla całych sygnałów.

Tabela 27. Zestawienie współczynników SNR_{SSVEP} dla całych sygnałów.


SSVEP	Całe sygnały	CNN- LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
6	2,22	2,64	2,54	2,52	2,55	2,67	1,51	1,91
7	2,17	2,58	2,61	2,38	2,52	2,66	1,58	2,31
8	2,26	2,73	2,70	2,58	2,59	2,74	1,66	2,40
9	3,25	3,94	3,72	3,60	3,64	3,83	1,73	2,95

W tabeli 27 zaprezentowano porównanie współczynników SNR_{SSVEP} dla każdej z wybranych metod, które różnią się od wcześniej prezentowanych tabel dla okien z artefaktami i bez. Najwyższe współczynniki wyznaczono dla metod RLS, CNN-LSTM oraz LR. Dla pozostałych metod uzyskano niższe wartości, a montaż bipolarny i filtracja Laplace’a odstają od nich znacząco. Porównując współczynniki SNR_{SSVEP} z wyznaczonymi dla okien bez artefaktów, najbardziej zbliżone wartości wyznaczono dla metody RLS oraz CNN-LSTM. Obie metody w widoczny sposób uwydatniają amplitudy prążka widma odpowiadającego częstotliwości SSVEP, ale zgodnie ze wcześniejszymi spostrzeżeniami to metoda CNN-LSTM zapewnia również skuteczne usuwanie artefaktów (nie stwierdzono istotnych statystycznie różnic między oknami bez artefaktów, a oknami z artefaktami oczyszczonymi z wykorzystaniem sieci CNN-LSTM $p = 0,203$).

5.6.2. Eliminacja artefaktów dla wyższych częstotliwości


Do wyższych częstotliwości pobudzeń rejestrowanych podczas tworzenia bazy danych zaliczana jest stymulacja o częstotliwości 25Hz. Pomimo zastosowania wyższej częstotliwości podczas akwizycji, wyraźna odpowiedź SSVEP została zaobserwowana jedynie w kilku przypadkach. W pozostałych, mimo analizy okien wolnych od artefaktów, nie odnotowano obecności charakterystycznych prążków w widmie. Może to wskazywać na ograniczoną skuteczność częstotliwości 25Hz w generowaniu odpowiedzi wzrokowej SSVEP u większości badanych osób. Pomimo trudności w detekcji SSVEP, sygnały zebrane przy tej częstotliwości stymulacji okazały się przydatne w analizach zaprezentowanych we wcześniejszych podrozdziałach, dotyczących usuwania artefaktów. Wynika to z faktu, że sygnały zawierały poprawnie zarejestrowane artefakty mięśniowe związane z zaciskaniem szczęki. Dane wykorzystano do obliczenia parametrów takich jak uśredniona moc sygnału, wartości minimalne i maksymalne, co umożliwiło ocenę skuteczności metod oczyszczania sygnału EEG. W niniejszym podrozdziale przedstawiono szczegółową analizę przykładowej sesji pomiarowej trwającej 30 sekund, zarejestrowanej na elektrodzie *O1* u jednego z uczestników, u którego odpowiedź SSVEP na częstotliwość 25Hz była zauważalna. Ze względu na położenie elektrody,

nie było możliwości zastosowania filtracji Laplace’a, dlatego ograniczono się do montażu bipolarnego. Zgodnie z podejściem stosowanym w poprzednich analizach, dokonano ręcznego podziału sygnału na okna bez artefaktów, okna z artefaktami oraz przeanalizowano cały sygnał. W dalszej części rozdziału zaprezentowano i skomentowano wyniki uzyskane dla każdego z typów okien oraz całego sygnału. Średnią wartość modułu widma dla obu rodzajów okien przedstawiono na rysunku 58.



Rysunek 58. Średnia wartość modułu widma dla poszczególnych okien sygnału z artefaktami zaciskania szczęki i bez artefaktów wybrane z sesji pomiarowej SSVEP 25Hz.

Analiza widm przedstawionych na rysunku 58 wskazuje, że amplituda prążka odpowiadającego częstotliwości SSVEP 25Hz jest wyraźnie większa niż poziom tła w oknach pozbawionych artefaktów. W przypadku okien z artefaktami, amplituda tego prążka jest zakłócona i nie jest wyraźnie widoczna na tle całego sygnału. Na rysunku 59 przedstawione zostały średnie wartości modułu widma dla okien bez artefaktów wybranych z sygnałów po oczyszczaniu. Ze względu na ograniczoną czytelność przy jednoczesnym przedstawieniu wyników wszystkich metod, na rysunku uwzględniono jedynie okna oczyszczone za pomocą sieci CNN-LSTM.



Rysunek 59. Średnia wartość modułu widma dla poszczególnych okien sygnału bez artefaktów: sygnał rzeczywisty i oczyszczony za pomocą sieci CNN-LSTM.


W tabeli 28 przedstawiono uśrednione wyniki dotyczące każdej z analizowanych metod dla okien bez artefaktów wyselekcjonowanych z sygnału podlegającego oczyszczaniu.

Tabela 28. Parametry wyznaczone dla oczyszczonych okien bez artefaktów.

	Okna bez artefaktów	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny
SNR_{SSVEP}	2,54	2,55	2,99	2,82	2,76	3,01	2,23
Min	-32,38	-32,15	-29,74	-26,40	-31,48	-30,05	-25,17
Max	31,28	30,78	28,87	28,39	29,61	28,37	28,31
Std	11,28	11,24	10,56	10,04	11,11	10,80	9,64
Moc	127,74	126,78	112,26	101,26	124,11	117,28	93,22

Analizując parametry sygnałów zawarte w tabeli 28, jak również widma przedstawione na rysunku 59 możemy zauważyć różnice między metodami. Montaż bipolarny zastosowany między elektrodami $O1$ i Oz tłumi amplitudę prążka widma odpowiadającego częstotliwości SSVEP, a ponadto zmienia kształt widma okien bez artefaktów, co czyni go nieużytecznym. Pozostałe metody również wpływają na okna bez artefaktów. Najmniejszym wpływem wyróżnia się model CNN-LSTM, który w zdecydowanej większości zachowuje zbliżone parametry do okien bez artefaktów przed oczyszczaniem. Takie działanie jest bardzo pożądane. W przypadku pozostałych metod obserwuje się spadek amplitudy i mocy sygnału, przy jednoczesnym uwypukleniu prążka widma odpowiadającego częstotliwości SSVEP względem tła. Dokładna analiza widma wskazuje na istotny wzrost amplitudy prążka odpowiadającego częstotliwości SSVEP ponad jego pierwotną wartość w przypadku metod LMS, LR i RLS. Takie podejście nie jest akceptowalne, gdyż jest to modyfikacja sygnału który nie zawiera

artefaktów. Na rysunku 60 przedstawiono średnie wartości modułu widma dla okien z artefaktami (pominięty został montaż bipolarny ze względu na znaczącą modyfikację okien bez artefaktów). W tabeli 29 zaprezentowano zestawienie parametrów wyznaczone dla oczyszczonych okien z artefaktami.




Rysunek 60. Średnia wartość modułu widma dla poszczególnych okien sygnału z artefaktami: sygnał rzeczywisty i oczyszczony za pomocą wybranych metod.

Tabela 29. Parametry wyznaczone dla oczyszczonych okien z artefaktami.

	Okna z artefaktami	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny
SNR_{SSVEP}	1,23	1,92	1,88	1,75	1,80	2,12	1,53
Min	-86,74	-31,63	-49,89	-46,54	-50,42	-43,54	-29,15
Max	85,11	28,72	42,39	46,09	49,90	42,60	28,44
Std	26,54	10,43	14,35	14,87	16,79	14,86	10,35
Moc	763,92	109,64	209,21	227,74	291,08	224,79	107,70

Na podstawie parametrów zawartych w tabeli 29 oraz rysunku 60 można stwierdzić, że występują zauważalne różnice zarówno w amplitudach prążków widma odpowiadających częstotliwościom SSVEP, jak i w wartościach mocy sygnałów. Parametry oczyszczonych okien z artefaktami najbardziej zbliżone do pożądaných (okien bez artefaktów z tabeli 28) dotyczą modelu CNN-LSTM. Obserwując widma możemy jednak zauważyć, że amplituda prążka odpowiadającego częstotliwości SSVEP w przypadku CNN-LSTM jest bardziej tłumiona niż w przypadku innych metod. Mimo tego, dzięki usunięciu artefaktów z sygnału, zauważalny jest wzrost współczynnika SNR_{SSVEP} powyżej wartości uzyskanych dla pozostałych metod. Widmo i parametry wyznaczone dla całego sygnału przedstawiono na rysunku 61 i w tabeli 30.




Rysunek 61. Moduł widma całego sygnału: sygnał rzeczywisty i oczyszczony za pomocą wybranych metod.

Tabela 30. Parametry wyznaczone dla całego sygnału.


	Cały sygnał	CNN-LSTM	LR	ICA	LMS	RLS	Montaż bipolarny
SNR_{SSVEP}	1,83	2,26	2,34	2,20	2,23	2,46	1,86
Średnia	0,02	-0,02	0,02	0,02	0,02	0,01	0,00
Min	-120,21	-44,04	-74,12	-81,72	-69,47	-64,38	-39,25
Max	144,16	43,04	55,68	61,02	68,77	55,43	37,92
Std	19,03	11,04	12,21	12,17	13,59	12,57	9,93
Moc	362,22	121,84	149,16	148,04	184,69	157,89	98,58

Analiza parametrów wyznaczonych dla całego sygnału, przedstawionych w tabeli 30 oraz na rysunku 61, ukazuje różnice pomiędzy zastosowanymi metodami filtracji w odniesieniu do pełnego przebiegu sygnału EEG. Montaż bipolarny, poza modyfikacją przebiegów (również we fragmentach pozbawionych artefaktów), jedynie nieznacznie zwiększył współczynnik SNR_{SSVEP} , jednocześnie silnie tłumiąc cały sygnał, co przełożyło się na najniższą wartość mocy w zestawieniu. Metody regresji liniowej oraz RLS umożliwiły wyraźniejsze uwidocznienie amplitudy prążka widma odpowiadającego częstotliwości SSVEP, jednak nie były wystarczająco skuteczne w redukcji artefaktów (moc, wartość minimalna i maksymalna), szczególnie w porównaniu z metodą opartą na sieci CNN-LSTM. Podsumowując, wszystkie analizowane metody (z wyjątkiem montażu bipolarnego), charakteryzują się one zdolnością do redukcji zakłóceń, jednak ich skuteczność jest wyraźnie zróżnicowana w zależności od zastosowanego podejścia. Najlepsze rezultaty w zakresie usuwania artefaktów uzyskano przy użyciu sieci CNN-LSTM oraz regresji liniowej. Należy jednak zauważyć, że stosowanie


regresji powoduje również zmiany w przebiegach pozbawionych zakłóceń, co jest zjawiskiem niepożądanym. Najwyższy współczynnik SNR_{SSVEP} uzyskany został dla metody RLS, jednak podobnie jak regresja, RLS nie zapewnia pełnej eliminacji artefaktów i wprowadza zmiany w oknach bez artefaktów. Metoda ICA również nie usuwa artefaktów w pełni, a dodatkowo wymaga specjalistycznej wiedzy w celu poprawnej identyfikacji i odrzucenia komponentów związanych z zakłóceniami. Na zakończenie, w celu ilustracji efektywności oczyszczania sygnału, zaprezentowano spektrogramy dla jednej z elektrod, uzyskane przy użyciu metody CNN-LSTM, wybranej jako najskuteczniejsza. Na rysunku 62 przedstawiono spektrogram sygnału przed oczyszczaniem, na rysunku 63 po oczyszczeniu, natomiast na rysunku 64 zaprezentowano różnicę między sygnałem oczyszczanym a oczyszczonym, odpowiadającą zakłóceniom skutecznie usuniętym przez model.



Rysunek 62. Spektrogram przedstawiający sygnał przed usuwaniem artefaktów zaciskania szczęki.



Rysunek 63. Spektrogram przedstawiający sygnał po eliminacji artefaktów zaciskania szczęki z wykorzystaniem sieci CNN-LSTM.



Rysunek 64. Spektrogram przedstawiający różnicę sygnałów przed usuwaniem artefaktów oraz oczyszczonego za pomocą CNN-LSTM.

Artefakty zaciskania szczęki są widoczne w 4, 10, 16, 22 i 27 sekundzie sygnału przedstawionego na rysunku 62. Spektrogram sygnału uwidacznia również częstotliwość stymulacji 25Hz. Po oczyszczeniu sygnału z artefaktów za pomocą sieci CNN-LSTM (rysunek 63), zachowana zostaje analizowana częstotliwość SSVEP 25Hz, a zakłócenia ulegają skutecznemu usunięciu.

Na rysunku 64 zaprezentowano spektrogram komponentu usuniętego przez sieć CNN-LSTM. Widoczny brak charakterystycznych składowych w paśmie SSVEP 25Hz potwierdza, że metoda nie ingeruje istotnie w niesione informacje, ograniczając się jedynie do eliminacji artefaktów. Szczegółowe wartości współczynników SNR_{SSVEP} dla wszystkich elektrod i sygnałów EEG zostały zaprezentowane w Załączniku 8.3. Uwzględniono okna z artefaktami, bez artefaktów oraz całe sygnały EEG.

5.7. Porównanie metod oczyszczania sygnałów z wykorzystaniem klasyfikacji SSVEP

W podrozdziale przedstawiono praktyczne zastosowanie SSVEP w kontekście klasyfikacji. Wykorzystano trafność klasyfikacji jako miarę oceny skuteczności metod usuwania artefaktów, sprawdzając, czy zastosowane metody prowadzą do poprawy wyników klasyfikacji. Do analiz wykorzystano dodatkowe sygnały EEG/EMG zarejestrowane dla czterech użytkowników. Rejestracje obejmowały stymulację różnymi częstotliwościami z zakresu 6-9Hz z jednoczesnym wykonywaniem artefaktów zaciskania szczęki. Czterej uczestnicy charakteryzowali się zróżnicowanym stosunkiem amplitudy prążka widma na częstotliwości SSVEP do szumu tła (SNR_{SSVEP}), co przekładało się na różną wyrazistość odpowiedzi SSVEP. Ponadto każdy z nich inaczej reagował podczas badania. U niektórych uczestników obserwowano skupienie, u innych rozproszenie uwagi. Jakość sygnałów była wysoka, a obecne artefakty dobrze widoczne, co umożliwiło rzetelną i wszechstronną ocenę skuteczności metod usuwania zakłóceń w zadaniu klasyfikacji. W pierwszym etapie przeprowadzono oczyszczanie sygnałów EEG za pomocą każdej z analizowanych metod usuwania artefaktów i ręcznie wybrano jednosekundowe okna (256 próbek), zarówno zawierające artefakty, jak i ich pozbawione. Po usunięciu artefaktów wyselekcjonowano rejestracje przeznaczone do treningu klasyfikatora oraz inne, do jego testowania. Wszystkie dane treningowe i testowe pochodziły od tego samego użytkownika. Klasyfikację przeprowadzono osobno dla okien z artefaktami i bez artefaktów, wykorzystując wartość SNR_{SSVEP} jako cechę wejściową do klasyfikatora. Analiza została ograniczona do elektrody *Oz*, ponieważ tylko dla niej możliwe było zastosowanie wszystkich omawianych metod eliminacji artefaktów, w tym transformacji międzykanałowych, takich jak montaż bipolarny i filtracja Laplace'a. Wybór innej elektrody uniemożliwiłby zastosowanie wszystkich metod, co utrudniłoby rzetelne porównanie skuteczności oczyszczania. Opis przeprowadzonych eksperymentów oraz liczba poszczególnych okien sygnałów zamieszczone zostały w tabeli 31.

Tabela 31. Liczba okien w każdym z przeprowadzonych eksperymentów klasyfikacji SSVEP.

		Liczba okien			
		Bez artefaktów		Z artefaktami	
Osoba 1	SSVEP	6Hz	7Hz	6Hz	7Hz
	Trening	70	59	42	52
	Test	24	23	12	14
Osoba 2	SSVEP	7Hz	8Hz	7Hz	8Hz
	Trening	59	42	52	36
	Test	23	21	14	15
Osoba 3	SSVEP	7Hz	8Hz	7Hz	8Hz
	Trening	57	70	42	44
	Test	23	17	16	14
Osoba 4	SSVEP	8Hz	9Hz	8Hz	9Hz
	Trening	44	36	30	31
	Test	16	14	14	14

W tabeli 31 przedstawiono wielkość każdego ze zbiorów treningowych i testowych dla czterech ochotników. W przypadku osoby 1 klasyfikacja dotyczyła rozróżnienia między częstotliwościami 6 i 7Hz, dla osób 2 i 3 między 7 a 8Hz, natomiast dla osoby 4 między 8 a 9Hz. Podczas selekcji danych do zbiorów dołożono starań, aby klasy były możliwie zrównoważone i nie występowały istotne dysproporcje międzyklasowe. Do realizacji zadania klasyfikacji wybrano klasyfikator SVM z funkcją jądra Gaussa, który dobrze sprawdza się w przypadku danych nieseparowalnych linowo. Najbardziej istotne parametry klasyfikatora przedstawiono w tabeli 32.

Tabela 32. Parametry wybranego klasyfikatora SVM.

Parametr	Wartość	Opis
Funkcja jądra	rbf	Funkcja jądra wybrana została jako funkcja Gaussa.
Współczynnik C	1.0	Siła regularyzacji.
Współczynnik gamma	scale	Parametr jądra rbf ustalany automatycznie na podstawie liczby próbek i wariancji
Maksymalna liczba iteracji	-1	Brak limitu iteracji

Dla każdego eksperymentu związanego z klasyfikacją wykorzystywany był inny klasyfikator SVM o parametrach zawartych w tabeli 32. Tabela 33 zawiera wyniki trafności klasyfikacji dla kolejnych osób dla okien bez artefaktów.

Tabela 33. Wyniki trafności klasyfikacji dla okien bez artefaktów.

	Przed oczyszczaniem	CNN- LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
<i>Osoba 1</i> <i>6 vs 7Hz</i>	0,7	0,74	0,77	0,7	0,72	0,72	0,49	0,62
<i>Osoba 2</i> <i>7 vs 8Hz</i>	0,59	0,64	0,70	0,64	0,61	0,61	0,59	0,55
<i>Osoba 3</i> <i>7 vs 8Hz</i>	0,95	0,95	0,97	0,95	0,95	1	0,55	0,95
<i>Osoba 4</i> <i>8 vs 9Hz</i>	0,97	0,93	0,97	0,97	1	1	0,53	0,47

Na podstawie wyników klasyfikacji dla okien bez artefaktów (tabela 33) można stwierdzić, że dla większości metod uzyskano trafność zbliżoną do poziomu sprzed oczyszczania sygnału, co sugeruje, że nie wpływają negatywnie na częstotliwości charakterystyczne dla SSVEP. Wyjątek stanowią montaż bipolarny oraz filtracja Laplace’a, które istotnie obniżają trafność klasyfikacji w porównaniu do nieoczyszczonych sygnałów bez artefaktów. Niewielki spadek trafności zaobserwowano również w przypadku sieci CNN-LSTM dla osoby 4. Dobre rezultaty uzyskano natomiast dla filtracji adaptacyjnych oraz ICA. Warto zauważyć, że trafność klasyfikacji dla sygnałów przed oczyszczaniem była zróżnicowana pomiędzy użytkownikami. Osoby 3 i 4 osiągnęły wyraźnie lepsze wyniki niż osoby 1 i 2. Może to świadczyć o silniejszych odpowiedziach SSVEP generowanych przez tych uczestników, co ułatwiało klasyfikację. Trafność klasyfikacji dla okien zawierających artefakty została zestawiona w tabeli 34.

Tabela 34. Wyniki trafności klasyfikacji dla okien zawierających artefakty.

	Przed oczyszczaniem	CNN- LSTM	LR	ICA	LMS	RLS	Montaż bipolarny	Laplace
<i>Osoba 1</i>	0,5	0,69	0,69	0,58	0,58	0,77	0,58	0,58
<i>Osoba 2</i>	0,48	0,69	0,72	0,52	0,55	0,66	0,59	0,59
<i>Osoba 3</i>	1	1	1	1	1	1	0,43	0,93
<i>Osoba 4</i>	0,89	0,96	0,96	0,93	0,93	0,93	0,57	0,5

W przypadku okien z artefaktami (tabela 34) można zaobserwować różnice między poszczególnymi metodami. Trafność klasyfikacji dla okien z artefaktami przed oczyszczaniem jest niższa niż w przypadku okien bez artefaktów, które przedstawiono w tabeli 33. Wyjątek stanowi osoba 3, dla której uzyskano wyjątkowo wysokie wyniki, nawet w przypadku obecności artefaktów, co wynika z silnych odpowiedzi SSVEP rejestrowanych w jej sygnałach. Opisywany przypadek może posłużyć jako przykład oceny działania metod w przypadku bardzo wysokich wartości współczynnika SNR_{SSVEP} , nawet przed oczyszczaniem sygnału. Montaż bipolarny oraz filtracja Laplace’a znacząco pogorszyły trafność klasyfikacji SSVEP, nawet u osoby 3. Pozostałe metody w różnym stopniu poprawiają trafność klasyfikacji, co

oznacza, że różnią się zdolnością do zachowania i uwydatniania amplitudy prążka widma odpowiadającego częstotliwości SSVEP. Najwyższe wyniki trafności klasyfikacji uzyskano dla metod regresji liniowej, CNN-LSTM oraz RLS. Podsumowując efekty klasyfikacji w odniesieniu do wcześniejszych obserwacji, metoda CNN-LSTM cechuje się wysoką trafnością zarówno w uwydatnianiu amplitudy prążka widma odpowiadającego częstotliwości SSVEP (wysokie wyniki klasyfikacji, dobrze zachowana informacja SSVEP), jak i w usuwaniu artefaktów, przy minimalnej modyfikacji sygnału pozbawionego artefaktów. Metody RLS i LR także pozwalają na zachowanie amplitudy prążka widma odpowiadającego częstotliwości SSVEP, jednak nie zapewniają pełnej redukcji artefaktów. Większość metod nie modyfikuje okien pozbawionych zakłóceń, co świadczy o zachowaniu integralności i jakości sygnału. Wyjątkami są montaż bipolarny oraz filtracja Laplace'a, które wprowadzają zauważalne zmiany w oknach.

5.8. Ocena skuteczności metod oczyszczania w obecności różnorodnych artefaktów

Podczas akwizycji materiału badawczego, której celem była rejestracja odpowiedzi typu SSVEP, u trzech uczestników nie stwierdzono obecności charakterystycznych składowych widmowych, które jednoznacznie wskazywałyby na występowanie tego rodzaju odpowiedzi. Ze względu na brak oczekiwanej odpowiedzi SSVEP, zdecydowano o przeprowadzeniu dodatkowej rejestracji, mającej na celu pozyskanie sygnałów zawierających różne typy zakłóceń.


W trakcie tej rejestracji uczestnicy wykonywali szereg czynności prowadzących do generowania artefaktów, takich jak zaciskanie szczęki, grymasy twarzy, ruchy gałek ocznych, mruganie, przełykanie śliny oraz inne spontaniczne działania mogące zakłócać sygnał EEG. Celem było pozyskanie danych umożliwiających ocenę skuteczności wybranych metod oczyszczania sygnałów EEG w warunkach występowania różnych typów zakłóceń. W szczególności analizowano działanie modelu CNN-LSTM, trenowanego wyłącznie na danych syntetycznych zawierających artefakt zaciskania szczęki.

Ograniczenie treningu do jednego rodzaju artefaktu wynikało z wysokiego nakładu pracy niezbędnego do przygotowania danych syntetycznych. Proces ten obejmował selekcję fragmentów sygnału na podstawie inspekcji wizualnej, identyfikację obecności artefaktów w domenie czasu i częstotliwości, analizę statystyczną oraz analizę widmową.

Przygotowanie danych syntetycznych było procesem czasochłonnym, wymagającym wysokiej precyzji oraz wielu iteracyjnych testów w celu uzyskania wiarygodnie


odwzorowanych zakłóceń. Realistyczne odwzorowanie każdego nowego typu artefaktu w danych syntetycznych wymagałoby wcześniejszego pozyskania sygnałów EEG od wielu uczestników, co jest niezbędne do analizy właściwości zakłóceń i określenia ich charakterystycznych cech. Z tego względu, w ramach pracy doktorskiej zdecydowano o przeprowadzeniu treningu modelu na jednym rodzaju zakłócenia. Wybrano artefakt zaciskania szczęki, który na podstawie wcześniejszych obserwacji został uznany za reprezentatywny przykład artefaktów mięśniowych.

W celach ilustracyjnych przedstawiono wybraną rejestrację (rysunek 65), przy czym efekty oczyszczania są analogiczne również dla pozostałych przypadków



Rysunek 65. Rejestracja dodatkowa: przebieg sygnału zawierający różnorodne artefakty.

Na rysunku 65 przedstawiono rejestrację podczas której uczestnik badania wykonywał różne artefakty. Możemy zaobserwować przebiegi dla każdej z elektrod. Niektóre z artefaktów pomimo znaczących amplitud na elektrodach EMG (15-30 sekunda rejestracji) nie były propagowane na elektrody EEG. Artefakty widoczne w przebiegu czasowym różnią się od dotychczas analizowanych artefaktów zaciskania szczęki, na przykład 42-43 sekunda dotyczy artefaktu związanego z napinaniem karku. Jego źródłem jest elektroda *Kark*, a sam artefakt oddziałuje na elektrody EEG inaczej niż inne artefakty. Podczas prezentacji, tak jak w przypadku poprzednich analiz skupiono się na elektrodzie *Oz* oraz na metodach dających akceptowalne rezultaty: CNN-LSTM, LR, ICA oraz filtracji adaptacyjnej. Z powodu znaczących modyfikacji sygnału zrezygnowano z analiz dotyczących montażu bipolarnego i filtracji Laplace'a. Na rysunku 66 przedstawiono efekt oczyszczania sygnałów z elektrody *Oz* z wykorzystaniem wybranych metod eliminacji artefaktów.



Rysunek 66. Efekt oczyszczania sygnałów z elektrody Oz zawierających różnorodne artefakty.

Na rysunku 66, czerwoną ramką zostały zaznaczone efekty oczyszczania sygnałów z elektrody *Oz*. Poniżej ramki znajduje się rzeczywisty sygnał z elektrody *Oz* przed oczyszczaniem oraz przebiegi z elektrod EMG. Można zaobserwować, że wszystkie metody poza CNN-LSTM zachowały artefakty występujące podczas pierwszych dziesięciu sekund rejestracji. Sieć CNN-LSTM dokonała ich eliminacji gdyż były podobne do artefaktów zaciskania szczęki. Artefakty zarejestrowane w przedziale czasowym 10-20 sekundy najprawdopodobniej były związane z grymasem twarzy. Charakter tych zakłóceń różni się od artefaktów wynikających z zaciskania szczęki, co znalazło odzwierciedlenie w skuteczności zastosowanych metod oczyszczania. Żadne z testowanych podejść nie doprowadziło do ich pełnej eliminacji. Metoda CNN-LSTM dokonała najsilniejszej redukcji tych zakłóceń w porównaniu z innymi metodami, jednakże nie wyeliminowała ich całkowicie. Zakłócenia elektrookulograficzne występujące w przedziale czasowym 20-30 sekundy, choć dobrze widoczne (elektroda *Fp1*) nie powodowały propagacji na elektrody EEG. Seria artefaktów wywołana w przedziale 30-40 sekundy dotyczyła nadymania policzków. Artefakty nie były silnie propagowane, jednakże żadna z metod nie pozwoliła na ich redukcję. W przedziale czasowym 40-50 sekundy zarejestrowano artefakty związane z napinaniem mięśni karku. Sieć CNN-LSTM eliminuje część zakłóceń, jednakże pozostawia ich fragmenty. Nieco gorzej wypada regresja liniowa, natomiast pozostałe metody nie wprowadzały istotnych zmian w stosunku do sygnału przed oczyszczaniem. W ostatnich 10 sekundach sesji pomiarowej zarejestrowano aktywność najprawdopodobniej związaną z mruganiem, które nie powoduje

propagacji zakłóceń na elektrody EEG. W tabeli 35 zaprezentowano parametry (wartość minimalną i maksymalną, odchylenie standardowe i moc) wyznaczone dla całego sygnału przed oczyszczaniem, jego oczyszczonej wersji otrzymanej za pomocą wybranych metod oczyszczania, a także „Krzyża fiksacji”.

Tabela 35. Zestawienie parametrów wyznaczonych dla „Krzyża fiksacji” oraz sesji pomiarowej z różnorodnymi artefaktami.

	Krzyż fiksacji	Cały sygnał	CNN-LSTM	LR	ICA	LMS	RLS
Min	-44,88	-128,37	-85,98	-144,33	-126,16	-132,27	-128,68
Max	41,00	85,57	37,55	62,27	89,01	103,44	96,58
Std	9,32	11,39	9,90	10,50	11,22	10,52	10,50
Moc	86,90	129,75	105,16	110,25	125,88	110,67	110,24

Analizując parametry przedstawione w tabeli 35 można zauważyć, że żadna z metod nie uzyskała wartości zbliżonych do tych, które reprezentowane są jako wzorzec sygnału bez artefaktów („Krzyż fiksacji”). Najbardziej zbliżone wartości pod względem amplitud (wartości minimalna i maksymalna), odchylenia standardowego oraz mocy otrzymano dla sygnału oczyszczonego z wykorzystaniem sieci CNN-LSTM. Regresja liniowa spowodowała zwiększenie modułu minimalnej wartości ponad wartość sprzed oczyszczania, co nie jest akceptowalne. Analogiczne efekty zwiększania wartości otrzymano stosując oczyszczanie z wykorzystaniem ICA (wartość maksymalna) oraz LMS i RLS (obie wartości). W kontekście mocy każda z metod spowodowała jej zmniejszenie względem sygnału przed oczyszczaniem, jednak najmniejszą redukcję uzyskano z wykorzystaniem ICA.

Podsumowując, standardowe metody oczyszczania sygnału EEG okazały się mało skuteczne zarówno w przypadku artefaktów pochodzących od zaciskania szczęki, jak i innych typów zakłóceń zarejestrowanych podczas analizowanej sesji pomiarowej. Sieć CNN-LSTM, trenowana wyłącznie na sygnałach syntetycznych zawierających artefakty zaciskania szczęki, umożliwiła skuteczną redukcję różnorodnych artefaktów mięśniowych.

5.9. Porównanie czasów oczyszczania sygnałów

Podrozdział zawiera zestawienie czasów oczyszczania jednosekundowego okna sygnału z artefaktów za pomocą każdej z analizowanych metod. Z analizy wyłączone zostały montaż bipolarny i Laplace’a, gdyż polegają jedynie na odjęciu przebiegów z sąsiednich elektrod. Wyniki przedstawione w tabeli 36 odnoszą się do uśrednionych czasów oczyszczania 1000 jednosekundowych okien sygnału, przy czym każde okno zawiera 256 próbek, a częstotliwość próbkowania wynosi 256Hz. Czas oczyszczania i odchylenie standardowe (Std) zostały

zaprezentowane w milisekundach. W przypadku metody ICA zastosowano losowy wybór komponentów do odrzucenia, co miało na celu zobrazowanie szybkości działania samego algorytmu.

Tabela 36. Zestawienie uśrednionych czasów oczyszczania dla 1000 jednosekundowych okien.

Czas [ms]	CNN-LSTM	ICA	LR	LMS	RLS
Średnia	60,95	11,10	3,59	1,76	4,73
Std	8,32	0,96	1,15	0,06	0,18

Analizując średnie czasy oczyszczania zamieszczone w tabeli 36 możemy zauważyć, że sieć CNN-LSTM ma średnio najdłuższy czas oczyszczania. Najkrótsze czasy oczyszczania uzyskano dla filtracji LMS. Wszystkie analizowane metody oczyszczania sygnałów są wystarczająco szybkie, aby mogły być zastosowane w systemach czasu rzeczywistego. Średnie czasy oczyszczania okna nie przekraczają 100 milisekund, co sprawia, że systemy wykorzystujące omawiane metody mogłyby charakteryzować się wysoką responsywnością i płynnością działania w czasie rzeczywistym.

5.10. Porównanie z wynikami badań dostępnych w literaturze

W ostatnich latach w literaturze naukowej pojawiło się wiele prac poświęconych problemowi usuwania artefaktów z sygnałów EEG przy użyciu sztucznych sieci neuronowych. Porównanie skuteczności poszczególnych rozwiązań jest jednak bardzo utrudnione. Główną przyczyną jest brak jednolitego podejścia do tworzenia zbiorów danych, wykorzystywanych typów artefaktów oraz miar oceny jakości oczyszczania. W większości badań wykorzystywano dane syntetyczne, tworzone poprzez sztuczne mieszanie czystego sygnału EEG z zarejestrowanymi wcześniej artefaktami lub generowanymi sygnałami zakłócającymi. Porównanie omawianych metod zamieszczono w tabeli 38.

W pracy [56] zaproponowano model łączący konwolucyjne i rekurencyjne sieci neuronowe o dwóch skalach czasowych (Dual-Scale CNN-LSTM). Zastosowano dwie równoległe gałęzie konwolucyjne z filtrami o rozmiarach 3 i 7, co miało umożliwić wychwytywanie cech sygnału EEG w różnych skalach czasowych. Podstawowym celem badania było usuwanie zakłóceń pochodzących od aktywności mięśniowej z syntetycznie przygotowanych danych. Autorzy wykorzystywali dane wygenerowane poprzez mieszanie czystych EEG i artefaktów według określonych proporcji stosunku sygnału do szumu (SNR). Proces oceny skuteczności polegał na porównaniu oryginalnych czystych sygnałów EEG z sygnałami po oczyszczeniu za pomocą

Tabela 38. Porównanie z wynikami badań dostępnych w literaturze.

Praca	Model	Dane	Artefakty	Metryki oceny	Wyniki	Czas przetwarzania
T. Gao, D. Chen, Y. Tang, Z. Ming, and X. Li [56]	Dual-Scale CNN-LSTM (dwie gałęzie CNN + LSTM)	Syntetyczne (EEG + EMG + EOG + ECG + EM, różne SNR)	Elektrookulograficzne, mięśniowe, pochodzące od aktywności serca, artefakty związane z ruchami elektrod	SNR, CC, RRMSE: RMSEt, RMSEf	SNR = 15.68 dB, RRMSE = 0.37 (oba), CC = 0.93	1.52 ms / 512 próbek
M. Azhar, T. Shafique, and A. Amjad [98]	CNN	Syntetyczne (z EEGdenoiseNet)	Elektrookulograficzne, mięśniowe	CC, RRMSE: RMSEt, RMSEf	RRMSE = 0.35 (oba), CC = 0.94	Nie podano
C. Yu et al. [99]	SSA + CNN	Syntetyczne (na podstawie bazy danych CHB-MIT)	Mięśniowe	RRMSE, CC	RRMSE = 0.5, CC = 0.88 (dla SNR = -3 dB)	Nie podano
R. Jiang et al. [100]	CLEnet: CNN + LSTM + EMA-1D (mechanizm uwagi)	Syntetyczne + rzeczywiste EEG (zadanie 2-back, 11 uczestników)	Elektrookulograficzne, mięśniowe oraz mieszane	SNR, CC, RRMSE: RMSEt, RMSEf	Poprawa: SNR +2.45%, CC +2.65%, RRMSEt - 6.94%, RRMSEf - 3.30%	0.129 GFLOPs (512 próbek)
Autorska metoda CNN-LSTM	CNN + LSTM	Rzeczywiste + SSVEP (17 uczestników), syntetyczne (autorski generator)	Mięśniowe	RMSE, SNR _{SSVEP}	RMSE = 4.26 ± 1.45 SNR _{SSVEP} = 1.80/2.75 (Uśredniony dla okien z artefaktami dla niskich częstotliwości SSVEP przed/po oczyszczaniu).	60.95 ± 8.32 ms / 256 próbek

wskaźników takich jak SNR, współczynnik korelacji (CC) oraz błąd RRMSE w dziedzinie czasowej (RRMSEt) i spektralnej (RRMSEf). Wykorzystano kilka zestawów danych zawierających różne typy zakłóceń, a dla najbardziej skomplikowanego model DuoCL osiągnął średnio: SNR = 15.68 dB, RRMSEt = 0.37, RRMSEf = 0.37, CC = 0.93. Segment EEG o długości 2 sekund z jednego kanału był przetwarzany średnio w czasie 1.52 ms, co stanowi czas o trzy rzędy wielkości krótszy od rzeczywistego czasu trwania sygnału. Model nie wykorzystywał jednak sygnałów pochodzących z elektrod pomocniczych rejestrujących aktywność związaną z artefaktami, w przeciwieństwie do sieci prezentowanej w pracy

doktorskiej, która osiągnęła dłuższe czasy oczyszczania jednej sekundy sygnału EEG, średnio 60.95 ± 8.32 ms.

W pracy [98] skupiono się na jednoczesnym usuwaniu artefaktów elektrookulograficznych i mięśniowych z sygnałów EEG. Do tego celu wykorzystano sieć konwolucyjną CNN, której zadaniem było przekształcanie sygnału wejściowego z artefaktami na oczyszczone EEG. Dane treningowe pochodziły ze zbioru EEGdenoiseNet i również były syntetyczne. Jako metryki oceny wykorzystano między innymi RRMSE i współczynnik korelacji. Ostatecznie model osiągnął wartość RRMSE równą 0.35 zarówno w dziedzinie czasowej, jak i spektralnej ($RRMSE_t = 0.35$, $RRMSE_f = 0.35$) oraz współczynnik korelacji równy 0.94 ($CC = 0.94$), co świadczy o wysokim stopniu zgodności sygnałów oczyszczonych z sygnałami referencyjnymi. W pracy nie podano informacji o czasie przetwarzania sygnałów, jednak autorzy sugerują możliwość rozszerzenia modelu w przyszłości o przetwarzanie sygnałów EEG w czasie rzeczywistym.

Z kolei autorzy publikacji [99] zaproponowali hybrydowe podejście do usuwania artefaktów mięśniowych z jednokanałowych sygnałów EEG, łączące metodę SSA (Singular spectrum analysis) z konwolucyjną siecią neuronową. Do treningu i testowania modelu wykorzystano syntetyczne sygnały EEG wygenerowane na podstawie danych z bazy CHB-MIT, pobranych z nagrań EEG próbkowanych z częstotliwością 256 Hz. Na danych testowych wykazano, że proponowana metoda przewyższa klasyczne podejścia, szczególnie przy stosunku sygnału do szumu wynoszącym co najmniej -1 dB ($RRMSE = 0,35$). Autorzy nie podali jednak czasów oczyszczania sygnału.

W pracy [100] przedstawiono model CLEnet, łączący sieci CNN, LSTM oraz własną wersję mechanizmu uwagi: EMA-1D. Model został zaprojektowany do pracy zarówno na danych jedno, jak i wielokanałowych. W badaniach wykorzystano trzy zbiory danych: dwa syntetyczne, utworzone poprzez łączenie czystych sygnałów EEG z artefaktami (elektrookulograficznymi i mięśniowymi oraz pochodzącym od aktywności serca), a także rzeczywisty, 32-kanałowy zbiór EEG pochodzący od zdrowych uczestników wykonujących zadanie typu 2-back. W przypadku rzeczywistego zbioru, autorzy wskazali na obecność artefaktów nieznanego pochodzenia, między innymi elektrookulograficznych i mięśniowych, a także zakłóceń wynikających z pulsacji naczyń krwionośnych i przełykania. Do utworzenia referencyjnych danych „czystego EEG”, dla tego zbioru zastosowano procedurę oczyszczania sygnału za pomocą ICA oraz ręcznej inspekcji komponentów. Oznacza to, że sieć była trenowana i oceniana względem sygnału, który sam był wynikiem uprzedniej filtracji. W badaniach wykorzystano dane EEG o częstotliwości próbkowania 256 Hz. W porównaniu

do innych modeli takich jak 1D-ResCNN i NovelCNN, model CLEnet poprawia SNR o około 2,45%, zwiększa CC o 2,65%, a jednocześnie zmniejsza RRMSEt o 6,94% oraz RRMSEf o 3,30%. Choć w pracy nie podano szczegółowych wartości czasu przetwarzania, zastosowana architektura i modularność modelu sugerują potencjał do zastosowań bliskich pracy w czasie rzeczywistym.

W odróżnieniu od opisywanych badań, w pracy doktorskiej zastosowano podejście oparte na rzeczywistych, jednocześnie rejestrowanych sygnałach EEG i dodatkowych sygnałach EMG (tabela 38). Rejestracja danych EEG odbywała się w trakcie eksperymentu związanego z wymuszoną stymulacją wzrokową SSVEP, co pozwoliło na późniejszą ocenę wpływu procesu oczyszczania na obecność i jakość odpowiedzi wywołanych.

Istotną nowością w porównaniu do wcześniejszych badań było wprowadzenie wskaźnika SNR_{SSVEP} , który pozwolił na ocenę wpływu procesu oczyszczania na zachowanie charakterystycznych cech odpowiedzi SSVEP. Ze względu na brak znanego sygnału referencyjnego w rzeczywistych danych EEG, nie było możliwe zastosowanie klasycznych wskaźników błędów, takich jak MSE, współczynnik korelacji czy RRMSE, które były wykorzystywane w badaniach bazujących na danych syntetycznych ($RMSE = 4,26 \pm 1,45$).

Autorska sieć CNN-LSTM wykazuje wysoką skuteczność w oczyszczaniu sygnałów EEG z artefaktów mięśniowych przy jednoczesnym zachowaniu istotnych komponentów SSVEP. Efektywność metody została potwierdzona na rzeczywistych danych, co podkreśla jej praktyczną wartość. Wykorzystanie dodatkowych elektrod rejestrujących źródła zakłóceń, mimo że nie jest powszechnie stosowane, jest istotnym elementem podejścia, który umożliwia skuteczne usuwanie artefaktów. Relatywnie krótki czas przetwarzania pozwala na implementację metody w systemach działających w czasie rzeczywistym. Proponowane rozwiązanie wpisuje się w aktualne trendy związane z wykorzystaniem zaawansowanych sieci neuronowych w analizie sygnałów EEG.

6. Podsumowanie

Wyniki uzyskane w trakcie realizacji pracy wskazują, że zastosowanie hybrydowej sieci CNN-LSTM, przy jednoczesnym wykorzystaniu kanałów EMG jako danych wejściowych, umożliwia skuteczne usuwanie artefaktów mięśniowych z sygnałów EEG bez utraty wartościowych informacji. Aby umożliwić obiektywną ocenę skuteczności oczyszczania, zaproponowano nową miarę: współczynnik SNR_{SSVEP} , pozwalający na ilościową analizę zachowania odpowiedzi SSVEP bez potrzeby użycia sygnału referencyjnego wolnego od zakłóceń.

Model hybrydowy CNN-LSTM, został zoptymalizowany pod względem liczby parametrów, uzyskał najniższe wartości błędów RMSE dla danych syntetycznych oraz wysokie wartości SNR_{SSVEP} dla rzeczywistych sygnałów EEG, przewyższając skutecznością metody klasyczne, takie jak ICA, regresja liniowa, filtracja LMS i RLS czy metody transformacji międzykanałowej. Sieć skutecznie usuwała artefakty tylko w miejscach ich występowania, pozostawiając okna wolne od zakłóceń praktycznie nienaruszone. W analizie spektrogramów nie było możliwe wskazanie momentów występowania artefaktów po oczyszczeniu, co świadczy o skuteczności działania modelu. W porównaniu z innymi metodami, CNN-LSTM najwierniej odwzorowywał sygnał w oczyszczonych oknach z artefaktami względem oryginalnych okien wolnych od zakłóceń zarówno pod względem amplitud, mocy, jak również przebiegu czasowego.

Dla stymulacji wywołujących SSVEP w zakresie 6-9Hz, CNN-LSTM uzyskał najkorzystniejsze współczynniki SNR_{SSVEP} w oczyszczonym sygnale. Choć dla częstotliwości 25 Hz odpowiedź SSVEP była obecna tylko u części uczestników, także tutaj CNN-LSTM wykazał się wysoką skutecznością, co potwierdziła analiza spektrogramów.

Wyniki klasyfikacji na podstawie współczynników SNR_{SSVEP} dla sygnałów oczyszczonych potwierdziły praktyczną przydatność sieci hybrydowej. CNN-LSTM pozwalał na utrzymanie lub poprawę trafności klasyfikacji SSVEP względem sygnałów nieoczyszczonych, zwłaszcza w przypadku okien zawierających artefakty.

Jako uzupełnienie analizy, zaprezentowano działanie wszystkich ocenianych metod na przykładowym sygnale pochodzącym z osobnej bazy zawierającej różnorodne artefakty. CNN-LSTM wykazał największą zdolność do usuwania zakłóceń, choć w przypadku artefaktów innego typu niż zaciskanie szczęki, fragmenty artefaktów były nadal obecne. Jest to związane z faktem, że sieć była trenowana wyłącznie na jednym rodzaju zakłóceń. Pozostałe metody nie

wykazywały istotnego wpływu na eliminację artefaktów lub jedynie nieznacznie osłabiały ich intensywność.

Biorąc pod uwagę wszystkie powyższe obserwacje, poparte licznymi wynikami, teza postawiona na początku pracy *„Zastosowanie sieci hybrydowej typu CNN-LSTM oraz dodatkowej rejestracji źródeł EMG pozwala na skuteczną eliminację artefaktów mięśniowych z sygnału EEG”* jest prawdziwa.

Przeprowadzone badania dotyczące analizy artefaktów oraz ich eliminacji mogą mieć pozytywny wpływ na rozwój dyscypliny, jaką jest Inżynieria Biomedyczna. Uzyskane wyniki wskazują na możliwość zastosowania opracowanej metody w zaawansowanych systemach analizy sygnałów bioelektrycznych, szczególnie w interfejsach mózg-komputer oraz w monitorowaniu stanu pacjenta. Skuteczna eliminacja artefaktów bez utraty istotnych informacji z sygnałów EEG zwiększa wiarygodność dalszych analiz i może przyczynić się do tworzenia dokładniejszych i bardziej niezawodnych narzędzi wykorzystywanych w praktyce klinicznej i badaniach naukowych.

Zaprezentowane podejście związane z wielokanałowym oczyszczaniem sygnałów przy użyciu sieci konwolucyjnych i rekurencyjnych pokazuje ich użyteczność w zadaniu eliminacji artefaktów.

Dalsze prace badawcze mogą skupić się na rozszerzeniu generatora o modele innych typów artefaktów obecnych w sygnałach EEG oraz na douczeniu sieci CNN-LSTM, co umożliwi bardziej wszechstronne testowanie metod oczyszczania. Ponadto warto podjąć próbę dalszej optymalizacji architektury sieci CNN-LSTM w celu zmniejszenia jej złożoności obliczeniowej. Jednym z istotnych kierunków rozwoju może być również próba dodatkowego ograniczenia liczby wykorzystywanych elektrod przy zachowaniu skuteczności oczyszczania, co zwiększyłoby praktyczną użyteczność opracowanego podejścia.

Badania związane z eliminacją artefaktów były wykonywane i częściowo finansowane ze środków Politechniki Warszawskiej w ramach Programu Inicjatywa doskonałości – uczelnia badawcza (IDUB) pod tytułem *„Opracowanie skutecznych metod usuwania ekstremalnych artefaktów z sygnału EEG”*.

7. Bibliografia

- [1] P. M. Rossini, J. Cole, W. Paulus, U. Ziemann, and R. Chen, ‘1924–2024: First centennial of EEG’, *Clinical Neurophysiology*, vol. 170, pp. 132–135, Feb. 2025, doi: 10.1016/j.clinph.2024.11.021.
- [2] X. Gu *et al.*, ‘EEG-based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and their Applications’, Jan. 28, 2020, *arXiv*: arXiv:2001.11337. doi: 10.48550/arXiv.2001.11337.
- [3] E. Niedermeyer and F. H. L. da Silva, *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams & Wilkins, 2005.
- [4] **M. Kołodziej, A. Majkowski, and M. Jurczak, ‘Acquisition and Analysis of Facial Electromyographic Signals for Emotion Recognition’, *Sensors*, vol. 24, no. 15, Art. no. 15, Jan. 2024, doi: 10.3390/s24154785.**
- [5] ‘Report of the committee on methods of clinical examination in electroencephalography: 1957’, *Electroencephalography and Clinical Neurophysiology*, vol. 10, no. 2, pp. 370–375, May 1958, doi: 10.1016/0013-4694(58)90053-1.
- [6] J. H. McKay and W. O. Tatum, ‘Artifact Mimicking Ictal Epileptiform Activity in EEG’, *J Clin Neurophysiol*, vol. 36, no. 4, pp. 275–288, Jul. 2019, doi: 10.1097/WNP.0000000000000597.
- [7] M. Y and V. P, ‘Efficient EEG motion artifact elimination framework for ambulatory epileptic seizure detection application’, *Biomedical physics & engineering express*, vol. 10, Mar. 2024, doi: 10.1088/2057-1976/ad2ff4.
- [8] M. Fatourehchi, A. Bashashati, R. Ward, and G. Birch, ‘EMG and EOG artifacts in brain computer interface systems: A survey’, *Clinical neurophysiology: official journal of the International Federation of Clinical Neurophysiology*, vol. 118, pp. 480–94, Apr. 2007, doi: 10.1016/j.clinph.2006.10.019.
- [9] J.-F. Gagnon *et al.*, ‘Association between waking EEG slowing and REM sleep behavior disorder in PD without dementia’, *Neurology*, vol. 62, pp. 401–6, Mar. 2004, doi: 10.1212/01.WNL.0000106460.34682.E9.
- [10] M. Trigka, E. Dritsas, and C. Fidas, ‘A Survey on Signal Processing Methods for EEG-based Brain Computer Interface Systems’, in *Proceedings of the 26th Pan-Hellenic Conference on Informatics*, Athens Greece: ACM, Nov. 2022, pp. 213–218. doi: 10.1145/3575879.3575995.
- [11] R. Anand, N. Radharapu, P. Pradhan, and R. Birok, ‘Removal of EOG Artefact from EEG – A Review’, 2022. doi: 10.3233/ATDE220783.
- [12] X. Jiang, G.-B. Bian, and Z. Tian, ‘Removal of Artifacts from EEG Signals: A Review’, *Sensors*, vol. 19, p. 987, Feb. 2019, doi: 10.3390/s19050987.
- [13] Md. A. Iqbal, Md. M. Rahman, S. Muhtasim, S. E. Uddin Shubha, and M. Hasan, ‘Effect of EOG Artifact Removal on EEG Motor-Imagery Classification’, in *2022 25th International Conference on Computer and Information Technology (ICCIT)*, Dec. 2022, pp. 850–854. doi: 10.1109/ICCIT57492.2022.10056062.
- [14] S. Hoffmann and M. Falkenstein, ‘The Correction of Eye Blink Artefacts in the EEG: A Comparison of Two Prominent Methods’, *PloS one*, vol. 3, p. e3004, Feb. 2008, doi: 10.1371/journal.pone.0003004.

- [15] G. Di Flumeri, P. Arico, G. Borghini, A. Colosimo, and F. Babiloni, 'A new regression-based method for the eye blinks artifacts correction in the EEG signal, without using any EOG channel', *Annu Int Conf IEEE Eng Med Biol Soc*, vol. 2016, pp. 3187–3190, Aug. 2016, doi: 10.1109/EMBC.2016.7591406.
- [16] the B. team, 'All about EEG Artifacts and filtering tools', Bitbrain. Accessed: May 15, 2025. [Online]. Available: <https://www.bitbrain.com/blog/eeeg-artifacts>
- [17] L. Ghosh, S. Saha, and A. Konar, 'Bi-directional Long Short-Term Memory model to analyze psychological effects on gamers', *Applied Soft Computing*, vol. 95, p. 106573, Oct. 2020, doi: 10.1016/j.asoc.2020.106573.
- [18] H. Li *et al.*, 'Massage Therapy's Effectiveness on the Decoding EEG Rhythms of Left/Right Motor Imagery and Motion Execution in Patients With Skeletal Muscle Pain', *IEEE Journal of Translational Engineering in Health and Medicine*, vol. 9, pp. 1–20, 2021, doi: 10.1109/JTEHM.2021.3056911.
- [19] S. Behera, M. Mohanty, and S. Mohapatra, 'Design of optimized adaptive filter for artifact removal from EEG signal', *Journal of Statistics & Management Systems*, vol. 26, pp. 201–212, Jan. 2023, doi: 10.47974/JSMS-959.
- [20] P. Sharma, 'Removal of Artifacts In EEG Signals Using Sign Based LMS Adaptive Filtering Techniques', in *2023 1st International Conference on Innovations in High Speed Communication and Signal Processing (IHCSP)*, Mar. 2023, pp. 199–203. doi: 10.1109/IHCSP56702.2023.10127136.
- [21] A. Garces, E. Laciari, H. Patiño, and M. Valentinuzzi, 'Artifact removal from EEG signals using adaptive filters in cascade', *Journal of Physics: Conference Series*, vol. 90, p. 012081, Dec. 2007, doi: 10.1088/1742-6596/90/1/012081.
- [22] S. Tong, A. Bezerianos, J. Paul, Y. Zhu, and N. Thakor, 'Removal of ECG interference from the EEG recordings in small animals using independent component analysis', *Journal of Neuroscience Methods*, vol. 108, no. 1, pp. 11–17, Jul. 2001, doi: 10.1016/S0165-0270(01)00366-1.
- [23] S. Saba-Sadiya, E. Chantland, T. Alhanai, T. Liu, and M. M. Ghassemi, 'Unsupervised EEG Artifact Detection and Correction', *Front Digit Health*, vol. 2, p. 608920, Jan. 2021, doi: 10.3389/fdgh.2020.608920.
- [24] M. Chaumon, D. V. M. Bishop, and N. A. Busch, 'A practical guide to the selection of independent components of the electroencephalogram for artifact correction', *Journal of Neuroscience Methods*, vol. 250, pp. 47–63, Jul. 2015, doi: 10.1016/j.jneumeth.2015.02.025.
- [25] S. Devuyst, T. Dutoit, P. Stenuit, M. Kerkhofs, and E. Stanus, '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*, Aug. 2008, pp. 5204–5207. doi: 10.1109/IEMBS.2008.4650387.
- [26] Y. Leclercq *et al.*, 'Rejection of pulse related artefact (PRA) from continuous electroencephalographic (EEG) time series recorded during functional magnetic resonance imaging (fMRI) using constraint independent component analysis (cICA)', *NeuroImage*, vol. 44, no. 3, pp. 679–691, Feb. 2009, doi: 10.1016/j.neuroimage.2008.10.017.
- [27] G. Tamburro, D. B. Stone, and S. Comani, 'Automatic Removal of Cardiac Interference (ARCI): A New Approach for EEG Data', *Front. Neurosci.*, vol. 13, May 2019, doi: 10.3389/fnins.2019.00441.

- [28] P. Wang, J.-S. Nam, and X. Han, ‘Development of a comprehensive fatigue detection model for beekeeping activities based on deep learning and EEG signals’, *Computers and Electronics in Agriculture*, vol. 225, p. 109265, Oct. 2024, doi: 10.1016/j.compag.2024.109265.
- [29] L. Pion-Tonachini, K. Kreutz-Delgado, and S. Makeig, ‘ICLabel: An automated electroencephalographic independent component classifier, dataset, and website’, *Neuroimage*, vol. 198, pp. 181–197, Sep. 2019, doi: 10.1016/j.neuroimage.2019.05.026.
- [30] S. Blum, N. S. J. Jacobsen, M. G. Bleichner, and S. Debener, ‘A Riemannian Modification of Artifact Subspace Reconstruction for EEG Artifact Handling’, *Front. Hum. Neurosci.*, vol. 13, Apr. 2019, doi: 10.3389/fnhum.2019.00141.
- [31] W. De Clercq, A. Vergult, B. Vanrumste, W. Van Paesschen, and S. Van Huffel, ‘Canonical Correlation Analysis Applied to Remove Muscle Artifacts From the Electroencephalogram’, *IEEE Transactions on Biomedical Engineering*, vol. 53, no. 12, pp. 2583–2587, Nov. 2006, doi: 10.1109/TBME.2006.879459.
- [32] R. Kalidoss, ‘Ocular Artifact Correction In ECG Using Wavelet Thresholding’, Aug. 2017.
- [33] M. Aslan, M. Baykara, and T. B. Alakus, ‘LieWaves: dataset for lie detection based on EEG signals and wavelets’, *Med Biol Eng Comput*, vol. 62, no. 5, pp. 1571–1588, May 2024, doi: 10.1007/s11517-024-03021-2.
- [34] H. Zhang, M. Zhao, C. Wei, D. Mantini, Z. Li, and Q. Liu, ‘EEGdenoiseNet: a benchmark dataset for deep learning solutions of EEG denoising’, *J. Neural Eng.*, vol. 18, no. 5, p. 056057, Oct. 2021, doi: 10.1088/1741-2552/ac2bf8.
- [35] X. Pu, P. Yi, K. Chen, Z. Ma, D. Zhao, and Y. Ren, ‘EEGDnet: Fusing non-local and local self-similarity for EEG signal denoising with transformer’, *Computers in Biology and Medicine*, vol. 151, p. 106248, Dec. 2022, doi: 10.1016/j.compbiomed.2022.106248.
- [36] W. Sun, Y. Su, X. Wu, and X. Wu, ‘A novel end-to-end 1D-ResCNN model to remove artifact from EEG signals’, *Neurocomputing*, vol. 404, pp. 108–121, Sep. 2020, doi: 10.1016/j.neucom.2020.04.029.
- [37] S. Mahmud *et al.*, ‘Restoration of motion-corrupted EEG signals using attention-guided operational CycleGAN’, *Engineering Applications of Artificial Intelligence*, vol. 128, p. 107514, Feb. 2024, doi: 10.1016/j.engappai.2023.107514.
- [38] B. Priya Prathaban and R. Balasubramanian, ‘Dynamic learning framework for epileptic seizure prediction using sparsity based EEG Reconstruction with Optimized CNN classifier’, *Expert Systems with Applications*, vol. 170, p. 114533, May 2021, doi: 10.1016/j.eswa.2020.114533.
- [39] M. V. V. S. Prasad and T. R. Babu, ‘Less complexity-aware intelligent 1-dimensional CNN with weighted deep features for artifacts removal in EEG signals’, *Digital Signal Processing*, vol. 145, p. 104319, Feb. 2024, doi: 10.1016/j.dsp.2023.104319.
- [40] L. Wu, A. Liu, C. Li, and X. Chen, ‘Enhancing EEG artifact removal through neural architecture search with large kernels’, *Advanced Engineering Informatics*, vol. 62, p. 102831, Oct. 2024, doi: 10.1016/j.aei.2024.102831.
- [41] B. Yang, K. Duan, C. Fan, C. Hu, and J. Wang, ‘Automatic ocular artifacts removal in EEG using deep learning’, *Biomedical Signal Processing and Control*, vol. 43, pp. 148–158, May 2018, doi: 10.1016/j.bspc.2018.02.021.

- [42] M. Mathe, M. Padmaja, and B. Tirumala Krishna, ‘Intelligent approach for artifacts removal from EEG signal using heuristic-based convolutional neural network’, *Biomedical Signal Processing and Control*, vol. 70, p. 102935, Sep. 2021, doi: 10.1016/j.bspc.2021.102935.
- [43] C. Wang, A. Grau, and F. Zhang, ‘One-Dimensional EEG Artifact Removal Network Based on Convolutional Neural Networks’, Mar. 2024.
- [44] C. Wang, A. Grau, and F. Zhang, ‘2-D GCANet Applied to Denoise 1-D EEG Signals in Online Remote Teaching Scenarios’, Mar. 2024.
- [45] N. Bahador, K. Erikson, J. Laurila, J. Koskenkari, T. Ala-Kokko, and J. Kortelainen, ‘A Correlation-Driven Mapping For Deep Learning application in detecting artifacts within the EEG’, *Journal of Neural Engineering*, vol. 17, p. 056018, Oct. 2020, doi: 10.1088/1741-2552/abb5bd.
- [46] J. Yu, C. Li, K. Lou, C. Wei, and Q. Liu, ‘Embedding Decomposition for Artifacts Removal in EEG Signals’, Feb. 21, 2022, *arXiv*: arXiv:2112.00989. doi: 10.48550/arXiv.2112.00989.
- [47] H.-A. T. Nguyen, A. T. Do, T. H. Le, and T. D. Bui, ‘A deep sparse autoencoder method for automatic EOG artifact removal’, in *2019 19th International Conference on Control, Automation and Systems (ICCAS)*, Oct. 2019, pp. 346–351. doi: 10.23919/ICCAS47443.2019.8971645.
- [48] H. Cui, C. Li, A. Liu, R. Qian, and X. Chen, ‘A Dual-Branch Interactive Fusion Network to Remove Artifacts From Single-Channel EEG’, *IEEE Transactions on Instrumentation and Measurement*, vol. 73, pp. 1–12, 2024, doi: 10.1109/TIM.2023.3342863.
- [49] J. Yin, A. Liu, C. Li, R. Qian, and X. Chen, ‘A GAN Guided Parallel CNN and Transformer Network for EEG Denoising’, *IEEE Journal of Biomedical and Health Informatics*, pp. 1–12, 2023, doi: 10.1109/JBHI.2023.3277596.
- [50] Y. Li, A. Liu, J. Yin, C. Li, and X. Chen, ‘A Segmentation-Denoising Network for Artifact Removal From Single-Channel EEG’, *IEEE Sensors Journal*, vol. 23, no. 13, pp. 15115–15127, Jul. 2023, doi: 10.1109/JSEN.2023.3276481.
- [51] Y. Dong *et al.*, ‘An Approach for EEG Denoising Based on Wasserstein Generative Adversarial Network’, *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, vol. PP, Aug. 2023, doi: 10.1109/TNSRE.2023.3309815.
- [52] J. R. McIntosh, J. Yao, L. Hong, J. Faller, and P. Sajda, ‘Ballistocardiogram Artifact Reduction in Simultaneous EEG-fMRI Using Deep Learning’, *IEEE Trans Biomed Eng*, vol. 68, no. 1, pp. 78–89, Jan. 2021, doi: 10.1109/TBME.2020.3004548.
- [53] L. Xing and A. J. Casson, ‘Deep Autoencoder for Real-Time Single-Channel EEG Cleaning and Its Smartphone Implementation Using TensorFlow Lite With Hardware/Software Acceleration’, *IEEE Trans Biomed Eng*, vol. 71, no. 11, pp. 3111–3122, Nov. 2024, doi: 10.1109/TBME.2024.3408331.
- [54] N. Mashhadi, A. Z. Khuzani, M. Heidari, and D. Khaledyan, ‘Deep learning denoising for EOG artifacts removal from EEG signals’, in *2020 IEEE Global Humanitarian Technology Conference (GHTC)*, Oct. 2020, pp. 1–6. doi: 10.1109/GHTC46280.2020.9342884.
- [55] Y. Pei *et al.*, ‘DTP-Net: Learning to Reconstruct EEG Signals in Time-Frequency Domain by Multi-Scale Feature Reuse’, *IEEE Journal of Biomedical and Health Informatics*, vol. 28, no. 5, pp. 2662–2673, May 2024, doi: 10.1109/JBHI.2024.3358917.

- [56] T. Gao, D. Chen, Y. Tang, Z. Ming, and X. Li, ‘EEG Reconstruction With a Dual-Scale CNN-LSTM Model for Deep Artifact Removal’, *IEEE Journal of Biomedical and Health Informatics*, vol. 27, no. 3, pp. 1283–1294, Mar. 2023, doi: 10.1109/JBHI.2022.3227320.
- [57] X. Huang, Z. Hao, Y. Pan, and W. Dou, ‘Enhancing Artifact Removal From Scalp EEG Using State-Wise Deep Convolutional Network’, in *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, Dec. 2023, pp. 2501–2507. doi: 10.1109/BIBM58861.2023.10385850.
- [58] J. Yin, A. Liu, C. Li, R. Qian, and X. Chen, ‘Frequency Information Enhanced Deep EEG Denoising Network for Ocular Artifact Removal’, *IEEE Sensors Journal*, vol. 22, no. 22, pp. 21855–21865, Nov. 2022, doi: 10.1109/JSEN.2022.3209805.
- [59] S. Mahmud, M. S. Hossain, M. E. H. Chowdhury, and M. B. I. Reaz, ‘MLMRS-Net: Electroencephalography (EEG) motion artifacts removal using a multi-layer multi-resolution spatially pooled 1D signal reconstruction network’, *Neural Comput & Applic*, vol. 35, no. 11, pp. 8371–8388, Apr. 2023, doi: 10.1007/s00521-022-08111-6.
- [60] X. Jin, J. Wang, L. Liu, and Y. Lin, ‘Uncertainty-Aware Denoising Network for Artifact Removal in EEG Signals’, *IEEE Trans Neural Syst Rehabil Eng*, vol. 31, pp. 4470–4480, 2023, doi: 10.1109/TNSRE.2023.3330963.
- [61] S. Behera and M. N. Mohanty, ‘Artifact removal using deep WVFLN for brain signal diagnosis through IoMT’, *Measurement: Sensors*, vol. 24, p. 100465, Dec. 2022, doi: 10.1016/j.measen.2022.100465.
- [62] Y. Feng, Q. Liu, A. Liu, R. Qian, and X. Chen, ‘A novel SSA-CCA framework for muscle artifact removal from ambulatory EEG’, *Virtual Reality & Intelligent Hardware*, vol. 4, no. 1, pp. 1–21, Feb. 2022, doi: 10.1016/j.vrih.2022.01.001.
- [63] X. Chen, Q. Chen, Y. Zhang, and Z. J. Wang, ‘A Novel EEMD-CCA Approach to Removing Muscle Artifacts for Pervasive EEG’, *IEEE Sensors Journal*, vol. 19, no. 19, pp. 8420–8431, Oct. 2019, doi: 10.1109/JSEN.2018.2872623.
- [64] S.-H. Kim, H.-J. Yang, N. A. T. Nguyen, S. K. Prabhakar, and S.-W. Lee, ‘WeDea: A New EEG-Based Framework for Emotion Recognition’, *IEEE Journal of Biomedical and Health Informatics*, vol. 26, no. 1, pp. 264–275, Jan. 2022, doi: 10.1109/JBHI.2021.3091187.
- [65] C. Bao, Z. Hao, and W. Dou, ‘Automatic Removal of Scalp EEG Artifacts Using an Interpretable Hybrid Deep Learning Method’, in *2022 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, Dec. 2022, pp. 1451–1456. doi: 10.1109/BIBM55620.2022.9995132.
- [66] A. Narmada and M. K. Shukla, ‘A novel adaptive artifacts wavelet Denoising for EEG artifacts removal using deep learning with Meta-heuristic approach’, *Multimed Tools Appl*, vol. 82, no. 26, pp. 40403–40441, Nov. 2023, doi: 10.1007/s11042-023-14949-2.
- [67] S. Zhang *et al.*, ‘Efficient Rejection of Artifacts for Short-Term Few-Channel EEG Based on Fast Adaptive Multidimensional Sub-Bands Blind Source Separation’, *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1–16, 2021, doi: 10.1109/TIM.2021.3115586.
- [68] C. Guerrero-Mosquera and A. Navia-Vazquez, ‘Automatic removal of ocular artefacts using adaptive filtering and independent component analysis for electroencephalogram data’, *Signal Processing, IET*, vol. 6, pp. 99–106, May 2012, doi: 10.1049/iet-spr.2010.0135.

- [69] L. Ghosh, D. Dewan, A. Chowdhury, and A. Konar, ‘Exploration of face-perceptual ability by EEG induced deep learning algorithm’, *Biomedical Signal Processing and Control*, vol. 66, p. 102368, Apr. 2021, doi: 10.1016/j.bspc.2020.102368.
- [70] O. W. Samuel *et al.*, ‘A Low-rank Spatiotemporal based EEG Multi-Artifacts Cancellation Method for Enhanced ConvNet-DL’s Motor Imagery Characterization’, *Annu Int Conf IEEE Eng Med Biol Soc*, vol. 2021, pp. 791–794, Nov. 2021, doi: 10.1109/EMBC46164.2021.9629547.
- [71] P. Croce, F. Zappasodi, L. Marzetti, A. Merla, V. Pizzella, and A. M. Chiarelli, ‘Deep Convolutional Neural Networks for Feature-Less Automatic Classification of Independent Components in Multi-Channel Electrophysiological Brain Recordings’, *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 8, pp. 2372–2380, Aug. 2019, doi: 10.1109/TBME.2018.2889512.
- [72] F. Lopes *et al.*, ‘Ensemble Deep Neural Network for Automatic Classification of EEG Independent Components’, *IEEE Trans Neural Syst Rehabil Eng*, vol. 30, pp. 559–568, 2022, doi: 10.1109/TNSRE.2022.3154891.
- [73] R. Kaur, M. Korolkov, M. E. Hernandez, and R. Sowers, ‘Automatic Identification of Brain Independent Components in Electroencephalography Data Collected while Standing in a Virtually Immersive Environment - A Deep Learning-Based Approach’, in *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Jul. 2020, pp. 95–98. doi: 10.1109/EMBC44109.2020.9175741.
- [74] D. S. Prasad, S. R. Chanamallu, and K. S. Prasad, ‘Optimized deformable convolution network for detection and mitigation of ocular artifacts from EEG signal’, *Multimed Tools Appl*, vol. 81, no. 21, pp. 30841–30879, Sep. 2022, doi: 10.1007/s11042-022-12874-4.
- [75] Ö. Kasim and M. Tosun, ‘Effective removal of eye-blink artifacts in EEG signals with semantic segmentation’, *SIViP*, vol. 16, no. 5, pp. 1289–1295, Jul. 2022, doi: 10.1007/s11760-021-02080-4.
- [76] H. Zhu *et al.*, ‘The Masking Impact of Intra-Artifacts in EEG on Deep Learning-Based Sleep Staging Systems: A Comparative Study’, *IEEE Trans Neural Syst Rehabil Eng*, vol. 30, pp. 1452–1463, 2022, doi: 10.1109/TNSRE.2022.3173994.
- [77] S. A. Keenan, ‘6 - Polysomnographic Technique: An Overview’, in *Sleep Disorders Medicine*, S. Chokroverty, Ed., Butterworth-Heinemann, 1994, pp. 79–94. doi: 10.1016/B978-0-7506-9002-7.50011-2.
- [78] A. Biasiucci, B. Franceschiello, and M. M. Murray, ‘Electroencephalography’, *Current Biology*, vol. 29, no. 3, pp. R80–R85, Feb. 2019, doi: 10.1016/j.cub.2018.11.052.
- [79] Y. Gordienko, N. Gordienko, V. Taran, A. Rojbi, S. Telenyk, and S. Stirenko, ‘Effect of natural and synthetic noise data augmentation on physical action classification by brain–computer interface and deep learning’, *Front. Neuroinform.*, vol. 19, Feb. 2025, doi: 10.3389/fninf.2025.1521805.
- [80] D. Arora, M. Garg, and M. Gupta, ‘Diving deep in Deep Convolutional Neural Network’, in *2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)*, Dec. 2020, pp. 749–751. doi: 10.1109/ICACCCN51052.2020.9362907.
- [81] S. Mutasa, S. Sun, and R. Ha, ‘Understanding artificial intelligence based radiology studies: CNN architecture’, *Clinical Imaging*, vol. 80, pp. 72–76, Dec. 2021, doi: 10.1016/j.clinimag.2021.06.033.

- [82] I. Malashin, V. Tynchenko, A. Gantimurov, V. Nelyub, and A. Borodulin, ‘Applications of Long Short-Term Memory (LSTM) Networks in Polymeric Sciences: A Review’, *Polymers*, vol. 16, no. 18, Art. no. 18, Jan. 2024, doi: 10.3390/polym16182607.
- [83] F. Landi, L. Baraldi, M. Cornia, and R. Cucchiara, ‘Working Memory Connections for LSTM’, *Neural Networks*, vol. 144, pp. 334–341, Dec. 2021, doi: 10.1016/j.neunet.2021.08.030.
- [84] S. Belagoune, N. Bali, A. Bakdi, B. Baadji, and K. Atif, ‘Deep learning through LSTM classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems’, *Measurement*, vol. 177, p. 109330, Jun. 2021, doi: 10.1016/j.measurement.2021.109330.
- [85] G. Van Houdt, C. Mosquera, and G. Nápoles, ‘A Review on the Long Short-Term Memory Model’, *Artificial Intelligence Review*, vol. 53, Dec. 2020, doi: 10.1007/s10462-020-09838-1.
- [86] I. Sutskever, O. Vinyals, and Q. V. Le, ‘Sequence to Sequence Learning with Neural Networks’, Dec. 14, 2014, *arXiv*: arXiv:1409.3215. doi: 10.48550/arXiv.1409.3215.
- [87] **M. Kołodziej, M. Jurczak, A. Majkowski, A. Rysz, and B. Świdorski, ‘A Hybrid CNN-LSTM Approach for Muscle Artifact Removal from EEG Using Additional EMG Signal Recording’, *Applied Sciences*, vol. 15, no. 9, Art. no. 9, Jan. 2025, doi: 10.3390/app15094953.**
- [88] **M. Jurczak, M. Kołodziej, and A. Majkowski, ‘Implementation of a Convolutional Neural Network for Eye Blink Artifacts Removal From the Electroencephalography Signal’, *Frontiers in Neuroscience*, vol. 16, 2022, Accessed: Jul. 11, 2023. [Online]. Available: <https://www.frontiersin.org/articles/10.3389/fnins.2022.782367>**
- [89] **M. Jurczak, M. Kołodziej, and A. Majkowski, ‘Implementation of Convolutional Neural Network for Artifact Removal from EEG Signals’, in *2023 24th International Conference on Computational Problems of Electrical Engineering (CPEE)*, Sep. 2023, pp. 1–4. doi: 10.1109/CPEE59623.2023.10285322.**
- [90] J. Urigüen and B. Zapiain, ‘EEG artifact removal – State-of-the-art and guidelines’, *Journal of neural engineering*, vol. 12, p. 031001, Apr. 2015, doi: 10.1088/1741-2560/12/3/031001.
- [91] R. Ranjan, B. Chandra Sahana, and A. Kumar Bhandari, ‘Ocular artifact elimination from electroencephalography signals: A systematic review’, *Biocybernetics and Biomedical Engineering*, vol. 41, no. 3, pp. 960–996, Jul. 2021, doi: 10.1016/j.bbe.2021.06.007.
- [92] J. Cheng *et al.*, ‘Remove Diverse Artifacts Simultaneously From a Single-Channel EEG Based on SSA and ICA: A Semi-Simulated Study’, *IEEE Access*, vol. 7, p. 2019, May 2019, doi: 10.1109/ACCESS.2019.2915564.
- [93] **M. Jurczak, M. Kołodziej, and A. Majkowski, ‘Comparison of Independent Component Analysis, Linear Regression and Adaptive Filtering for Artifact Removal in SSVEP Registration’, *PRZEGLĄD ELEKTROTECHNICZNY*, vol. 1, Apr. 2024, doi: 10.15199/48.2024.05.54.**
- [94] V. Çetin, S. Ozekes, and H. S. Varol, ‘Harmonic analysis of steady-state visual evoked potentials in brain computer interfaces’, *Biomedical Signal Processing and Control*, vol. 60, p. 101999, Jul. 2020, doi: 10.1016/j.bspc.2020.101999.
- [95] N. Siribunyaphat and Y. Punsawad, ‘Steady-State ,Visual Evoked Potential-Based Brain–Computer Interface Using a Novel Visual Stimulus with Quick Response (QR) Code Pattern’, *Sensors*, vol. 22, no. 4, Art. no. 4, Jan. 2022, doi: 10.3390/s22041439.

- [96] **M. Kołodziej, M. Jurczak, and A. Majkowski, ‘Study of the Impact of Physiological Artifacts on SSVEP Acquisition’, *IEEE Sensors Letters*, vol. 7, no. 6, pp. 1–4, Jun. 2023, doi: 10.1109/LENS.2023.3278031.**
- [97] Y.-P. Lin, Y. Wang, and T.-P. Jung, ‘Assessing the feasibility of online SSVEP decoding in human walking using a consumer EEG headset’, *J Neuroeng Rehabil*, vol. 11, p. 119, Aug. 2014, doi: 10.1186/1743-0003-11-119.
- [98] M. Azhar, T. Shafique, and A. Amjad, ‘A Convolutional Neural Network for the Removal of Simultaneous Ocular and Myogenic Artifacts from EEG Signals’, *Electronics*, vol. 13, no. 22, Art. no. 22, Jan. 2024, doi: 10.3390/electronics13224576.
- [99] C. Yu *et al.*, *A Joint SSA and CNN Algorithm to Remove EMG Artifacts from Single Channel EEG*. 2021, p. 6. doi: 10.1109/CISP-BMEI53629.2021.9624216.
- [100] R. Jiang *et al.*, ‘A novel EEG artifact removal algorithm based on an advanced attention mechanism’, *Sci Rep*, vol. 15, no. 1, p. 19419, Jun. 2025, doi: 10.1038/s41598-025-98653-1.

8. Załączniki

8.1. Formularz zgody na udział w badaniu

Załącznik zawiera formularz zgody podpisywany przez każdego z uczestników przed przystąpieniem do udziału w badaniu.

Formularz zgody na udział w badaniu

Tytuł badania: Nowoczesne metody eliminacji artefaktów z sygnału EEG

Cel badania: Celem badania jest rejestracja baz danych zawierających sygnały EEG wraz z artefaktami EOG i EMG. Pomiary dokonane zostaną z wykorzystaniem czepek EEG z elektrodami i wzmacniacza sygnałów g.USBamp firmy g.Tec. W celu umieszczenia elektrod na głowie badanego planowane jest użycie żelu przewodzącego. Akwizycja odbędzie się z wykorzystaniem przygotowanego do tego celu stanowiska z monitorem do prezentacji bodźców o określonej częstotliwości. Pozwoli to na rejestrację potencjałów wywołanych SSVEP.

Opis procedury:

Uczestnikowi zostanie założony czepki EEG oraz elektrody na twarzy. W celu uzyskania kontaktu skóra-elektroda, zostanie zastosowany zmywalny żel przewodzący. Sygnały będą rejestrowane przy użyciu wzmacniacza sygnałów g.USBamp podłączonego do komputera. Podczas sesji, uczestnik będzie obserwował monitor, na którym będą prezentowane bodźce wizualne o określonej częstotliwości. Kilukrotnie użytkownik zostanie poproszony o wykonanie artefaktów takich jak zaciśnięcie szczęki i sztuczny uśmiech.

Niedogodności:

Przeprowadzenie badań może wiązać się z niewielkim dyskomfortem użytkownika. Może być on związany z nanoszeniem żelu na skórę, zapinaniem czepek oraz przyklejaniem i odklejaniem elektrod z twarzy. Oglądanie wyświetlanych na monitorze obrazów może powodować chwilowe zmęczenie oczu.

Oświadczenie Uczestnika:

Ja, niżej podpisany/a, dobrowolnie zgadzam się na udział w powyższym badaniu. Oświadczam, że zostałem/am poinformowany/a o celu, procedurach badania oraz o możliwych dolegliwościach związanych z uczestnictwem w badaniu. Zostałem/am również poinformowany/a o prawie do wycofania się z badania w dowolnym momencie bez podania przyczyny i bez negatywnych konsekwencji.

Oświadczam również, że:

Nie posiadam znanych mi chorób neurologicznych.

Nie jestem pod wpływem alkoholu ani żadnych środków odurzających.

Rozumiem, że moje dane osobowe będą przetwarzane w celach badawczych, z zachowaniem poufności i anonimowości, zgodnie z obowiązującymi przepisami o ochronie danych osobowych.

Imię i Nazwisko Uczestnika:

Data i Podpis Uczestnika:

8.2. Kody źródłowe modeli CNN-LSTM (Python)

Załącznik zawiera kody źródłowe implementacji testowanych modeli CNN-LSTM wykorzystanych w eksperymentach. Modele zostały zaimplementowane w języku Python z użyciem bibliotek do głębokiego uczenia: *tensorflow* w wersji 2.10.1 oraz *keras* w wersji 2.10.0.

Model 1

```
model = Sequential()
model.add(Conv2D(128, kernel_size=(1, 6), activation='relu', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=1, activation='relu'))
model.add(Reshape((256, 256*1)))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 2

```
model = Sequential()
model.add(Conv2D(128, kernel_size=(1, 6), activation='relu', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=1, activation='relu'))
model.add(Reshape((256, 256*1)))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 3

```
model = Sequential()
model.add(Conv2D(128, kernel_size=(1, 6), activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 128*1)))
model.add(Conv1D(256, kernel_size=6, activation='relu', padding='same'))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 4

```
model = Sequential()
model.add(Conv2D(128, kernel_size=(16, 6), activation='relu', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=1, activation='relu'))
```

```

model.add(Reshape((256, 241*1)))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```

Model 5

```

model = Sequential()
model.add(Conv2D(128, kernel_size=(1, 6), activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 128*1)))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```

Model 6

```

model = Sequential()
model.add(Conv2D(128, kernel_size=(1, 6), activation='relu', input_shape=(256, 6, 1)))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```

Model 7

```

model = Sequential()
model.add(Conv2D(64, kernel_size=(32, 6), activation='relu', input_shape=(256, 6, 1), padding='same'))
model.add(Reshape((256, 384*1)))
model.add(LSTM(1, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```

Model 8

```

model = Sequential()
model.add(Conv2D(128, kernel_size=(1, 6), activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 128*1)))
model.add(Conv1D(256, kernel_size=64, activation='relu', padding='same'))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```


Model 9

```
model = Sequential()
model.add(Conv2D(128, kernel_size=(16, 6), activation='relu', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=32, activation='relu', padding='same'))
model.add(Reshape((241, 256*1)))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 10

```
model = Sequential()
model.add(Conv1D(256, kernel_size=1, activation='relu', input_shape=(256, 6, 1)))
model.add(Conv2D(128, kernel_size=(1, 6), activation='relu'))
model.add(Reshape((256, 128*1)))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 11

```
model = Sequential()
model.add(Conv1D(256, kernel_size=1, activation='relu', input_shape=(256, 6, 1)))
model.add(Conv2D(128, kernel_size=(1, 6), activation='relu'))
model.add(Reshape((256, 128*1)))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 12

```
model = Sequential()
model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 256)))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 13

```
model = Sequential()
```

```

model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```

Model 14

```

model = Sequential()
model.add(Conv1D(128, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 128*1)))
model.add(LSTM(256, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```

Model 15

```

model = Sequential()
model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 256)))
model.add(LSTM(16, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```

Model 16

```

model = Sequential()
model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 256)))
model.add(LSTM(256, return_sequences=True))
model.add(GlobalAveragePooling1D())
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')

```

Model 17

```

model = Sequential()
model.add(Conv2D(32, kernel_size=(32, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 256*1)))
model.add(LSTM(16, return_sequences=True))
model.add(Flatten())

```

```
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 18

```
model = Sequential()
model.add(Conv2D(256, kernel_size=(32, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 256*1)))
model.add(LSTM(16, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 19

```
model = Sequential()
model.add(Conv2D(32, kernel_size=(16, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 256*1)))
model.add(LSTM(16, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 20

```
model = Sequential()
model.add(Conv2D(32, kernel_size=(16, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(128, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 128*1)))
model.add(LSTM(16, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 21

```
model = Sequential()
model.add(Conv2D(32, kernel_size=(32, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(128, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 128*1)))
model.add(LSTM(16, return_sequences=True))
model.add(Flatten())
```

```
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 22

```
model = Sequential()
model.add(Conv2D(32, kernel_size=(8, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(128, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 128*1)))
model.add(LSTM(16, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 23

```
model = Sequential()
model.add(Conv2D(32, kernel_size=(32, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=6, activation='relu'))
model.add(Reshape((256, 256*1)))
model.add(Conv1D(256, kernel_size=6, activation='relu', padding='same'))
model.add(LSTM(16, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 24

```
model = Sequential()
model.add(Conv2D(32, kernel_size=(32, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 256*1)))
model.add(LSTM(8, return_sequences=True))
model.add(Flatten())
model.add(Dense(256, activation='linear'))
model.compile(optimizer='adam', loss='mean_squared_error')
```

Model 25

```
model = Sequential()
model.add(Conv2D(32, kernel_size=(32, 6), activation='relu', padding='same', input_shape=(256, 6, 1)))
model.add(Conv1D(256, kernel_size=6, activation='relu', input_shape=(256, 6, 1)))
model.add(Reshape((256, 256*1)))
model.add(LSTM(1, return_sequences=True))
```

```
model.add(Flatten())  
model.add(Dense(256, activation='linear'))  
model.compile(optimizer='adam', loss='mean_squared_error')
```

8.3. Szczegółowe wartości wyznaczonych współczynników SNR_{SSVEP}

Załącznik zawiera szczegółowe dane współczynnika SNR_{SSVEP} dla wszystkich elektrod i sygnałów EEG. Uwzględniono trzy warianty danych: okna z artefaktami, bez artefaktów oraz całe przebiegi.

Elektroda O1 – okna bez artefaktów

Sesja	SSVEP	Przed oczyszczaniem	CNN-LSTM	LR	ICA	LMS	RLS	Filtracja bipolarna
S01	7	1,67	1,71	1,69	1,83	1,74	1,71	1,30
S02	7	0,95	1,00	0,95	1,05	1,02	1,02	0,70
S03	6	1,74	1,77	2,28	1,94	2,13	2,34	4,72
S04	7	1,55	1,62	1,73	1,59	1,82	1,83	2,64
S05	8	1,36	1,31	1,55	1,34	1,46	1,47	1,60
S06	8	2,09	2,10	2,19	2,22	2,18	2,23	1,49
S07	7	1,46	1,52	1,61	1,60	1,48	1,57	1,39
S08	8	1,08	1,14	1,15	1,12	1,09	1,12	0,90
S09	6	1,96	1,99	1,98	2,06	2,00	2,06	0,53
S10	6	2,02	2,01	1,79	2,09	1,96	2,01	0,59
S11	6	2,48	2,52	2,33	2,64	2,58	2,53	0,64
S12	6	2,40	2,42	2,22	2,44	2,39	2,61	0,56
S13	7	1,67	1,69	1,77	1,81	1,84	1,83	0,47
S14	8	1,29	1,35	1,31	1,36	1,30	1,28	0,63
S15	6	1,14	1,15	1,32	1,19	1,37	1,22	1,25
S16	7	1,91	1,95	2,08	2,03	2,04	1,88	1,36
S17	8	1,43	1,50	1,52	1,83	1,70	1,78	0,93
S18	7	2,74	2,72	2,88	0,93	2,92	3,07	2,59
S19	8	3,42	3,46	3,54	3,90	3,33	3,60	2,72
S20	7	1,49	1,48	2,02	1,22	2,19	1,97	2,92
S21	8	2,60	2,62	2,57	2,42	2,57	2,72	3,78
S22	25	2,54	2,55	2,99	2,82	2,76	3,01	2,23
S23	25	2,83	2,83	3,15	1,52	3,03	3,31	2,18
S24	25	3,30	3,27	3,49	3,29	3,34	3,42	1,97
S25	7	1,37	1,36	1,45	1,57	1,36	1,45	0,97
S26	8	1,24	1,27	1,38	1,27	1,18	1,27	1,42
S27	9	1,71	1,98	2,00	1,82	1,80	1,91	1,71
S28	25	1,39	1,40	1,38	1,43	1,44	1,41	1,20
S29	7	2,79	2,77	2,60	2,99	2,80	2,77	3,02
S30	8	3,12	3,15	3,18	3,38	3,29	3,41	3,10
S31	9	2,88	2,96	3,04	3,18	2,98	2,97	3,17
S32	25	1,17	1,14	1,22	1,14	1,15	1,17	2,82
S33	7	2,25	2,29	2,42	2,21	2,30	2,26	1,41
S34	8	2,23	2,29	2,23	2,31	2,23	2,25	1,32
S35	9	2,40	2,52	2,37	2,49	2,37	2,35	1,43

S36	25	1,54	1,49	1,56	1,54	1,58	1,60	1,31
S37	7	2,74	2,70	2,70	2,80	2,69	2,85	4,02
S38	8	2,59	2,59	2,27	2,72	2,64	2,55	3,83
S39	9	4,00	4,02	3,83	4,02	3,99	4,03	5,92
S40	25	1,68	1,64	1,73	1,67	1,75	1,81	3,00
S41	7	2,28	2,28	2,20	2,31	2,25	2,23	0,94
S42	8	2,41	2,51	2,51	2,52	2,50	2,59	1,27
S43	9	2,53	2,61	2,58	2,67	2,69	2,68	1,26
S44	25	1,73	1,67	1,71	1,73	1,80	1,79	1,25
S45	7	1,37	1,35	1,34	1,24	1,34	1,30	1,21
S46	8	1,98	2,08	1,80	1,92	1,95	1,85	1,38
S47	9	2,24	2,32	2,45	2,66	2,54	2,49	1,92
S48	25	1,58	1,58	1,65	1,66	1,65	1,67	1,70

Elektroda O1 – okna z artefaktami

Sesja	SSVEP	Przed oczyszczaniem	CNN-LSTM	LR	ICA	LMS	RLS	Filtracja bipolarna
S01	7	1,00	1,77	1,55	1,33	1,30	1,37	1,21
S02	7	0,58	0,95	0,61	0,77	0,63	0,72	0,79
S03	6	1,01	1,33	1,55	1,28	1,39	1,45	3,83
S04	7	1,09	1,60	1,25	1,15	1,46	1,52	2,60
S05	8	0,97	1,32	1,20	0,98	1,20	1,29	1,64
S06	8	0,72	1,36	1,12	0,97	0,83	1,03	1,26
S07	7	0,96	1,63	1,39	1,19	1,18	1,32	1,20
S08	8	0,61	0,99	0,92	0,72	0,78	0,90	1,00
S09	6	1,17	1,83	1,64	1,42	1,42	1,46	0,60
S10	6	0,96	1,83	1,45	1,40	1,39	1,67	0,68
S11	6	1,04	1,51	1,48	1,27	1,35	1,50	0,40
S12	6	1,73	2,30	2,28	2,03	2,11	2,20	0,59
S13	7	1,11	1,79	1,55	1,34	1,41	1,54	0,55
S14	8	0,78	1,14	1,09	0,91	0,89	0,90	0,63
S15	6	0,83	2,27	1,25	1,03	1,04	1,16	1,03
S16	7	0,91	2,14	2,00	1,41	1,53	1,75	0,99
S17	8	0,73	1,92	1,69	1,52	1,24	1,37	0,83
S18	7	1,14	2,02	1,50	0,63	1,33	1,50	1,97
S19	8	2,34	3,75	3,73	3,53	2,83	3,55	2,70
S20	7	0,99	1,55	1,46	0,63	1,45	1,74	2,39
S21	8	1,43	2,20	2,20	1,58	1,90	2,26	3,89
S22	25	1,23	1,92	1,88	1,75	1,80	2,12	1,53
S23	25	0,77	1,45	1,42	1,30	1,28	1,33	1,56
S24	25	1,15	1,79	1,53	1,07	1,39	1,48	1,30
S25	7	1,75	1,92	1,86	1,75	1,67	1,77	1,42
S26	8	1,45	1,61	1,65	1,54	1,48	1,56	1,05
S27	9	1,80	1,82	1,71	1,74	1,72	1,75	1,84
S28	25	1,68	1,67	1,64	1,71	1,63	1,59	1,01
S29	7	2,11	2,93	2,90	2,57	2,27	2,54	2,98
S30	8	2,11	2,98	3,08	2,51	2,39	2,52	3,91
S31	9	2,04	3,33	2,99	2,84	2,59	2,85	2,46
S32	25	0,83	1,10	1,19	0,93	1,09	1,19	2,42
S33	7	1,55	2,12	1,78	1,68	1,77	1,73	1,19
S34	8	1,40	2,23	1,69	1,44	1,74	1,72	1,10
S35	9	1,36	2,61	1,88	1,65	1,78	1,76	0,92
S36	25	1,18	1,08	1,43	1,12	1,33	1,43	1,45
S37	7	3,18	3,70	3,79	3,21	3,26	3,51	4,02
S38	8	2,61	3,13	3,04	2,67	2,75	2,84	4,17
S39	9	2,52	3,13	3,30	2,69	2,86	2,99	5,68
S40	25	1,26	1,33	1,36	1,28	1,29	1,42	2,96
S41	7	1,47	2,11	1,73	1,71	1,78	1,87	1,10
S42	8	1,35	2,12	1,48	1,51	1,62	1,64	0,99

S43	9	2,34	2,91	2,69	2,55	2,64	2,81	1,21
S44	25	1,42	1,32	1,33	1,32	1,27	1,32	1,26
S45	7	0,55	1,28	0,74	0,63	0,77	0,84	1,41
S46	8	0,65	1,95	1,21	0,88	1,23	1,35	1,77
S47	9	0,64	1,87	1,25	0,99	1,25	1,26	1,79
S48	25	1,11	1,52	1,55	1,41	1,62	1,74	1,61

Elektroda O1 – cały sygnał

Sesja	SSVEP	Przed oczyszczaniem	CNN-LSTM	LR	ICA	LMS	RLS	Filtracja bipolarna
S01	7	1,30	1,67	1,61	1,56	1,51	1,55	1,28
S02	7	0,99	1,14	1,04	1,12	1,01	1,07	0,77
S03	6	1,74	1,91	2,07	1,85	1,98	2,06	4,47
S04	7	1,17	1,39	1,42	1,23	1,48	1,52	2,44
S05	8	1,26	1,40	1,55	1,26	1,45	1,41	1,75
S06	8	1,16	1,55	1,44	1,35	1,37	1,44	1,32
S07	7	1,20	1,60	1,58	1,44	1,47	1,61	1,27
S08	8	0,87	1,13	1,14	0,99	1,04	1,13	0,98
S09	6	1,60	1,89	1,79	1,79	1,75	1,81	0,54
S10	6	1,77	2,15	1,94	2,05	2,01	2,10	0,65
S11	6	1,73	2,03	1,88	1,95	1,96	2,03	0,56
S12	6	2,24	2,42	2,31	2,37	2,35	2,43	0,61
S13	7	1,54	1,74	1,69	1,70	1,66	1,71	0,56
S14	8	1,03	1,17	1,23	1,13	1,10	1,16	0,55
S15	6	1,18	1,59	1,47	1,39	1,45	1,47	1,13
S16	7	1,30	1,92	2,03	1,74	1,90	1,89	1,26
S17	8	1,12	1,51	1,58	1,61	1,46	1,57	1,06
S18	7	2,14	2,47	2,42	0,95	2,26	2,44	2,29
S19	8	2,71	3,33	3,36	3,54	2,92	3,27	2,55
S20	7	1,22	1,47	1,81	0,86	1,79	1,87	2,77
S21	8	2,01	2,41	2,52	2,07	2,40	2,52	3,58
S22	25	1,83	2,26	2,34	2,20	2,23	2,46	1,86
S23	25	1,24	2,21	2,20	1,48	2,03	2,22	1,93
S24	25	1,82	2,59	2,46	2,04	2,26	2,34	1,61
S25	7	1,40	1,41	1,51	1,58	1,43	1,49	1,14
S26	8	1,30	1,35	1,39	1,32	1,27	1,34	1,21
S27	9	1,74	1,84	1,79	1,76	1,76	1,81	1,80
S28	25	1,34	1,35	1,35	1,35	1,31	1,32	1,19
S29	7	2,53	2,78	2,74	2,83	2,64	2,71	2,95
S30	8	2,95	3,33	3,30	3,31	3,12	3,22	3,84
S31	9	2,40	2,84	2,75	2,79	2,61	2,75	2,95
S32	25	1,11	1,23	1,28	1,18	1,23	1,30	2,49
S33	7	1,90	2,16	2,07	1,97	1,97	1,95	1,15
S34	8	1,90	2,35	2,07	1,99	2,09	2,08	1,13
S35	9	2,06	2,73	2,37	2,24	2,32	2,30	1,20
S36	25	1,46	1,46	1,49	1,45	1,54	1,60	1,32
S37	7	3,11	3,19	3,26	3,11	3,11	3,22	4,01
S38	8	2,61	2,72	2,58	2,68	2,67	2,62	4,08
S39	9	3,12	3,38	3,34	3,18	3,27	3,31	5,87
S40	25	1,64	1,66	1,64	1,65	1,66	1,68	3,10
S41	7	1,82	2,10	1,93	1,95	1,98	2,00	0,93
S42	8	1,82	2,24	1,99	1,96	2,00	2,03	1,10

S43	9	2,47	2,77	2,68	2,65	2,67	2,77	1,28
S44	25	1,58	1,57	1,58	1,58	1,60	1,59	1,28
S45	7	0,88	1,25	0,96	0,95	1,06	1,04	1,20
S46	8	1,14	2,09	1,58	1,43	1,70	1,74	1,49
S47	9	1,35	2,41	1,94	1,82	1,89	1,99	1,80
S48	25	1,21	1,49	1,57	1,48	1,65	1,69	1,66

Elektroda Oz – okna bez artefaktów

Sesja	SSVEP	Przed oczyszczaniem	CNN- LSTM	LR	ICA	LMS	RLS	Filtracja bipolarna	Filtracja Laplace'a
S01	7	2,53	2,59	2,64	2,74	2,71	2,68	0,76	1,33
S02	7	1,07	1,03	1,08	1,18	1,16	1,20	0,80	0,88
S03	6	3,38	3,39	4,23	3,81	4,00	4,45	2,06	5,03
S04	7	2,54	2,61	2,99	2,63	3,17	3,23	1,19	3,24
S05	8	1,73	1,69	2,24	1,75	2,14	2,24	1,51	2,07
S06	8	2,57	2,59	2,67	2,71	2,72	2,78	1,14	1,49
S07	7	1,92	2,00	2,19	2,14	2,07	2,21	0,65	1,11
S08	8	1,52	1,60	1,62	1,64	1,64	1,69	0,61	0,97
S09	6	2,48	2,51	2,58	2,66	2,60	2,67	1,35	1,25
S10	6	2,11	2,11	1,93	2,19	2,07	2,14	1,50	1,42
S11	6	3,50	3,52	3,28	3,76	3,72	3,65	1,38	1,34
S12	6	3,26	3,27	3,04	3,28	3,25	3,54	1,39	1,21
S13	7	2,49	2,55	2,72	2,72	2,79	2,84	1,20	0,93
S14	8	1,63	1,69	1,72	1,76	1,77	1,79	0,89	0,75
S15	6	1,33	1,30	1,47	1,45	1,57	1,52	1,99	2,11
S16	7	2,22	2,24	2,47	2,41	2,46	2,39	1,24	1,89
S17	8	1,97	2,02	2,28	2,82	2,48	2,59	1,64	1,60
S18	7	2,74	2,73	3,19	2,87	3,10	3,25	2,37	3,53
S19	8	3,74	3,74	3,97	4,24	3,83	4,09	2,95	2,69
S20	7	2,41	2,40	3,30	2,42	3,29	3,14	3,99	5,73
S21	8	3,53	3,55	3,68	3,54	3,73	3,87	4,50	6,24
S22	25	2,87	2,86	3,20	3,14	3,11	3,12	2,94	2,41
S23	25	2,50	2,48	2,74	2,67	2,74	2,80	3,13	2,55
S24	25	2,30	2,27	2,35	2,19	2,37	2,32	3,07	2,44
S25	7	3,20	3,18	3,19	3,24	3,20	3,35	1,18	1,50
S26	8	2,80	2,78	3,00	2,82	2,90	3,15	1,36	1,76
S27	9	3,17	3,95	4,22	3,21	3,64	4,16	1,42	1,97
S28	25	2,18	2,16	2,34	2,37	2,38	2,44	1,45	1,20
S29	7	4,96	4,90	4,82	5,27	5,03	5,09	1,76	3,80
S30	8	5,57	5,54	5,41	5,81	5,87	5,96	1,21	3,18
S31	9	5,81	5,88	5,75	6,31	5,97	6,06	1,56	4,37
S32	25	3,27	3,14	3,31	3,32	3,36	3,43	1,18	3,23
S33	7	2,07	2,14	2,22	2,03	2,09	2,07	1,88	1,36
S34	8	1,95	2,02	1,97	2,08	1,93	1,95	2,26	1,85
S35	9	2,06	2,16	2,06	2,20	2,03	2,03	2,32	1,94
S36	25	1,57	1,51	1,55	1,63	1,66	1,68	1,30	1,32
S37	7	4,22	4,15	4,21	4,25	4,37	4,65	1,77	5,00
S38	8	4,82	4,78	4,47	5,20	4,93	5,04	1,86	4,88
S39	9	7,18	7,17	6,90	7,25	7,21	7,22	2,64	5,77
S40	25	3,63	3,48	3,80	3,84	3,77	3,93	1,49	3,63
S41	7	2,07	2,10	1,93	2,08	2,04	2,04	2,17	1,73

S42	8	2,35	2,47	2,50	2,44	2,40	2,50	1,96	1,55
S43	9	2,09	2,15	2,20	2,13	2,24	2,26	2,36	1,72
S44	25	1,41	1,35	1,50	1,47	1,57	1,60	1,47	1,36
S45	7	2,10	2,10	2,01	2,00	2,03	1,97	0,90	1,69
S46	8	2,26	2,33	2,05	2,25	2,19	2,14	0,80	1,66
S47	9	2,90	3,03	3,09	3,33	3,18	3,11	1,22	2,14
S48	25	2,60	2,60	2,76	2,72	2,69	2,69	1,42	2,32

Elektroda Oz – okna z artefaktami

Sesja	SSVEP	Przed oczyszczaniem	CNN- LSTM	LR	ICA	LMS	RLS	Filtracja bipolarna	Filtracja Laplace'a
S01	7	1,13	2,21	2,03	1,57	1,68	1,89	0,88	1,18
S02	7	0,61	1,07	0,69	0,90	0,70	0,80	0,94	1,01
S03	6	1,70	2,23	2,35	2,06	2,18	2,27	1,29	3,57
S04	7	1,55	2,23	1,79	1,66	2,08	2,23	1,60	2,70
S05	8	1,12	1,54	1,40	1,13	1,33	1,48	1,22	2,09
S06	8	0,78	1,58	1,20	1,12	1,01	1,25	0,77	1,09
S07	7	1,06	2,02	1,73	1,40	1,46	1,70	0,62	1,20
S08	8	0,71	1,27	1,19	1,04	1,02	1,22	0,91	1,34
S09	6	1,37	2,24	1,94	1,72	1,68	1,71	1,05	0,97
S10	6	1,05	1,98	1,59	1,53	1,50	1,83	1,49	1,42
S11	6	1,24	1,96	1,78	1,61	1,67	1,85	1,27	1,22
S12	6	2,22	3,03	2,99	2,59	2,73	2,88	1,59	1,44
S13	7	1,38	2,46	2,14	1,79	1,95	2,20	1,32	0,94
S14	8	0,91	1,39	1,22	1,10	1,13	1,19	0,81	0,65
S15	6	0,80	2,26	1,17	0,98	0,92	1,17	2,17	1,50
S16	7	0,89	2,27	2,25	1,25	1,63	1,90	1,47	1,32
S17	8	0,78	2,28	2,02	1,81	1,44	1,83	1,45	1,07
S18	7	1,43	2,51	2,07	1,50	1,64	1,85	1,07	1,80
S19	8	2,52	4,06	4,09	3,73	3,07	3,89	2,25	2,66
S20	7	1,33	2,24	2,19	1,33	1,97	2,25	3,82	4,80
S21	8	1,96	3,06	3,02	2,38	2,58	3,06	3,95	5,92
S22	25	0,94	1,67	1,44	1,45	1,38	1,80	2,11	1,73
S23	25	0,67	1,32	1,11	0,85	0,98	0,97	2,07	1,74
S24	25	0,92	1,51	1,14	0,85	1,03	1,08	1,95	1,51
S25	7	3,60	4,16	3,94	3,69	3,65	3,90	1,37	2,30
S26	8	2,75	3,08	3,36	2,79	2,98	3,35	1,53	1,79
S27	9	4,64	4,69	4,52	4,64	4,63	4,64	1,59	2,26
S28	25	2,12	2,23	2,32	2,19	2,10	2,24	1,46	1,06
S29	7	3,10	4,61	4,52	3,89	3,55	4,20	1,52	4,26
S30	8	3,42	5,18	5,50	4,23	4,06	4,70	1,71	4,88
S31	9	2,73	4,85	4,72	4,28	3,76	4,57	1,99	3,45
S32	25	1,48	2,15	2,57	1,81	2,04	2,40	1,53	2,84
S33	7	1,60	2,19	1,72	1,71	1,74	1,70	1,87	1,47
S34	8	1,31	2,06	1,60	1,32	1,64	1,63	2,17	1,77
S35	9	1,27	2,43	1,75	1,53	1,62	1,61	1,79	1,63
S36	25	1,26	1,19	1,46	1,32	1,33	1,50	1,61	1,22
S37	7	3,97	4,63	4,85	3,99	4,12	4,62	1,73	4,46
S38	8	3,66	4,32	4,26	3,97	3,83	4,09	1,83	5,22
S39	9	4,16	5,30	5,39	4,57	4,72	5,21	1,99	6,07
S40	25	2,45	2,63	3,00	2,68	2,61	3,01	1,88	3,31
S41	7	1,48	2,06	1,68	1,65	1,67	1,75	2,17	1,58

S42	8	1,35	2,08	1,50	1,51	1,63	1,66	1,75	1,42
S43	9	2,31	2,84	2,58	2,39	2,58	2,69	2,14	1,62
S44	25	1,37	1,39	1,35	1,35	1,37	1,44	1,36	1,20
S45	7	0,83	2,06	1,15	1,06	1,24	1,33	0,86	2,15
S46	8	0,79	2,37	1,51	1,03	1,50	1,66	0,96	1,88
S47	9	0,77	2,31	1,52	1,23	1,55	1,58	1,07	2,16
S48	25	1,20	1,77	1,88	1,65	2,00	2,12	1,16	1,82

Elektroda Oz – cały sygnał

Sesja	SSVEP	Przed oczyszczaniem	CNN- LSTM	LR	ICA	LMS	RLS	Filtracja bipolarna	Filtracja Laplace'a
S01	7	1,70	2,34	2,32	2,10	2,18	2,29	0,85	1,23
S02	7	1,00	1,18	1,08	1,19	1,10	1,14	0,88	0,83
S03	6	2,99	3,33	3,58	3,30	3,49	3,69	1,68	4,71
S04	7	1,92	2,25	2,36	2,03	2,50	2,64	1,47	2,89
S05	8	1,48	1,67	1,88	1,50	1,80	1,83	1,40	2,06
S06	8	1,40	1,90	1,78	1,65	1,71	1,80	0,96	1,21
S07	7	1,49	2,08	2,08	1,85	1,94	2,15	0,71	1,22
S08	8	1,10	1,49	1,51	1,36	1,40	1,53	0,73	1,16
S09	6	1,96	2,36	2,26	2,25	2,21	2,30	1,21	1,06
S10	6	1,91	2,30	2,10	2,21	2,16	2,29	1,37	1,27
S11	6	2,22	2,73	2,50	2,59	2,64	2,74	1,35	1,25
S12	6	2,92	3,20	3,08	3,13	3,11	3,26	1,62	1,35
S13	7	2,12	2,57	2,47	2,48	2,48	2,58	1,31	0,98
S14	8	1,25	1,43	1,49	1,39	1,40	1,50	0,85	0,71
S15	6	1,29	1,93	1,70	1,63	1,69	1,75	1,81	1,79
S16	7	1,35	2,17	2,38	1,72	2,11	2,22	1,50	1,84
S17	8	1,30	2,03	2,20	2,33	2,00	2,23	1,40	1,45
S18	7	2,51	2,94	3,09	2,70	2,79	3,07	2,06	2,86
S19	8	3,25	3,97	4,12	4,09	3,59	4,03	2,32	2,57
S20	7	1,93	2,44	2,94	1,94	2,71	2,91	3,89	5,26
S21	8	2,74	3,30	3,49	3,03	3,31	3,53	4,10	5,92
S22	25	1,64	2,28	2,21	2,13	2,10	2,37	2,44	2,01
S23	25	1,05	2,00	1,93	1,59	1,79	1,88	2,60	2,20
S24	25	1,33	1,94	1,75	1,46	1,65	1,65	2,47	1,93
S25	7	3,08	3,16	3,34	3,11	3,32	3,45	1,20	1,80
S26	8	2,76	2,83	2,97	2,78	2,87	3,10	1,25	1,70
S27	9	3,96	4,25	4,27	4,00	4,22	4,46	1,40	2,25
S28	25	2,15	2,16	2,25	2,21	2,16	2,24	1,25	1,29
S29	7	4,27	4,84	4,76	4,80	4,62	4,89	1,87	3,98
S30	8	5,09	5,89	5,79	5,69	5,53	5,82	1,67	4,48
S31	9	4,26	5,40	5,18	5,27	4,93	5,42	1,57	4,03
S32	25	2,41	2,77	2,98	2,64	2,78	3,01	1,33	2,88
S33	7	1,81	2,04	1,94	1,86	1,88	1,84	1,87	1,37
S34	8	1,66	2,00	1,83	1,75	1,85	1,84	2,29	1,72
S35	9	1,77	2,33	2,05	1,94	1,97	1,96	2,03	1,75
S36	25	1,44	1,45	1,48	1,44	1,53	1,62	1,49	1,31
S37	7	4,21	4,32	4,51	4,24	4,32	4,57	1,48	4,80
S38	8	4,23	4,38	4,26	4,54	4,33	4,44	1,83	4,93
S39	9	5,72	6,30	6,15	5,96	6,06	6,29	2,04	6,08
S40	25	3,30	3,35	3,54	3,48	3,43	3,61	1,59	3,63
S41	7	1,68	1,90	1,77	1,76	1,80	1,82	2,20	1,58

S42	8	1,71	2,10	1,85	1,83	1,86	1,90	1,87	1,45
S43	9	2,18	2,44	2,35	2,23	2,35	2,44	2,28	1,68
S44	25	1,42	1,36	1,39	1,41	1,44	1,44	1,47	1,30
S45	7	1,30	1,95	1,52	1,51	1,60	1,64	0,85	1,72
S46	8	1,37	2,46	1,90	1,65	2,02	2,10	0,94	1,80
S47	9	1,61	2,92	2,33	2,22	2,32	2,44	1,03	1,90
S48	25	1,54	2,15	2,17	1,97	2,26	2,31	1,27	2,01

Elektroda O2 – okna bez artefaktów

Sesja	SSVEP	Przed oczyszczaniem	CNN- LSTM	LR	ICA	LMS	RLS
S01	7	2,89	2,97	3,06	3,02	3,12	3,12
S02	7	1,05	1,05	0,92	1,10	1,09	1,09
S03	6	2,57	2,58	3,09	2,95	2,98	3,24
S04	7	2,41	2,49	2,89	2,42	3,10	3,21
S05	8	1,64	1,55	2,25	1,66	2,00	2,21
S06	8	3,02	3,05	3,27	3,30	3,30	3,37
S07	7	1,99	2,07	2,35	2,27	2,20	2,36
S08	8	1,99	2,07	2,25	2,23	2,27	2,35
S09	6	2,02	2,07	2,15	2,21	2,22	2,28
S10	6	1,67	1,70	1,64	1,79	1,66	1,69
S11	6	2,83	2,88	2,66	3,09	3,05	3,02
S12	6	2,68	2,69	2,48	2,65	2,65	2,89
S13	7	2,49	2,56	2,74	2,70	2,75	2,81
S14	8	1,62	1,65	1,66	1,74	1,70	1,76
S15	6	1,75	1,76	1,88	1,93	2,11	1,90
S16	7	2,27	2,28	2,54	2,48	2,45	2,38
S17	8	2,23	2,30	2,43	3,20	2,76	2,93
S18	7	3,76	3,72	4,66	4,61	4,37	4,78
S19	8	5,13	5,10	5,83	5,69	5,33	5,98
S20	7	1,45	1,42	1,85	1,56	1,90	1,74
S21	8	2,19	2,22	2,33	2,38	2,25	2,39
S22	25	3,43	3,41	3,84	3,74	3,73	3,91
S23	25	3,10	3,09	3,37	3,25	3,30	3,49
S24	25	3,20	3,16	3,28	3,14	3,20	3,23
S25	7	3,80	3,74	3,91	4,22	3,88	4,07
S26	8	3,13	3,09	3,42	3,17	3,35	3,71
S27	9	3,17	4,00	4,22	3,55	3,66	4,19
S28	25	2,14	2,11	2,33	2,17	2,33	2,44
S29	7	6,00	5,88	5,92	6,47	6,15	6,27
S30	8	6,94	6,85	6,86	7,34	7,43	7,63
S31	9	7,45	7,53	7,40	8,35	7,76	7,84
S32	25	3,84	3,69	4,06	3,98	4,03	4,11
S33	7	1,71	1,72	1,76	1,62	1,64	1,62
S34	8	1,03	1,09	1,12	1,09	1,05	1,07
S35	9	1,18	1,23	1,22	1,29	1,19	1,19
S36	25	1,39	1,32	1,39	1,33	1,49	1,50
S37	7	4,68	4,57	4,78	4,73	4,98	5,41
S38	8	5,88	5,79	5,48	6,45	6,17	6,36
S39	9	7,94	7,94	7,80	8,10	8,12	8,24
S40	25	3,91	3,75	4,37	4,27	4,14	4,46
S41	7	1,59	1,59	1,45	1,58	1,53	1,52
S42	8	1,68	1,80	1,83	1,82	1,74	1,81

S43	9	1,26	1,33	1,39	1,33	1,39	1,53
S44	25	1,01	0,98	1,13	1,04	1,14	1,18
S45	7	1,70	1,73	1,63	1,64	1,69	1,64
S46	8	1,36	1,43	1,24	1,38	1,36	1,35
S47	9	1,99	2,09	2,13	2,23	2,17	2,13
S48	25	2,00	2,02	2,16	2,11	2,11	2,12

Elektroda O2 – okna z artefaktami

Sesja	SSVEP	Przed oczyszczaniem	CNN- LSTM	LR	ICA	LMS	RLS
S01	7	1,20	2,43	2,21	1,19	1,83	2,08
S02	7	0,58	1,09	0,78	0,92	0,83	0,94
S03	6	1,49	1,91	2,03	1,83	1,82	1,89
S04	7	1,61	2,30	1,88	1,67	2,16	2,28
S05	8	0,94	1,23	1,12	0,94	1,07	1,16
S06	8	0,78	1,69	1,28	1,22	1,05	1,32
S07	7	1,09	2,15	1,73	1,43	1,47	1,70
S08	8	0,80	1,70	1,54	1,20	1,32	1,56
S09	6	1,23	2,06	1,75	1,52	1,52	1,55
S10	6	0,78	1,58	1,28	1,24	1,18	1,50
S11	6	1,05	1,60	1,48	1,34	1,35	1,46
S12	6	2,01	2,79	2,67	2,28	2,44	2,59
S13	7	1,31	2,38	2,07	1,69	1,86	2,13
S14	8	0,87	1,32	1,21	1,09	1,11	1,21
S15	6	0,92	2,82	1,35	1,15	1,23	1,49
S16	7	0,99	2,55	2,43	1,42	1,82	2,10
S17	8	0,86	2,50	2,12	1,88	1,48	1,97
S18	7	1,54	2,72	2,29	1,61	1,67	2,19
S19	8	2,88	4,76	4,74	4,25	3,55	4,51
S20	7	0,92	1,46	1,46	1,04	1,22	1,44
S21	8	1,41	2,17	2,07	1,72	1,70	2,05
S22	25	1,14	2,10	1,96	1,82	1,83	2,27
S23	25	0,71	1,49	1,43	0,85	1,27	1,28
S24	25	1,05	1,85	1,47	1,08	1,33	1,42
S25	7	3,67	4,36	4,20	3,39	3,76	4,04
S26	8	2,48	2,79	3,20	2,51	2,77	3,16
S27	9	5,19	5,22	5,09	5,31	5,23	5,27
S28	25	1,90	2,03	2,11	1,87	1,90	2,07
S29	7	3,21	4,87	4,98	4,01	3,71	4,55
S30	8	3,68	5,74	6,48	4,62	4,54	5,63
S31	9	2,53	4,65	4,78	4,36	3,64	4,65
S32	25	1,57	2,30	2,85	1,93	2,24	2,67
S33	7	1,20	1,70	1,28	1,29	1,31	1,33
S34	8	1,12	1,64	1,32	1,16	1,34	1,34
S35	9	0,93	1,68	1,22	1,00	1,07	1,11
S36	25	1,35	1,22	1,48	1,38	1,35	1,60
S37	7	4,32	5,08	5,42	4,35	4,47	5,09
S38	8	4,01	4,81	4,73	4,37	4,27	4,67
S39	9	4,58	5,99	6,14	5,14	5,29	6,05
S40	25	2,74	3,03	3,50	3,07	2,94	3,52
S41	7	1,22	1,69	1,36	1,24	1,31	1,40
S42	8	1,13	1,69	1,21	1,24	1,33	1,33

S43	9	1,85	2,25	2,02	1,90	2,04	2,09
S44	25	1,23	1,16	1,23	1,22	1,28	1,32
S45	7	0,72	1,72	0,99	0,88	1,06	1,10
S46	8	0,78	2,06	1,38	1,02	1,36	1,47
S47	9	0,68	1,82	1,21	0,98	1,21	1,25
S48	25	1,07	1,55	1,63	1,48	1,75	1,81

Elektroda O2 – cały sygnał

Sesja	SSVEP	Przed oczyszczaniem	CNN- LSTM	LR	ICA	LMS	RLS
S01	7	1,89	2,68	2,64	1,92	2,51	2,66
S02	7	0,98	1,15	1,07	1,18	1,08	1,12
S03	6	2,35	2,60	2,73	2,58	2,68	2,77
S04	7	1,91	2,23	2,36	1,96	2,52	2,65
S05	8	1,34	1,50	1,67	1,37	1,60	1,59
S06	8	1,55	2,19	2,03	1,89	1,94	2,08
S07	7	1,53	2,17	2,18	1,93	2,01	2,24
S08	8	1,36	1,98	2,03	1,74	1,87	2,05
S09	6	1,67	2,00	1,97	1,93	1,89	1,97
S10	6	1,59	1,91	1,81	1,89	1,82	1,92
S11	6	1,79	2,19	2,05	2,12	2,12	2,21
S12	6	2,39	2,64	2,55	2,57	2,58	2,70
S13	7	1,97	2,41	2,38	2,34	2,36	2,46
S14	8	1,19	1,35	1,43	1,35	1,35	1,45
S15	6	1,54	2,40	2,17	1,99	2,13	2,23
S16	7	1,44	2,26	2,49	1,94	2,21	2,33
S17	8	1,42	2,31	2,56	2,73	2,30	2,63
S18	7	3,07	3,65	3,99	3,51	3,50	4,01
S19	8	3,84	4,71	5,10	4,92	4,36	4,98
S20	7	1,25	1,50	1,88	1,36	1,64	1,75
S21	8	1,91	2,26	2,37	2,16	2,17	2,31
S22	25	2,02	2,82	2,80	2,62	2,66	2,96
S23	25	1,24	2,38	2,38	1,60	2,18	2,34
S24	25	1,73	2,64	2,42	2,05	2,23	2,29
S25	7	3,40	3,51	3,84	3,95	3,76	3,94
S26	8	2,83	2,89	3,15	2,86	2,99	3,25
S27	9	4,13	4,46	4,52	4,38	4,43	4,72
S28	25	2,08	2,11	2,24	2,07	2,11	2,22
S29	7	4,73	5,47	5,49	5,40	5,25	5,67
S30	8	5,82	6,86	7,01	6,69	6,54	7,14
S31	9	4,58	6,06	5,94	6,09	5,53	6,28
S32	25	2,69	3,15	3,48	2,99	3,21	3,52
S33	7	1,40	1,59	1,50	1,43	1,46	1,43
S34	8	1,06	1,23	1,17	1,08	1,14	1,14
S35	9	1,02	1,31	1,19	1,11	1,10	1,12
S36	25	1,39	1,38	1,38	1,39	1,43	1,52
S37	7	4,77	4,89	5,27	4,83	4,97	5,40
S38	8	4,94	5,14	5,02	5,34	5,13	5,36
S39	9	6,34	7,06	7,07	6,69	6,86	7,27
S40	25	3,51	3,57	3,94	3,80	3,70	4,04
S41	7	1,26	1,43	1,30	1,25	1,31	1,33
S42	8	1,29	1,55	1,34	1,33	1,35	1,36

S43	9	1,54	1,73	1,67	1,58	1,66	1,74
S44	25	1,16	1,10	1,12	1,15	1,16	1,16
S45	7	1,14	1,64	1,29	1,31	1,40	1,38
S46	8	1,09	1,72	1,39	1,31	1,49	1,54
S47	9	1,31	2,09	1,69	1,66	1,68	1,78
S48	25	1,33	1,75	1,81	1,68	1,89	1,92

9. Spis skrótów

Adam – Adaptive Moment Estimation
ASR – Artifact Subspace Reconstruction
ATAR – Automatic and Tunable Artifact Removal
BCG – Ballistocardiogram
BCI – Brain-Computer Interface
BSA – Bird Swarm Algorithm
BSO – Beetle Swarm Optimization
BSS – Blind Source Separation
CCA – Canonical Correlation Analysis
cICA – Constrained Independent Component Analysis
CNN – Convolutional Neural Networks
COA – Coyote Optimization Algorithm
DAE – Deep Autoencoder
DARTS – Differentiable Architecture Search
DCN – Deformable Convolution Network
DCT – Discrete Cosine Transform
DLN – Deep Learning Network
DNN – Deep Neural Network
DRNet – Decomposer Reconstructor Net
DS-EFO – Distance Sorted-Electric Fish Optimization
DWT – Discrete Wavelet Transform
EEG – Electroencephalography
EEMD – Ensemble Empirical Mode Decomposition
EFO – Electric Fish Optimization
EKG – Electrocardiography
EMCD – Empirical Mean Curve Decomposition
EMCP – Eye Movement Correction Procedure
EMD – Empirical Mode Decomposition
EMG – Electromyography
EOG – Electrooculography
FCN – Fully Convolutional Network
FEM – Feature Enhancement Module

FFT – Fast Fourier Transform
FIR – Finite Impulse Response
GAP – Global Average Pooling
GWO – Grey Wolf Optimization
HEOG – Horizontal Electrooculogram
IC – Independent Component
ICA – Independent Component Analysis
IFFT – Inverse Fast Fourier Transform
IIR – Infinite Impulse Response
IMF – Intrinsic Mode Function
LDA – Linear Discriminant Analysis
LED – Light Emitting Diode
LR – Linear Regression
LMS – Least Mean Squares
LSTM – Long Short-Term Memory
MAPE – Mean Absolute Percentage Error
Max – Maximum
MI – Motor Imagery
Min – Minimum
MSE – Mean Squared Error
NA-FMEMD – Noise-Assisted Fast Multivariate Empirical Mode Decomposition
NAS – Neural Architecture Search
NLP – Natural Language Processing
NMSE – Normalized Mean Squared Error
OBS – Optimal Basis Set
OS-EHO – Opposition Searched-Elephant Herding Optimization
PRA – Pulse Related Artefact
PSNR – Peak Signal-to-Noise Ratio
PSO – Particle Swarm Optimization
RC – Reconstructed Component
RLS – Recursive Least Squares
RMSE – Root Mean Squared Error
RNN – Recurrent Neural Network
RRMSE – Relative Root Mean Square Error

SC – Shortcut Connection
SE – Squeeze and Excitation
Seq2Seq – Sequence-to-Sequence
SER – Sparsity-based EEG Reconstruction
SM-EFO – Spider Monkey-based Electric Fish Optimization
SOBI – Second-Order Blind Identification
SSA-CCA – Singular Spectrum Analysis - Canonical Correlation Analysis
SSIM – Structural Similarity Index Measure
SSVEP – Steady-State Visual Evoked Potential
STD / Std – Standard Deviation
STF-EVD – Spatio Temporal Filtering - Eigenvalue Decomposition
SVM – Support Vector Machine
UEM – Uncertainty Estimation Module
VEOG – Vertical Electrooculogram
VEP – Visual Evoked Potentials
VR – Virtual Reality
wICA – Wavelet-Independent Component Analysis
WNN – Wavelet Neural Network
WVFLN – Wavelet Vector Functional Link Network