

Automatyka i Robotyka
AUTOREFERAT ROZPRAWY DOKTORSKIEJ

**Metody inteligentnego monitorowania i cyfrowej analizy sygnałów
biomedycznych oraz ich zastosowanie do nieinwazyjnej stymulacji mózgu**

**Intelligent monitoring and digital analysis of biomedical signals: an application
in noninvasive brain stimulation**

mgr inż. Natalia Browarska-Waniek

Promotor: dr hab. inż. Jarosław Zygarlicki, prof. Uczelni

Promotor pomocniczy: dr hab. inż. Aleksandra Kawala-Sterniuk, prof. Uczelni

Opole, wrzesień 2024

Rozdział 1

Wprowadzenie

Ludzki mózg jest uważany za najważniejszy organ i zarazem najbardziej skomplikowany komputer na świecie. Zaczyna swoją aktywność nerwową już w drugim trymestrze ciąży i jest odpowiedzialny za przekazywanie sygnałów elektrycznych w całym ciele. Pomimo, że zawiera około 100 miliardów neuronów, z których każdy może tworzyć do 10 000 połączeń synaptycznych, jego struktura i funkcjonowanie pozostają owiane tajemnicą. Mózg waży około 2% całkowitej masy ciała, ale zużywa 20% energii ludzkiego organizmu, generując około 25W mocy.

Proces myślenia opiera się na elektryczności i chemii. Rozwój neuronauki od lat 70. XX wieku umożliwił szczegółowe zrozumienie mechanizmów układu nerwowego, a interfejsy mózg-komputer (BCI) pozwalają na komunikację bez użycia mięśni poprzez pomiary bioelektrycznej aktywności mózgu.

Zjawisko sprzężenia zwrotnego w teorii sterowania rodzi pytania o możliwość wpływania na zachowanie człowieka, choć obecny stan wiedzy wyklucza możliwość całkowitej kontroli nad osobą. Niemniej jednak, skuteczność tych metod jest wysoka dzięki eliminacji artefaktów wynikających z czaszki, skóry, włosów czy zanieczyszczeń, co pozwala na lepszy odczyt sygnałów elektrycznej aktywności mózgu.

1.1 Założenia badawcze

Wiele osób na codzień zmaga się z produktywnością z powodu ogólnego rozproszenia prokrastynacji, w związku z tym poszukuje się metod zwiększania efektywności pracy. Niniejsza rozprawa doktorska prezentuje obszerny przegląd metod inteligentnego monitorowania i cyfrowej analizy sygnałów biomedycznych w oparciu o zaawansowane metody filtracji sygnałów oraz uczenie maszynowe, bazując na danych zebranych podczas nieinwazyjnej stymulacji mózgu materiałem audio-wideo.

Interfejsy mózg-komputero parte na EEG pozwalają na obserwację aktywności mózgu w czasie rzeczywistym, umożliwiając określenie stanów psychicznych i emocjonalnych. Celem tych badań jest opracowanie metody analizy aktywności mózgu w celu wykrywania tych stanów przy użyciu konsumenckich urządzeń EEG. Algorytm dentyfikuje wzorce dla różnych trybów pracy i stanów mentalnych/emocjonalnych za pomocą cyfrowego przetwarzania sygnałów i głębokich sieci neuronowych.

W codziennych zastosowaniach interfejsów mózg-komputer istotne jest zastosowanie kompaktowego urządzenia przy jednoczesnym zachowaniu jak najwyższej jakości danych. Niniejsza rozprawa ma na celu przede wszystkim:

- Poprawę przetwarzania sygnałów w celu redukcji zakłóceń sygnału EEG.
- Opracowanie zoptymalizowanego algorytmu do rozpoznawania wzorców stanów mentalnych lub emocji.

Te kamienie milowe umożliwią zastosowanie BCI w różnych dziedzinach, takich jak aplikacje w medycynie, rozrywka, czy neuromarketing.

Integracja interfejsów mózg-komputer opartych na EEG z zaawansowanymi metodami cyfrowego przetwarzania sygnałów i uczenia maszynowego jest zgodna z zasadami automatyki i robotyki. Badania te przyczyniają się do rozwoju zautomatyzowanych systemów sterowania i interakcji człowiek-maszyna, poprawiając zastosowania takie jak adaptacyjne systemy sterowania, technologie wspomagające, inteligentne interfejsy użytkownika.

1.2 Cele Badawcze

Niniejsza rozprawa zawiera szczegółową analizę danych z urządzenia Emotiv EPOC Flex i opracuje metody rozróżniania stanów mentalnych i emocjonalnych. Celem jest ich identyfikacja za pomocą metod rozpoznawania wzorców.

Badania te zakładają również zastosowanie optymalnych warunków dla zadań wizualnych i proponują metodę nieinwazyjnej stymulacji mózgu.

Te założenia wypełniają lukę między zastosowaniami klinicznymi a konsumenckimi, wykorzystując konsumenckie urządzenia BCI i zaawansowane metody cyfrowego przetwarzania sygnałów.

Dla celów niniejszej rozprawy doktorskiej sformuowano następującą tezę oraz hipotezę:

Teza: *Inteligentne monitorowanie i cyfrowa analiza sygnałów biomedycznych z wykorzystaniem zaawansowanych metod cyfrowego przetwarzania sygnałów oraz sieci neuronowych mogą być kluczowe w identyfikacji najskuteczniejszych metod nieinwazyjnej stymulacji mózgu, wspierając badania nad rozwojem systemów, które mogą wpływać na pożądane stany mentalne i emocjonalne.*

Hipoteza: *Klasyfikacja cech sygnałów EEG poprzez inteligentne monitorowanie i cyfrową analizę umożliwi wybór odpowiednich metod nieinwazyjnej stymulacji mózgu, znacząco ułatwiając badania nad modulacją pożądanych stanów mentalnych i emocjonalnych osoby stymulowanej, z potencjalnymi przyszłymi zastosowaniami w systemach działających w czasie rzeczywistym.*

1.3 Struktura Rozprawy

Niniejsza rozprawa doktorska składa się z siedmiu rozdziałów wymienionych poniżej, dotyczy zaawansowanej analizy danych elektroencefalograficznych.

- **Rozdział 1: Wprowadzenie** krótko wprowadza zakres rozprawy, przedstawiając kluczowe obszary badawcze i główne cele badań. Omówiona została również motywacja stojąca za badaniami oraz jej znaczenie w obecnym zakresie naukowym.

- **Rozdział 2: Wstęp teoretyczny** zagłębia się w złożoną biologię mózgu i podstawowe aspekty elektroencefalografii. Ponadto omawia technologię stojącą za interfejsami mózg-komputer, ich powszechne zastosowania i rolę w rozwoju dziedziny nieinwazyjnej stymulacji mózgu.
- **Rozdział 3: Nieinwazyjna stymulacja mózgu** zawiera opis teorii emocji. Bada wpływ różnych czynników, takich jak dźwięki otoczenia lub oświetlenie na nastrój. Rozdział ten również omawia różne techniki stymulacji, w tym stymulację słuchową, wzrokową, przezczaszkową magnetyczną i prądową (TMS, tDCS, tACS, tRNS), wibracyjną, termiczną, chemiczną i sensoryczną. Opisuje również autorski zestaw danych użyty w dalszych badaniach.
- **Rozdział 4: Przetwarzanie sygnałów elektroencefalograficznych** przedstawia różne metody cyfrowego przetwarzania sygnałów, w tym zaawansowane techniki przetwarzania sygnałów, podejścia hybrydowe oraz podstawowe i adaptacyjne metody filtrowania cyfrowego. Omawia wpływ filtrów wygładzających na jakość danych. Rozdział obejmuje również zastosowanie tych metod dla przygotowanego wcześniej zestawu danych.
- **Rozdział 5: Ekstrakcja cech i rozpoznawanie wzorców** bada różne formy uczenia się w sieciach neuronowych oraz szczegółowo omawia różne struktury sieci neuronowych. Przedstawia kompleksową implementację metod rozpoznawania wzorców, koncentrując się na analizie porównawczej przeprowadzonej w celu oszacowania efektywności każdej metody.
- **Rozdział 6: Wyniki i dyskusja** zawiera kompleksowe podsumowanie rozprawy, przedstawiając kluczowe wyniki w uporządkowany sposób. Rozdział ten podkreśla również znaczenie wyników i omawia wszelkie napotkane ograniczenia podczas badań.
- **Rozdział 7: Wnioski** zbiera główne wnioski wynikające z badań. Reflektuje nad implikacjami tych wyników dla dziedziny badań. Przedstawia potencjalne kierunki dalszych badań, sugerując kolejne kroki i dodatkowe pytania, które wyłoniły się z obecnej pracy. Rozdział ten podkreśla również praktyczne zastosowania wyników badań i ich potencjał na przyszłość.

Badania opisane w rozprawie zostały przeprowadzone i realizowane na Wydziale Elektrotechniki, Automatyki i Informatyki Politechniki Opolskiej. Część badań została przeprowadzona na Technical University of Ostrava (VSB-TUO) podczas stażu Erasmus+.

Rozdział 2

Nieinwazyjna stymulacja mózgu - Opis zbioru danych MUSE

Zbiór danych MUSE (Music Used in Stimulation Experiments) [7] opisuje serię eksperymentów przeprowadzonych w ramach tego badania. Ważne informacje o pacjentach, takie jak wiek, płeć oraz stan fizyczny i psychiczny, zostały uwzględnione w tym badaniu [37]. Celem eksperymentu było zbadanie wpływu muzyki otoczenia na skupienie u pacjentów. Stymulacja dźwiękowa była stosowana podczas zadania logicznego - zadania wizualnego ERP, takiego jak prosta wykreślanka. Eksperyment został przeprowadzony w kontrolowanych warunkach laboratoryjnych. Uczestnicy używali słuchawek stereo JBL, z ustawioną głośnością na stałym i komfortowym poziomie.

Wolontariusze byli eksponowani na 30 minut materiału audiowizualnego. Eksperyment, w tym 20-minutowy okres konfiguracji urządzenia Emotiv EPOC Flex [12], trwał łącznie około 50 minut. Podczas eksperymentu uczestnicy wykonywali ćwiczenia logiczne. Zaprojektowano trzy scenariusze, aby ocenić wpływ wybranych dźwięków na grupę testową:

- zadania wykonywane bez żadnej stymulacji dźwiękowej,
- zadania wykonywane z rozpraszającymi dźwiękami,
- zadania wykonywane z dźwiękami wzmagającymi koncentrację

Przed każdym z trzech zadań uczestnicy byli eksponowani na dźwięki otoczenia natury, co miało zapewnić wprowadzenie w stan relaksu/spokoju przed kolejną fazą eksperymentu. Szczegóły scenariusza przedstawiono w poniższej tabeli:

W badaniu uwzględniono kluczowe informacje o uczestnikach, w tym wiek, płeć, stosowane leki oraz aktualny nastrój, wyrażany w skali od 0 do 10. Wszyscy uczestnicy byli członkami zespołu badawczego *The BCI and Signal Processing Lab*, działającego w ramach Wydziału Elektrotechniki, Automatyki i Informatyki na Politechnice Opolskiej. Wszyscy uczestnicy wyrazili zarówno ustną jak i pisemną zgodę na udział w badaniu.

Do tego eksperymentu użyto urządzenia Emotiv EPOC Flex [12], wyposażonego w elektrody żelowe. Emotiv EPOC Flex to interfejs mózg-komputer bazujący na elektroencefalografii, który jest urządzeniem przystępnym cenowo w klasie konsumenckiej i stosunkowo łatwo dostępny na rynku. Oferuje 32-kanałowe rozmieszczenie elektrod w systemie 10 – 20 oraz rozdzielczość EEG wynoszącą

Nr	Zadanie	Czas trwania	Opis
1	Konfiguracja urządzenia	20 min	Omówienie ogólnych zasad. Umieszczenie na głowie pacjenta czepka i elektrod.
2	Relaks	3 min	Relaks z zamkniętymi oczami. Ekspozycja na relaksujące bodźce dźwiękowe (natura, szum fal itp.)
3	Skupienie	7 min	Wykonanie łatwego zadania wizualnego (wyszukiwanie słów) bez stymulacji dźwiękowej.
4	Relaks	3 min	Relaks z zamkniętymi oczami. Ekspozycja na relaksujące bodźce dźwiękowe (natura, szum fal itp.)
5	Skupienie	7 min	Wykonanie łatwego zadania wizualnego (wyszukiwanie słów) z rozpraszającymi dźwiękami, takimi jak wiertarka elektryczna lub płaczące dziecko.
6	Relaks	3 min	Relaks z zamkniętymi oczami. Ekspozycja na relaksujące bodźce dźwiękowe (natura, szum fal itp.)
7	Skupienie	7 min	Wykonanie łatwego zadania wizualnego (wyszukiwanie słów) z bodźcami dźwiękowymi o częstotliwości 14 Hz.

Tabela 2.1: Scenariusz badania, mającego na celu stymulację mózgu przy pomocy dźwięków [7]

0.51V. Choć to urządzenie jest głównie przeznaczone do badań akademickich, należy zauważyć, że sygnały, które rejestruje, są już wstępnie przetworzone i nie zawierają pełnych informacji [16, 12]. Jednak niektóre źródła twierdzą, że Emotiv EPOC Flex dostarcza dane o jakości klinicznej [38].

W tym badaniu użyto łącznie 32 czujników: (*Cz, Fz, Fp1, F7, F3, FC1, C3, FC5, FT9, T7, TP9, CP5, CP1, P3, P7, O1, Pz, Oz, O2, P8, P4, CP2, CP6, TP10, FC6, C4, FC2, F4, F8, i Fp2*). Dalsze badania koncentrują się na analizie danych z tylko sześciu kanałów: *F3, F4, C3, C4, P3* i *P4*.

Decyzja o ograniczeniu liczby elektrod została podjęta po dokładnym podsumowaniu wcześniejszych doświadczeń badawczych i kompleksowym przeglądzie literatury. Jak wcześniej wspomniano, analiza danych biomedycznych, zwłaszcza EEG, jest skomplikowanym zadaniem [42, 19, 17, 16]. Duża liczba kanałów EEG komplikuje proces analizy danych, który można uprościć, wybierając tylko niezbędne kanały [3, 21, 15, 14]. To również skraca czas konfiguracji [3, 13] i sprawia, że systemy BCI stają się bardziej kompaktowe [21]. Jak dotąd, ta liczba elektrod wydaje się wystarczająca przy eksperymentach badawczych tego typu [13]. Użycie tylko sześciu kanałów w aplikacjach BCI zostało znalezione w licznych badaniach. Udowodniono, że zapewnia wydajność podobną do rozszerzonych zestawów kanałów [39, 20, 23, 40, 25]. W [20].

Procedura przetwarzania sygnałów została przeprowadzona przy użyciu języka programowania *Python* w środowisku *Spyder*. Analizowane dane zostały zarejestrowane z sześciu następujących lokalizacji: *F3*, *F4*, *C3*, *C4*, *P3* i *P4*, które reprezentują następujące lokalizacje mózgu: *czołowa*, *centralna* i *ciemieniowa*.

Narzędzia do przetwarzania i analizy danych

Dane zostały najpierw załadowane i wstępnie przetworzone przy użyciu *pandas*. Następnie użyto *NumPy* do wydajnych obliczeń na tablicach wielowymiarowych. Do przetwarzania sygnałów wykorzystano bibliotekę *SciPy*, a następnie wykorzystano *butter* do projektowania filtrów Butterwortha, funkcję *filtfilt* do filtrowania bez opóźnień, funkcję *savgol filter* do stosowania filtru Savitzky'ego-Golaya oraz funkcję *medfilt* do stosowania filtru medianowego. Dodatkowo użyto modułu *scipy.ndimage*, zbioru funkcji do przetwarzania obrazów wielowymiarowych. Funkcja *spectrogram* z *scipy.signal* była również używana do generowania spektrogramów. Biblioteka *Matplotlib* była używana do tworzenia wykresów, umożliwiając wizualizację wyników analizy.

Te biblioteki dostarczyły niezbędnych narzędzi do przeprowadzenia kompleksowej analizy sygnałów EEG w badaniu.

Dane EEG były próbkowane z częstotliwością 128 Hz, co jest powszechnie stosowaną wartością w badaniach EEG. Taka częstotliwość jest wystarczająco wysoka, aby uchwycić pełne spektrum fal mózgowych (do pasma gamma), a jednocześnie wystarczająco niska, aby przetwarzanie danych było efektywne z użyciem nowoczesnych zasobów obliczeniowych.

Dane zostały załadowane do *pandas DataFrame*, dwuwymiarowej struktury danych z etykietami. W tej analizie *DataFrame* zawiera dane EEG z sześciu elektrod: (*F3*), (*F4*), (*C3*), (*C4*), (*P3*) i (*P4*). Każda kolumna w *DataFrame* odpowiada danym z jednej elektrody. *Pandas DataFrame* zapewnia elastyczny i wydajny sposób manipulacji i analizy danych EEG.

Implementacja filtrów

Przed zastosowaniem filtrów wygładzających dane zostały wstępnie przetworzone przy użyciu dolnoprzepustowego filtra Butterwortha 4-tego rzędu z częstotliwością odcięcia 4Hz . Został zaimplementowany w celu zmniejszenia wpływu szumów i artefaktów o niskiej częstotliwości, takich jak te spowodowane mruganiem oczu. Ten krok wstępnego przetwarzania poprawił jakość danych EEG i sprawił, że były one lepiej przygotowane do dalszych etapów, takich jak zastosowanie kolejnych filtrów wygładzających.

W tym badaniu zastosowano pięć różnych typów filtrów do danych EEG:


- **Filtr 1:** Jest to klasyczny filtr wygładzający typu "średnia ruchoma". Parametr wygładzania (rozpiętość) jest domyślnie ustawiony na 5. Ten filtr działa poprzez uśrednianie punktów danych w przesuwającym się oknie o rozmiarze 5, co pomaga wygładzić krótkoterminowe fluktuacje i podkreślić długoterminowe trendy lub cykle.
- **Filtr 2:** Jest to również klasyczny filtr wygładzający typu "średnia ruchoma", ale z większym parametrem wygładzania (rozpiętość) ustawionym na 15. Skutkuje to bardziej wygładzonym wyjściem poprzez uśrednianie większej liczby punktów danych.

- **Filtr 3:** Ten filtr wykorzystuje metodę Savitzky'ego-Golaya, filtr wygładzający, który używa przesuwanego się okna punktów danych w problemie regresji wielomianowej. Rząd wielomianu wynosi 2, co oznacza, że dopasowuje funkcję kwadratową do punktów danych w oknie.
- **Filtr 4:** Jest to jednowymiarowy filtr medianowy 9-tego rzędu. Filtry medianowe są nieliniowymi filtrami, które redukują szумы w obrazie lub sygnale. Są szczególnie skuteczne w usuwaniu szumów typu "sól i pieprz".
- **Filtr 5:** Jest to filtr wygładzający FIR (Finite Impulse Response) Savitzky'ego-Golaya. Jest to filtr 4-tego rzędu i ma długość ramki wynoszącą 27. Ten filtr jest skuteczny w zachowywaniu cech oryginalnego sygnału.

Wybór tych filtrów i ich parametrów opiera się na wcześniejszych doświadczeniach i szeroko zakrojonych badaniach nad przetwarzaniem sygnałów EEG. Filtr Butterwortha jest skuteczny w początkowej redukcji szumów, co czyni go standardowym wyborem do wstępnego przetwarzania. Jak potwierdzono w licznych badaniach, filtry średniej ruchomej są proste i wydajne w wygładzaniu danych. Filtry Savitzky'ego-Golaya zachowują integralność cech sygnału, jednocześnie zapewniając gładkie wyjścia, co zostało udowodnione w różnych zastosowaniach. Filtr medianowy jest odporny na obsługę wartości odstających i specyficznych rodzajów szumów, co czyni go niezawodnym w poprawie danych EEG. Razem te filtry zapewniają kompleksowe podejście do poprawy jakości danych EEG, wykorzystując zarówno podstawy teoretyczne, jak i dowody empiryczne.


W tym badaniu dane poddane analizie pochodzą z dokładnych elektrod, mianowicie $F3$, $F4$, $C3$, $C4$, $P3$ i $P4$. Te elektrody są strategicznie rozmieszczone na przednich, centralnych i peryferyjnych obszarach skóry głowy, rejestrując szerokie spektrum aktywności mózgu.

Analiza nieprzetworzonego sygnału i wyniki z pięciu różnych filtrów wygładzających są przedstawione na Rysunkach 2.1 i 2.2, które ilustrują porównanie dla próbki 3s, którą charakteryzują fale alfa w trybie relaksu.



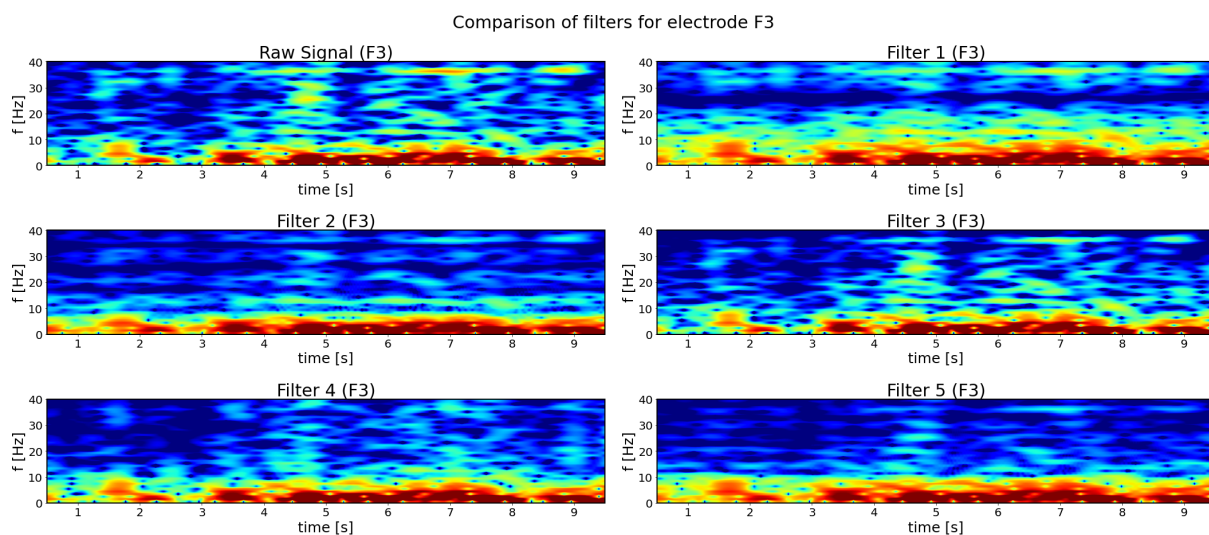
Rysunek 2.1: Porównanie filtrów dla kanału F3, pokazujące wpływ różnych filtrów na surowy sygnał

Analiza podkreśla skuteczność trzeciego filtra - filtra Savitzky'ego-Golaya. To odkrycie różni się od wniosków osiągniętych w innym badaniu [19] opartym na danych klinicznych. Inne filtry



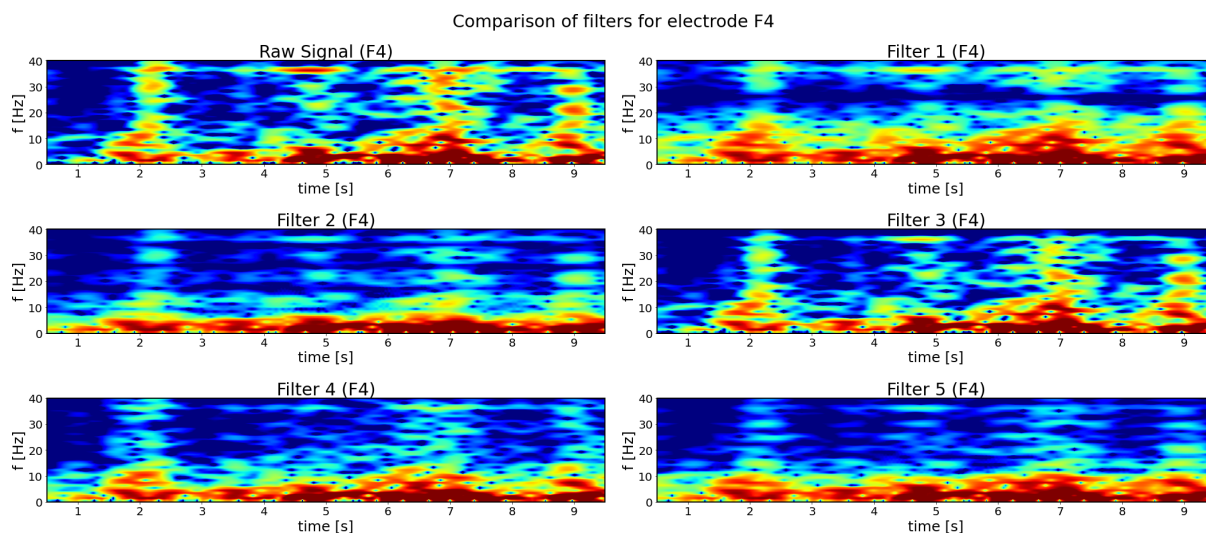
Rysunek 2.2: Porównanie filtrów dla kanału F4, pokazujące wpływ różnych filtrów na surowy sygnał

oceniane w tej analizie nadmiernie wygładzają dane, eliminując kluczowe szczegóły z tych próbek. W szczególności te filtry zmniejszyły znaczenie charakterystycznych "szczytów" w sygnale EEG - krytycznych markerów w analizach EEG. To spostrzeżenie podkreśla znaczenie wyboru filtra w wstępnym przetwarzaniu sygnału. Niewłaściwy wybór może nieumyślnie zasłonić znaczące cechy sygnału, zniekształcając wyniki i potencjalnie prowadząc do błędnych interpretacji. Dlatego filtr S-G, z jego równowagą między wygładzaniem a zachowaniem kluczowych cech sygnału, jest optymalnym wyborem do tego konkretnego zadania.



Rysunek 2.3: Obraz pokazuje sześć spektrogramów porównujących różne filtry zastosowane do surowego sygnału EEG z elektrody F3, ilustrując komponenty częstotliwościowe w czasie

Podobna sytuacja jest widoczna w próbkę 10s na spektrogramach. Spektrogramy są wizualnymi reprezentacjami tego, jak spektrum częstotliwości sygnału zmienia się w czasie. W kontekście EEG mogą pomóc zidentyfikować specyficzne wzorce lub anomalie w aktywności fal mózgowych, które zmieniają się w czasie. Spektrogramy są odczytywane, patrząc na trzy wymiary: czas (ox), częstotliwość (oy) i amplitudę częstotliwości w określonym czasie. Kolor w spektrogramie reprezentuje moc



Rysunek 2.4: Obraz pokazuje sześć spektrogramów porównujących różne filtry zastosowane do surowego sygnału EEG z elektrody F4, ilustrując komponenty częstotliwościowe w czasie

lub intensywność częstotliwości w danym czasie, przy czym cieplejsze kolory (czerwonawe) wskazują na wyższą moc, a chłodniejsze kolory (niebieskawe) wskazują na niższą moc. Wcześniej zastosowane filtry wygładzające są wizualnie przedstawione na Rysunkach 2.3 i 2.4.

Porównując surowe i przefiltrowane sygnały EEG, można ocenić, jak każdy filtr wpływa na zawartość częstotliwościową sygnału w czasie. Jest to szczególnie przydatne w identyfikowaniu specyficznych stanów aktywności mózgu lub diagnozowaniu zaburzeń neurologicznych. Dlatego filtr Savitzky'ego-Golaya jest optymalnym wyborem do tego konkretnego zadania ze względu na jego zdolność do wygładzania i zachowywania kluczowych cech sygnału.

Ważne jest staranne dobranie odpowiedniej metody filtrowania do przetwarzania sygnałów EEG, aby zachować istotne cechy sygnału przy jednoczesnym redukowaniu szumów. Filtr S-G wydaje się osiągać dobrą równowagę między wygładzaniem sygnału a zachowaniem kluczowych cech. W tym przypadku Filtr 3, filtr Savitzky'ego-Golaya, zachowuje więcej kluczowych informacji niż inne filtry.

Wybór filtra jest kluczowym krokiem w analizie danych EEG i wpływa na wyniki uzyskane z analizy danych EEG, podkreślając kluczową rolę tego kroku w przepływie pracy przetwarzania sygnałów. Może to oferować dalsze zrozumienie skuteczności i przydatności tych filtrów, co może otworzyć drogę do tworzenia bardziej zaawansowanych i dostosowanych metod filtrowania do analizy danych EEG.

Wyniki

Analiza porównawcza surowych i przefiltrowanych sygnałów EEG wyjaśnia wpływ każdego filtra na zawartość częstotliwościową sygnału biomedycznego. Ta metodologia jest szczególnie korzystna w wykrywaniu różnych stanów aktywności mózgu i diagnozowaniu zaburzeń neurologicznych.

Eksperyment ujawnia, że Filtr 2 (klasyczny filtr wygładzający typu "średnia ruchoma" z większym parametrem wygładzania ustawionym na 15) i Filtr 5 (filtr wygładzający FIR Savitzky'ego-Golaya 4-tego rzędu z długością ramki wynoszącą 27) nadmiernie wygładzają sygnał, potencjalnie usuwając kluczowe informacje. To zjawisko, znane jako nadmierne wygładzanie, może prowadzić do utraty ważnych informacji w sygnale.

Z drugiej strony, Filtr 1 (klasyczny filtr wygładzający typu "średnia ruchoma") i Filtr 4 (jednowymiarowy filtr medianowy 9-tego rzędu) poprawiają sytuację, gdzie "szczyty" są nadal widoczne. Jednak te filtry mogą nadal pozostawiać zbyt dużo szumów w danych, co utrudnia identyfikację prawdziwego sygnału, co można nazwać niedostatecznym wygładzaniem.

Filtr 3 (Savitzky'ego-Golaya) daje najbardziej optymalny wynik w tym zadaniu. Wygładza sygnał bez usuwania kluczowych danych, zachowując tym samym istotne cechy sygnału EEG. Równowaga między redukcją szumów a zachowaniem danych czyni go najbardziej odpowiednim filtrem dla tego konkretnego zastosowania.

Spektrogram surowego sygnału pokazuje szerokie spektrum częstotliwości w różnych punktach czasowych, z niektórymi obszarami o wyższej intensywności, które mogą odpowiadać istotnym cechom sygnału EEG.

Patrząc na Filtr 2, spektrogram pokazuje, że ten filtr znacznie wygładza sygnał, co skutkuje utratą niektórych szczegółów w spektrum częstotliwości. Może to potencjalnie prowadzić do utraty ważnych informacji w sygnale.

Filtr 4 zachowuje więcej szczegółów sygnału w porównaniu do Filtra 2. Niektóre obszary o wyższej intensywności są nadal widoczne, co sugeruje, że ten filtr może lepiej zachowywać ważne cechy sygnału.

Spektrogramy dla Filtrów 1 i 5 pokazują, że te filtry również wygładzają sygnał, ale w różnym stopniu. Filtr 3 wydaje się zachowywać więcej szczegółów sygnału w porównaniu do Filtra 5.

Analiza spektrogramów wskazuje, że Filtr 3, mimo wygładzania sygnału, zachowuje znaczną część częstotliwościowej zawartości surowego sygnału. Świadczy o tym podobieństwo kolorowych wzorców między spektrogramem surowego sygnału a tym dla Filtra 1. Sugeruje to, że Filtr 3 może być najskuteczniejszym wyborem, gdy celem jest redukcja szumów przy jednoczesnym zachowaniu jak największej ilości oryginalnych informacji częstotliwościowych sygnału.

Filtr Savitzky'ego-Golaya jest zatem optymalnym wyborem do tego konkretnego zadania ze względu na swoją zdolność do wygładzania sygnału przy jednoczesnym zachowaniu jego kluczowych cech. Wybór odpowiedniego filtra wygładzającego nie jest prosty, mimo że może się tak wydawać na pierwszy rzut oka. Autorka niniejszej rozprawy opiera się na wcześniejszych doświadczeniach z różnymi typami urządzeń interfejsu mózg-komputer (BCI) oraz ich filtrowaniem sygnałów [7, 10, 18].

To zadanie jest istotne, ponieważ dane z *Music Used in Stimulation Experiments Dataset (MUSE)* zostały zarejestrowane przy użyciu zestawu EEG Emotiv EPOC Flex z częstotliwością próbkowania wynoszącą zaledwie 128 Hz. Ta cecha jest charakterystyczna dla wszystkich produktów Emotiv, które generują widoczne "szczyty" w wykresach czasowych. Podobne zjawisko zaobserwowano w poprzednich badaniach z udziałem danych zarejestrowanych przy użyciu Emotiv EPOC EEG [17]. To spostrzeżenie skłoniło do zastosowania filtrowania wygładzającego. Ponieważ dane zostały wstępnie przetworzone podczas rejestracji, brakowało im pełnych informacji.

Rozdział 3

Ekstrakcja cech EEG i rozpoznawanie wzorców

Procedura przetwarzania sygnałów została przeprowadzona przy użyciu *Pythona* w środowisku *Spyder*. Dane EEG od wielu uczestników zostały załadowane do *pandas DataFrames*, zawierających dane z sześciu elektrod: (*F3*), (*F4*), (*C3*), (*C4*), (*P3*) i (*P4*). Dane zostały wstępnie przetworzone poprzez wybór konkretnych kolumn, ich przestawienie i usunięcie średniej. Następnie zostały podzielone na okresy relaksu i skupienia.

Do danych zastosowano dolnoprzepustowy filtr Butterwortha, a następnie filtr Savitzky'ego-Golaya do wygładzania. Przefiltrowane dane zostały podzielone na okresy relaksu i skupienia, a cechy zostały wyodrębnione do trenowania modeli klasyfikacyjnych. Modele te przewidują, czy dany segment danych pochodzi z okresu relaksu czy skupienia, umożliwiając dokładną klasyfikację na podstawie sygnałów EEG.

Przygotowanie modelu uczenia maszynowego i porównanie efektywności dla ekstrakcji cech sygnału

Kod wyodrębnia główne cechy sygnału, obliczając średnią, wariancję, skośność i kurtozę sygnałów EEG dla każdej elektrody podczas okresów relaksu i skupienia. Obliczenia te są wykonywane na segmentach sygnałów EEG trwających 1 sekundę, co odpowiada 128 próbek na segment ze względu na częstotliwość próbkowania wynoszącą 128Hz .

Pojęcie 'okna' w tym kontekście odnosi się do krótkiego segmentu sygnału EEG. Podzielenie sygnału na te kilkusekundowe okna pozwala na analizę, jak te statystyczne cechy zmieniają się w czasie. Podejście oparte na oknach jest powszechną techniką w przetwarzaniu sygnałów. Jest korzystne dla sygnałów niestacjonarnych, takich jak EEG, gdzie statystyczne właściwości sygnału mogą zmieniać się w czasie.

To podejście pozwala na uchwycenie rozkładu sygnałów i zrozumienie podstawowych wzorców w elektrycznej aktywności mózgu. Wyodrębnione cechy są następnie używane do trenowania modeli uczenia maszynowego w celu rozróżnienia stanów relaksu i skupienia.

Funkcja do ekstrakcji cech przetwarza dane EEG w oknach po 128 próbek. Dla każdego okna oblicza średnią, odchylenie standardowe, skośność i kurtozę sygnału. Te cechy są następnie łączone

w pojedynczy wektor cech dla każdego okna. Te tabele przedstawiają cechy wyodrębnione z połączonych próbek relaksu (relax1, relax2 i relax3) i próbek skupienia (focus1) pierwszego uczestnika.

Te dane dostarczają kompleksowego przeglądu charakterystyk sygnału EEG podczas różnych stanów psychicznych. Cechy wyodrębnione z sygnałów EEG, w tym średnia, wariancja, skośność i kurtoza obliczone dla każdej elektrody, oferują szczegółową reprezentację rozkładu sygnału. Złożoność tych cech charakteryzuje elektryczną aktywność mózgu podczas okresów relaksu i skupienia. Różnice obserwowane w tych cechach między dwoma stanami podkreślają ich potencjalną użyteczność w opracowywaniu modeli do przewidywania stanów i pogłębiają nasze zrozumienie różnych wzorców aktywności mózgu związanych z różnymi stanami psychicznymi.

Na podstawie wyników, na przykład, widać, że wartości średnie są zazwyczaj wyższe podczas relaksu, co wskazuje na wyższy poziom aktywności elektrycznej w mózgu. Z kolei wartości wariancji, skośności i kurtozy są niższe podczas okresów skupienia, co sugeruje bardziej stabilny i spójny sygnał. Te odkrycia dostarczają cennych informacji na temat funkcjonowania mózgu podczas różnych stanów psychicznych i mogą stanowić podstawę do dalszych badań neurobiologicznych i zastosowań.

Na podstawie wykresów czasowych, zmienność sygnałów EEG w czasie jest widoczna. Te sygnały, zarejestrowane z sześciu różnych elektrod, wykazują ciągłe fluktuacje amplitudy. Te fluktuacje reprezentują elektryczną aktywność mózgu podczas okresów relaksu i skupienia. Ważne jest, aby zauważyć, że różne wzorce sygnałów EEG są związane z różnymi stanami psychicznymi - fale alfa są związane z relaksem, podczas gdy fale beta są związane z aktywnym myśleniem lub skupieniem.

W tym konkretnym przypadku stan relaksu został wywołany z zamkniętymi oczami, co jest istotnym czynnikiem do rozważenia. Zamknięcie oczu często może zwiększyć amplitudę fal alfa, co jest zgodne z wyższą gęstością mocy spektralnej obserwowaną w paśmie alfa podczas relaksu.

Po procesie ekstrakcji cech, następnym krokiem jest przygotowanie danych do modelowania uczenia maszynowego. W tym kroku konieczne było połączenie wszystkich cech i stworzenie etykiet dla stanów psychicznych (0 dla relaksu i 1 dla skupienia). Następnie dane zostały przetasowane i podzielone na zestawy treningowe i testowe, osobno dla każdej pary elektrod (C3_C4, F3_F4, P3_P4). Wynikiem jest pojedynczy zestaw danych, który zawiera zarówno cechy relaksu, jak i skupienia. Ten sam proces został powtórzony dla cech opartych na segmentach.

Następnie dane zostały przetasowane i podzielone na zestawy treningowe i testowe. Zapewnia to, że model ma wystarczającą kombinację danych do nauki oraz niezależny zestaw niewidzianych danych do testowania jego wydajności. Połączony zestaw danych cech relaksu i skupienia jest podzielony na dwie części: 70% danych używanych do trenowania modelu uczenia maszynowego i pozostałe 30% używane do testowania wydajności modelu. Ten proces jest powtarzany dla każdej pary elektrod. Zestaw treningowy trenuje model uczenia maszynowego, pozwalając mu nauczyć się wzorców i relacji między cechami a stanami psychicznymi (relaks i skupienie). Zestaw testowy jest używany do oceny wydajności modelu, zapewniając, że może on dokładnie przewidzieć stany psychiczne nowych, niewidzianych danych. Ten krok jest kluczowy dla walidacji ogólności i odporności modelu.

Następnym krokiem w procesie jest zastosowanie modelu uczenia maszynowego dostosowanego do przygotowanych danych. Obejmuje to wybór odpowiedniego algorytmu, trenowanie modelu na zestawie treningowym i ocenę jego wydajności na zestawie testowym. Celem jest opracowanie modelu, który dokładnie rozróżnia stany relaksu i skupienia na podstawie wyodrębnionych cech z sygnałów EEG.

Po procesie ekstrakcji cech, modele uczenia maszynowego zostały zastosowane do przygotowanych danych. Badane modele obejmują:

- **Głęboka sieć neuronowa (DNN):** Składa się z warstwy wejściowej z 64 neuronami, dwóch ukrytych warstw z 128 neuronami każda i warstwy wyjściowej z 1 neuronem. Używa aktywacji relu w warstwach wejściowych i ukrytych oraz aktywacji sigmoid w warstwie wyjściowej. Warstwy dropout są dodane, aby zapobiec przeuczeniu. Kompilowany z binary_crossentropy loss, adam optimizer i accuracy metric.
- **Konwolucyjna sieć neuronowa (CNN):** Składa się z warstwy konwolucyjnej z 32 filtrami, warstwy max pooling, warstwy flattening, ukrytej warstwy z 64 neuronami i warstwy wyjściowej z 1 neuronem. Używa aktywacji relu w warstwach konwolucyjnych i ukrytych oraz aktywacji sigmoid w warstwie wyjściowej. Kompilowany z binary_crossentropy loss, adam optimizer i accuracy metric.
- **Długoterminowa pamięć krótkoterminowa (LSTM):** Składa się z warstwy LSTM z 64 jednostkami i warstwy wyjściowej z 1 neuronem. Używa aktywacji sigmoid w warstwie wyjściowej. Kompilowany z binary_crossentropy loss, adam optimizer i accuracy metric.
- **Rekurencyjna sieć neuronowa (RNN):** Składa się z warstwy RNN z 64 jednostkami i warstwy wyjściowej z 1 neuronem. Używa aktywacji sigmoid w warstwie wyjściowej. Kompilowany z binary_crossentropy loss, adam optimizer i accuracy metric.
- **Jednostka rekurencyjna z bramkowaniem (GRU):** Składa się z warstwy GRU z 64 jednostkami i warstwy wyjściowej z 1 neuronem. Używa aktywacji sigmoid w warstwie wyjściowej. Kompilowany z binary_crossentropy loss, adam optimizer i accuracy metric.
- **Głęboka CNN:** Składa się z dwóch warstw konwolucyjnych z 32 i 64 filtrami, warstwy max pooling, warstwy flattening, ukrytej warstwy z 64 neuronami i warstwy wyjściowej z 1 neuronem. Używa aktywacji relu w warstwach konwolucyjnych i ukrytych oraz aktywacji sigmoid w warstwie wyjściowej. Kompilowany z binary_crossentropy loss, adam optimizer i accuracy metric.

Wszystkie wymienione modele były trenowane przez maksymalnie 50 epok, ale zastosowano również technikę zwaną 'wczesnym zatrzymaniem', aby zapobiec przeuczeniu modelu. Wczesne zatrzymanie to technika regularyzacji, która automatycznie zatrzymuje trening modelu, gdy wydajność na zestawie walidacyjnym przestaje się poprawiać. Jest to przydatne podczas trenowania modelu przez kilka epok, ale nie indukuje ryzyka przeuczenia modelu.

W tym przypadku, jeśli model nie poprawi swojej wydajności na zestawie walidacyjnym przez 10 kolejnych epok (mierzonych przez funkcję straty), proces treningowy zostanie zatrzymany. Dodatkowo, dzięki funkcji ModelCheckpoint, model z najniższą stratą walidacyjną jest zapisywany.

Zastosowanie wczesnego zatrzymania i zapisywania modelu jest kluczowe w trenowaniu sieci neuronowych, ponieważ pomaga uniknąć przeuczenia i zapewnia, że zapisany jest model o najlepszej wydajności. Te techniki przyczyniają się do odporności i ogólności modelu, czyniąc go bardziej niezawodnym podczas stosowania do nowych, niewidzianych danych.

Przygotowanie modelu uczenia maszynowego i porównanie efektywności dla analizy częstotliwości

Te same modele zostały użyte w analizie częstotliwości (DNN, CNN, LSTM, RNN, GRU i Deep CNN). Wszystkie modele zostały skonfigurowane z tymi samymi parametrami. Podobnie, wczesne zatrzymanie zostało również zastosowane jako technika regularyzacji, aby zapobiec przeuczeniu modeli.

Wszystkie modele były trenowane na danych z okien czasowych ($1s$ i $10s$), które zostały przekształcone do dziedziny częstotliwości przy użyciu szybkiej transformacji Fouriera.

Wyniki

W przeprowadzonych eksperymentach przetestowano różne modele. Szczegółowe wyniki efektywności tych modeli są podsumowane powyżej w tabelach. Ta analiza porównawcza stanowi solidną podstawę do podejmowania świadomych decyzji dotyczących wyboru modeli do klasyfikacji sygnałów EEG. Wydajność każdego modelu można ocenić na podstawie kilku czynników, w tym ogólnej dokładności, precyzji i czułości dla stanów 'relaksu' i 'skupienia', liczby epok i czasu treningu.

Rozważ następujące punkty:

- Model GRU dla $P3_P4$ z oknem $10s$ osiąga najwyższą ogólną dokładność (72%) spośród wszystkich modeli. Jednak wymaga również najwięcej epok (27) i ma dłuższy czas treningu ($1.95s$).
- Model RNN dla $P3_P4$ z oknem $10s$ osiąga drugą najwyższą ogólną dokładność (65%) i wymaga mniej epok (7) w porównaniu do modelu GRU dla $P3_P4$. Jego czas treningu ($0.57s$) jest również krótszy.
- Model LSTM dla $P3_P4$ z oknem $5s$ osiąga trzecią najwyższą ogólną dokładność (66%) i wymaga mniej epok (5) niż model GRU dla $P3_P4$. Jednak jego czas treningu ($1.45s$) jest dłuższy niż modelu RNN dla $P3_P4$.

Na podstawie tych obserwacji modele można uszeregować w następujący sposób:

1. Model GRU dla $P3_P4$ z oknem $10s$ (najwyższa ogólna dokładność, ale dłuższy czas treningu i więcej epok)
2. Model RNN dla $P3_P4$ z oknem $10s$ (druga najwyższa ogólna dokładność, krótszy czas treningu i mniej epok)
3. Model LSTM dla $P3_P4$ z oknem $5s$ (trzecia najwyższa ogólna dokładność, dłuższy czas treningu, ale mniej epok)

Najlepiej działające modele zostały wybrane na podstawie obserwacji, uwzględniając różne czynniki, takie jak dokładność, czas treningu, liczba epok, złożoność modelu i inne istotne cechy. Wybrane modele to modele LSTM, RNN i GRU, a ich wydajność opiera się na ekstrakcji cech z oknami $5s$ i $10s$.

W kontynuacji analizy przeprowadzono głębsze badanie wydajności najlepiej działających modeli LSTM, RNN i GRU. Modele te zostały wybrane na podstawie ich wydajności w różnych rozmiarach okien ($5s$) i ($10s$).

Proces porównywania wyników różnych modeli jest kluczowym elementem uczenia maszynowego i analizy danych. Należy wziąć pod uwagę kilka istotnych aspektów:

- **Dokładność modelu:** Jest to podstawowa metryka, która pokazuje, jak dobrze model przewiduje wyniki. Może być mierzona na różne sposoby, w zależności od rodzaju problemu, na przykład poprzez precyzję, czułość, $F1$ -score dla problemów klasyfikacyjnych oraz MSE (Mean Squared Error) lub MAE (Mean Absolute Error) dla problemów regresji.
- **Złożoność modelu:** Bardziej złożone modele mogą lepiej dopasować dane treningowe, ale mogą prowadzić do przeuczenia. Ważne jest znalezienie równowagi między złożonością modelu a jego zdolnością do generalizacji.
- **Czas treningu:** Niektóre modele mogą wymagać znacznie więcej czasu treningu niż inne. Jeśli czas jest kluczowym czynnikiem, może to wpłynąć na wybór modelu.
- **Interpretowalność modelu:** Czasami ważne jest, aby model był łatwy do zrozumienia i interpretacji. Na przykład drzewa decyzyjne i regresja liniowa są zazwyczaj łatwiejsze do interpretacji niż sieci neuronowe.
- **Spójność kolumn:** Ważne jest sprawdzenie, czy kolumny w obu modelach są spójne. Oznacza to, że dane w każdej kolumnie w obu modelach powinny mieć podobne znaczenie i być w tym samym formacie.
- **Identyfikacja kluczowych różnic:** Porównując dwa modele, ważne jest zidentyfikowanie kluczowych różnic między dwoma zestawami wyników.

Porównawcza analiza różnych modeli klasyfikacyjnych przedstawiona w tym badaniu dostarcza cennych informacji na temat ich wydajności w kontekście klasyfikacji sygnałów EEG. Wyniki wskazują, że podczas gdy niektóre modele osiągają lepszą dokładność, inne mogą być bardziej efektywne pod względem czasu treningu. Ponadto wybór metody ekstrakcji cech i rozmiaru okna może znacząco wpłynąć na wydajność modeli.

W tym konkretnym przypadku warto wspomnieć, że wzorzec 'relaksu' osiąga lepszą dokładność niż 'skupienie'. Istnieją dwa kluczowe powody tego: wybrane próbki 'relaksu' są większe i dłuższe niż próbki 'skupienia'. Jednak może to być również spowodowane błędem ludzkim - podczas przeprowadzonego eksperymentu uczestnicy byli bardziej skłonni do relaksu niż do skupienia przez dłuższy czas, a wspomniane dane mogą być zakłócone przez ich niechciane myśli i zachowania podczas badania.

Aby podsumować i porównać, ogólne wyniki dla modeli w różnych konfiguracjach zostały uśrednione. Te średnie są przedstawione w Tabelach 3.1, 3.2, 3.3, 3.5 i 3.6. Każda tabela dostarcza kompleksowego przeglądu wydajności różnych modeli w różnych warunkach, oferując wgląd w ich średnią dokładność i czas treningu. Ta analiza porównawcza stanowi cenne źródło informacji na temat zachowania tych modeli w różnych scenariuszach i pomaga w podejmowaniu świadomych decyzji dotyczących ich zastosowania w rzeczywistych sytuacjach.

Tabela 3.1 przedstawia średnią wydajność modeli na podstawie ekstrakcji cech z oknem 1s. Można zauważyć, że model GRU osiągnął najwyższą średnią dokładność wynoszącą 61.67%, podczas gdy model CNN miał najkrótszy średni czas treningu wynoszący 3.70 sekundy.

Następnie okno zostało rozszerzone do 5s, a wyniki są przedstawione w Tabeli 3.2.

Model	Średnia dokładność	Średni czas treningu
DNN (C3_C4, F3_F4, P3_P4)	60.67%	5.62s
CNN (C3_C4, F3_F4, P3_P4)	60.33%	3.70s
LSTM (C3_C4, F3_F4, P3_P4)	60.67%	10.04s
RNN (C3_C4, F3_F4, P3_P4)	60.67%	4.38s
GRU (C3_C4, F3_F4, P3_P4)	61.67%	8.83s
DeepCNN (C3_C4, F3_F4, P3_P4)	61.00%	4.72s

Tabela 3.1: Średnia wydajność modeli na podstawie ekstrakcji cech (okno 1s)

Model	Średnia dokładność	Średni czas treningu
DNN (C3_C4, F3_F4, P3_P4)	57.33%	1.54s
CNN (C3_C4, F3_F4, P3_P4)	55.67%	1.50s
LSTM (C3_C4, F3_F4, P3_P4)	64.67%	1.88s
RNN (C3_C4, F3_F4, P3_P4)	64.67%	1.40s
GRU (C3_C4, F3_F4, P3_P4)	65.33%	2.44s
DeepCNN (C3_C4, F3_F4, P3_P4)	62.00%	1.15s

Tabela 3.2: Średnia wydajność modeli na podstawie ekstrakcji cech (okno 5s)

Model LSTM osiągnął najwyższą średnią dokładność wynoszącą 64.67% dla tego rozmiaru okna. Porównując te wyniki z wynikami dla okna 1s, można zauważyć, że zwiększenie rozmiaru okna doprowadziło do poprawy średniej dokładności modeli.

Okno zostało dalej rozszerzone do 10s, a wyniki są przedstawione w Tabeli 3.3.

Model	Średnia dokładność	Średni czas treningu
DNN (C3_C4, F3_F4, P3_P4)	58%	1.21s
CNN (C3_C4, F3_F4, P3_P4)	59%	1.16s
LSTM (C3_C4, F3_F4, P3_P4)	64%	1.46s
RNN (C3_C4, F3_F4, P3_P4)	62%	1.24s
GRU (C3_C4, F3_F4, P3_P4)	68%	1.79s
DeepCNN (C3_C4, F3_F4, P3_P4)	66%	1.22s

Tabela 3.3: Średnia wydajność modeli na podstawie ekstrakcji cech (okno 10s)

Model GRU ponownie osiągnął najwyższą średnią dokładność, tym razem wynoszącą 68%. Jednak porównując te wyniki z wynikami dla okna 5s, można zauważyć, że zwiększenie rozmiaru okna nie poprawiło znacząco średniej dokładności modeli.

Przeprowadzono również testy dla treningu modeli opartego na analizie FFT, ale nie przyniosły one spektakularnych wyników, jak pokazano w Tabeli 3.5. Średnia dokładność wynosiła około 57%, a średni czas treningu był znacznie dłuższy niż w przypadku innych metod.

Wyniki te pokazują, że analiza FFT nie przyniosła znaczącej poprawy w dokładności modeli, a czas treningu był dłuższy w porównaniu do innych metod ekstrakcji cech.

Podsumowując, analiza porównawcza różnych modeli klasyfikacyjnych i metod ekstrakcji cech dostarcza cennych informacji na temat ich wydajności w kontekście klasyfikacji sygnałów EEG. Wyniki wskazują, że wybór metody ekstrakcji cech i rozmiaru okna może znacząco wpłynąć na wydajność modeli. Modele GRU, RNN i LSTM wykazały się najlepszą wydajnością w różnych konfiguracjach, co sugeruje ich potencjalną użyteczność w rzeczywistych zastosowaniach.

Model	Średnia dokładność	Średni czas treningu
DNN (C3_C4, F3_F4, P3_P4)	57%	2.34s
CNN (C3_C4, F3_F4, P3_P4)	56%	2.12s
LSTM (C3_C4, F3_F4, P3_P4)	58%	2.78s
RNN (C3_C4, F3_F4, P3_P4)	57%	2.45s
GRU (C3_C4, F3_F4, P3_P4)	59%	2.89s
DeepCNN (C3_C4, F3_F4, P3_P4)	57%	2.36s

Tabela 3.4: Średnia wydajność modeli na podstawie analizy FFT (okno 1s)

Model	Średnia dokładność	Średni czas treningu
DNN (C3_C4, F3_F4, P3_P4)	57%	2.87s
CNN (C3_C4, F3_F4, P3_P4)	57%	2.87s
LSTM (C3_C4, F3_F4, P3_P4)	57%	189.92s
RNN (C3_C4, F3_F4, P3_P4)	57%	7.14s
GRU (C3_C4, F3_F4, P3_P4)	59%	145.36s
DeepCNN (C3_C4, F3_F4, P3_P4)	55%	8.80s

Tabela 3.5: Średnia wydajność modeli na podstawie analizy FFT (okno 1s)

Podobnie jak w przypadku analizy sygnałów cech, przeprowadzono eksperyment, aby rozszerzyć okno dla cech FFT do 5s i 10s. Jednak wydłużenie tego czasu nie przyniosło najlepszych wyników, jak wskazano w Tabeli 3.5. Średnia dokładność wynosiła tylko około 53%, a średni czas treningu był znacznie dłuższy.

Model	Średnia dokładność	Średni czas treningu
DNN (C3_C4, F3_F4, P3_P4)	53%	1.40s
CNN (C3_C4, F3_F4, P3_P4)	53%	5.33s
LSTM (C3_C4, F3_F4, P3_P4)	56%	277.70s
RNN (C3_C4, F3_F4, P3_P4)	57%	810.32s
GRU (C3_C4, F3_F4, P3_P4)	57%	770.50s
Deep CNN (C3_C4, F3_F4, P3_P4)	50%	61.70s

Tabela 3.6: Średnia wydajność modeli na podstawie analizy FFT (okno 10s)

Ogólnie rzecz biorąc, model GRU dobrze sprawdza się w różnych rozmiarach okien, osiągając najwyższą średnią dokładność. Jednak wybór między LSTM, RNN i GRU zależy od specyficznych wymagań zadania, w tym takich czynników jak zasoby obliczeniowe, czas treningu i znaczenie dokładności.

Najlepszy wybór modelu zależy od wymagań zadania. Jeśli dokładność jest najważniejszym czynnikiem, model GRU może być najlepszym wyborem. Model GRU dobrze sprawdza się w różnych rozmiarach okien, osiągając najwyższą średnią dokładność. Jednak model RNN może być lepszym rozwiązaniem, jeśli ważniejsza jest efektywność.

Jednak wybór między LSTM, RNN i GRU zależy od specyficznych wymagań zadania, w tym takich czynników jak zasoby obliczeniowe, czas treningu i znaczenie dokładności.

Rozdział 4

Wyniki i dyskusja

Wyniki badania zostały zorganizowane według głównych założeń badawczych, obejmujących filtrację sygnałów EEG oraz porównanie różnych modeli do klasyfikacji stanów mentalnych.

4.1 Ocena filtracji sygnałów EEG

Analiza sygnałów elektroencefalograficznych stwarza znaczące wyzwania ze względu na ich niską amplitudę i podatność na różne rodzaje szumów oraz artefaktów. W celu poprawy jakości sygnałów EEG zastosowano różne filtry wygładzające, mając na celu redukcję szumów przy jednoczesnym zachowaniu istotnych cech sygnału. W niniejszym badaniu porównano pięć różnych filtrów wygładzających:

- **Filtr Savitzky-Golay:** Jest to szeroko stosowany i wydajny filtr wygładzający, który wykorzystuje technikę dopasowania wielomianu metodą najmniejszych kwadratów do wygładzania danych. Jest szczególnie skuteczny w zachowywaniu wysokoczęstotliwościowych komponentów sygnału.
- **Filtr Median:** Nieliniowy filtr, który oblicza medianę wartości sekwencji przetwarzanego punktu i jego otoczenia. Ten filtr jest odporny na wartości odstające i skutecznie usuwa szumy typu 'sól i pieprz'.
- **Filtr Classic Moving Average:** Ten filtr działa poprzez uśrednianie punktów danych w przesuwającym się oknie z mniejszym parametrem wygładzania, aby osiągnąć umiarkowane wygładzanie.
- **Filtr Classic Moving Average:** Podobny do Filtra 1, ale z większym parametrem wygładzania, aby osiągnąć wyższy stopień wygładzania.
- **Filtr FIR Savitzky-Golay:** Ta odmiana filtra Savitzky'ego-Golaya ma wyższy rząd i dłuższą długość ramki, zapewniając inną równowagę między wygładzaniem a zachowaniem cech sygnału.

Analiza porównawcza surowych i przefiltrowanych sygnałów EEG wykazała, że filtr Savitzky'ego-Golaya (Filtr 3) jest najbardziej optymalnym wyborem do tego zadania. Ten filtr wygładza sygnał, nie usuwając przy tym krytycznych danych, dzięki czemu zachowuje istotne cechy sygnału EEG. Inne filtry, takie jak klasyczny filtr średniej ruchomej z większym parametrem wygładzania (Filtr

2) oraz Savitzky'ego-Golaya FIR (Filtr 5), nadmiernie wygładzają sygnał, co prowadzi do utraty ważnych informacji. Natomiast filtr medianowy (Filtr 4) i klasyczny filtr średniej ruchomej (Filtr 1) pozostawiają zbyt dużo szumów w danych, co utrudnia identyfikację prawdziwego sygnału.

Analiza spektrogramów przefiltrowanych sygnałów dodatkowo potwierdziła, że filtr Savitzky'ego-Golaya najlepiej zachowuje zawartość częstotliwościową sygnału, co jest kluczowe w analizie sygnałów EEG. Spektrogramy dostarczają wizualnej reprezentacji tego, jak spektrum częstotliwości sygnału zmienia się w czasie, a filtr Savitzky'ego-Golaya wykazał lepszą wydajność w utrzymaniu integralności komponentów częstotliwościowych sygnału.

Wybór odpowiedniego filtra jest kluczowym krokiem w przetwarzaniu sygnałów EEG, ponieważ znacząco wpływa na wyniki analizy. Niewłaściwy wybór filtra może ukryć znaczące cechy sygnału, prowadząc do błędnych interpretacji. Filtr Savitzky'ego-Golaya równoważy redukcję szumów i zachowanie kluczowych cech sygnału, co czyni go najbardziej odpowiednim filtrem do tego konkretnego zastosowania.

Podsumowując, filtr Savitzky'ego-Golaya okazał się najbardziej efektywnym narzędziem do wygładzania sygnałów EEG w tym badaniu. Utrzymywał on równowagę między redukcją szumów a zachowaniem istotnych cech sygnału. To odkrycie podkreśla, jak ważny jest staranny dobór filtra w przetwarzaniu sygnałów EEG, aby zapewnić dokładne i wiarygodne wyniki analizy.

4.2 Porównawcza analiza modeli klasyfikacyjnych

Modele o wysokiej wydajności, takie jak GRU, LSTM i RNN, mają pewne wspólne cechy. Wykorzystują one warstwy rekurencyjne, które są doskonale dostosowane do pracy z danymi sekwencyjnymi, jak sygnały EEG. Warstwy te pozwalają modelom uchwycić zależności czasowe w danych, co jest kluczowe dla precyzyjnej klasyfikacji stanów psychicznych na podstawie sygnałów EEG.

Aby dodatkowo poprawić wydajność klasyfikacji sygnałów EEG, można rozważyć techniki ensemblingu i kombinacje sieci. Ensembling polega na łączeniu prognoz wielu modeli w celu poprawy ogólnej dokładności i odporności.

Dla okna 1-sekundowego opartego na ekstrakcji cech:

- **GRU**: Osiągnął najwyższą ogólną dokładność (65.33%) dla pary elektrod $P3_P4$, ale wymagał najwięcej epok (średnio 21) i miał dłuższy czas treningu (średnio 10.76s).
- **RNN**: Zapewnił dobrą równowagę między dokładnością (64.67%) a czasem treningu (średnio 4.38s) przy średnio 15 epokach.
- **LSTM**: Wykazał się wysoką wydajnością (64.67%), ale wymagał więcej epok (średnio 15) niż RNN i miał dłuższy czas treningu (średnio 10.04s).
- **CNN**: Miał szybszy czas treningu (średnio 3.70s), ale niższą dokładność (60.33%) i wymagał średnio 19 epok.
- **DNN**: Osiągnął najwyższą dokładność dla pary elektrod $P3_P4$ (62%), ale wymagał więcej epok (średnio 37) i miał dłuższy czas treningu (średnio 5.62s).
- **Deep CNN**: Wykazał nieco lepszą dokładność (62.33%) niż CNN, ale wymagał więcej epok (średnio 22) i miał dłuższy czas treningu (średnio 4.72s).

Dla okna 5-sekundowego opartego na ekstrakcji cech:

- **GRU**: Osiągnął najwyższą ogólną dokładność (68%) dla pary elektrod *P3_P4*, wymagając najwięcej epok (średnio 16) i miał dłuższy czas treningu (średnio 9.67s).
- **RNN**: Zapewnił dobrą równowagę między dokładnością (66%) a czasem treningu (średnio 1.39s) przy średnio 13 epokach.
- **LSTM**: Wykazał się wysoką wydajnością (66%), ale wymagał więcej epok (średnio 10) niż RNN i miał dłuższy czas treningu (średnio 1.88s).
- **CNN**: Miał szybszy czas treningu (średnio 1.16s), ale niższą dokładność (57%) i wymagał średnio 7 epok.
- **DNN**: Osiągnął najwyższą dokładność dla pary elektrod *P3_P4* (61%), ale wymagał więcej epok (średnio 21) i miał dłuższy czas treningu (średnio 1.39s).
- **Deep CNN**: Osiągnął najwyższą dokładność (69%) dla pary elektrod *P3_P4*, ale wymagał więcej epok (średnio 14) i miał dłuższy czas treningu (średnio 1.26s).

Dla okna 10-sekundowego opartego na ekstrakcji cech:

- **GRU**: Osiągnął najwyższą ogólną dokładność (72%) dla pary elektrod *P3_P4*, wymagając najwięcej epok (średnio 19) i miał dłuższy czas treningu (średnio 1.79s).
- **RNN**: Zapewnił dobrą równowagę między dokładnością (65%) a czasem treningu (średnio 0.88s) przy średnio 13 epokach.
- **LSTM**: Wykazał się wysoką wydajnością (68%), ale wymagał więcej epok (średnio 17) niż RNN i miał dłuższy czas treningu (średnio 1.83s).
- **CNN**: Miał szybszy czas treningu (średnio 0.84s), ale niższą dokładność (64%) i wymagał średnio 17 epok.
- **DNN**: Osiągnął najwyższą dokładność dla pary elektrod *P3_P4* (62%), ale wymagał więcej epok (średnio 28) i miał dłuższy czas treningu (średnio 1.21s).
- **Deep CNN**: Osiągnął najwyższą dokładność (72%) dla pary elektrod *P3_P4*, ale wymagał więcej epok (średnio 23) i miał dłuższy czas treningu (średnio 1.03s).

Dla okna 1-sekundowego opartego na analizie FFT:

- **GRU**: Osiągnął najwyższą ogólną dokładność (62%) dla pary elektrod *P3_P4*, ale miał dłuższy czas treningu (średnio 145.36s) i wymagał średnio 14 epok.
- **RNN**: Zapewnił dobrą równowagę między dokładnością (57%) a czasem treningu (średnio 2.87s) przy średnio 10 epokach.
- **LSTM**: Wykazał się wysoką wydajnością (57%), ale miał dłuższy czas treningu (średnio 2.87s) i wymagał średnio 10 epok.
- **CNN**: Miał szybszy czas treningu (średnio 2.87s), ale niższą dokładność (57%) i wymagał średnio 10 epok.
- **DNN**: Osiągnął najwyższą dokładność dla pary elektrod *P3_P4* (57%), ale miał dłuższy czas treningu (średnio 2.87s) i wymagał średnio 10 epok.
- **Deep CNN**: Miał najniższą dokładność (54%) dla pary elektrod *F3_F4*, ale miał dłuższy czas treningu (średnio 8.80s) i wymagał średnio 2 epok.

Dla okna 10-sekundowego opartego na analizie FFT:

- **GRU**: Osiągnął najwyższą ogólną dokładność (59%) dla pary elektrod *P3_P4*, ale miał dłuższy czas treningu (średnio 770.50s) i wymagał średnio 21 epok.

- **RNN**: Zapewnił dobrą równowagę między dokładnością (59%) a czasem treningu (średnio 650.32s) przy średnio 7 epokach.
- **LSTM**: Wykazał się wysoką wydajnością (58%), ale miał dłuższy czas treningu (średnio 277.36s) i wymagał średnio 24 epok.
- **CNN**: Miał szybszy czas treningu (średnio 5.33s), ale niższą dokładność (54%) i wymagał średnio 11 epok.
- **DNN**: Miał najniższą dokładność (53%) dla wszystkich par elektrod, ale miał dłuższy czas treningu (średnio 1.40s) i wymagał średnio 24 epok.
- **Deep CNN**: Miał najniższą dokładność (47%) dla pary elektrod *P3_P4*, ale miał dłuższy czas treningu (średnio 61.70s) i wymagał średnio 2 epok.

Najlepszym modelem do analizy FFT jest GRU, który osiąga najwyższą dokładność, szczególnie dla okna 5-sekundowego i pary elektrod *P3_P4*. Deep CNN również wykazuje wysoką dokładność, szczególnie dla okna 10-sekundowego i pary elektrod *P3_P4*. Dla analizy FFT, podczas gdy RNN zapewnia dobrą równowagę między dokładnością a czasem treningu. Jeśli priorytetem jest dokładność, GRU i Deep CNN są najlepszymi modelami. Jeśli priorytetem jest czas treningu, CNN i DNN są najszybsze do trenowania. Jeśli potrzebna jest równowaga między dokładnością a czasem treningu, RNN i LSTM oferują dobrą równowagę.

Inne czynniki do rozważenia to zasoby obliczeniowe, ponieważ GRU i Deep CNN mogą wymagać więcej zasobów obliczeniowych. Złożoność modelu jest również istotnym czynnikiem, ponieważ prostsze modele, takie jak DNN i CNN, mogą być łatwiejsze do wdrożenia i interpretacji. Techniki równoważenia danych, takie jak oversampling, undersampling lub ważenie klas, powinny być rozważone, jeśli dane treningowe są nie zrównoważone.

Poprzez wdrożenie technik ensembleingu i kombinacji sieci, oczekuje się, że ogólna wydajność klasyfikacji sygnałów EEG może zostać znacznie poprawiona, prowadząc do dokładniejszej i bardziej odpornej klasyfikacji stanów psychicznych. Niektóre z wymienionych technik to:

- **Stacking**: Zastosowanie wyjść modeli GRU, RNN i LSTM za pomocą meta-uczącego się (np. prostej sieci neuronowej lub regresji logistycznej) w celu dokonania ostatecznej prognozy. Podejście to może wykorzystać mocne strony każdego modelu.
- **Bagging**: Trening wielu instancji tego samego modelu (np. GRU) na różnych podzbiorach danych i uśrednianie ich prognoz. Metoda ta może zmniejszyć przeuczenie i poprawić generalizację.
- **Boosting**: Sekwencyjny trening modeli, gdzie każdy model stara się poprawić błędy poprzedniego. Technika ta może być szczególnie skuteczna w poprawie wydajności słabszych modeli.
- **Hybrid Models**: Wykorzystanie różnych typów modeli (np. CNN do ekstrakcji cech, a następnie GRU do modelowania sekwencji) w celu uchwycenia zarówno wzorców przestrzennych, jak i czasowych w danych EEG.

Poprzez wdrożenie tych technik ensembleingu i kombinacji sieci, oczekuje się, że ogólna wydajność klasyfikacji sygnałów EEG może zostać znacznie poprawiona, prowadząc do dokładniejszej i bardziej odpornej klasyfikacji stanów psychicznych. ziej odpornej klasyfikacji stanów psychicznych.

4.3 Dyskusja

Pierwszym krokiem było pozyskanie danych, co okazało się trudnym zadaniem ze względu na trudności w znalezieniu ochotników oraz uzyskaniu zgody etycznej. Rekrutacja uczestników była wyzwaniem, zwłaszcza biorąc pod uwagę znalezienie chętnych i odpowiednich osób do badania. Istniało również ryzyko, że pacjenci będący przyjaciółmi lub rodziną mogą nie być całkownie sumienni w swoim udziale, co mogłoby wprowadzić bias do wyników. Mimo tych wyzwań, udało się zebrać niezbędne dane, co pozwoliło na kontynuację badania. Proces ten wymagał znacznego wysiłku i wytrwałości.

Sprzęt użyty w badaniu również stanowił pewne wyzwania. Kluczowe było zapewnienie, że sprzęt działa poprawnie i jest odpowiednio użytkowany. Pomimo początkowych trudności, sprzęt został skutecznie wykorzystany do zebrania niezbędnych danych.

Jednym z kolejnych wyzwań było stworzenie protokołu badania, który mógł wydawać się zbyt długi i wyczerpujący, co mogło powodować frustrację wśród uczestników. Podkreśla to znaczenie odpowiedniego zaprojektowania scenariusza, który skutecznie zbiera niezbędne dane, jednocześnie uwzględniając czas i wysiłek uczestników. Ważne jest również aby pamiętać, że wydajność modeli sieci neuronowych w dużej mierze zależy od dostępnych próbek danych do treningu. Im więcej próbek, tym lepiej modele mogą się uczyć, co prowadzi do dokładniejszych i bardziej wiarygodnych wyników. Dlatego konieczne jest utrzymanie równowagi między zapewnieniem komfortu uczestników a zebraniem wystarczającej ilości danych do przeprowadzenia treningu modelu.

Kolejnym krokiem było zastosowanie filtrów wygładzających. Choć mogą wydawać się one podstawowe, każdy filtr został starannie wybrany, a ich ustawienia zostały odpowiednio dostrojone [19, 6, 7, 10, 18, 17].

Kluczowym czynnikiem, który skłonił autorkę do przeprowadzenia tego badania, była popularność urządzenia Emotiv EPOC Flex. Ważne jest jednak aby pamiętać, że sygnał ten jest już wstępnie przetworzony, zanim zostanie uznany za "surowe" dane. Ponadto należy podkreślić, że ten sprzęt nie zapewnia danych EEG o jakości klinicznej [1, 33, 27]. Zastosowanie filtrów wygładzających do analizy danych biomedycznych zostało już wcześniej udokumentowane w najnowszej literaturze [11, 32, 41, 2].

W przeciwieństwie do badania opisanego w artykule [7], które opierało się na tym samym zestawie danych, wybór filtra nieco się różnił. Ta różnica może być przypisana temu, że poprzednie badanie przeprowadzono w Matlabie, podczas gdy ten eksperyment wykonano w Spyder, przy użyciu języka programowania Python oraz odpowiednich bibliotek. Jednym z kluczowych kroków w obecnym badaniu było zastosowanie *t.slice*, co zapewniło, że długość danych przed i po filtracji była spójna do porównania. Ten krok był konieczny, ponieważ proces filtracji może zmieniać długość danych w zależności od specyficznych cech użytego filtra. *t.slice* skutecznie rozwiązało ten problem, zapewniając uczciwe porównanie surowych i przefiltrowanych danych - *t.slice* to okno czasowe wybierające określony segment danych do analizy. Użycie *t.slice*, koncentrujące się na określonym okresie sygnału, jest niezwykle przydatne, gdy sygnał ma niestacjonarne atrybuty. Podkreśla to znaczenie starannego przetwarzania danych i właściwego użycia narzędzi w badaniach przetwarzania sygnałów.

Przetwarzanie danych EEG można przeprowadzać za pomocą dwóch różnych typów urządzeń sprzętowych (klinicznych lub konsumenckich), co może prowadzić do odmiennych wyników. Badania dotyczące zastosowania filtrów wygładzających do danych EEG o jakości klinicznej zostały udoku-

mentowane w [19]. Inne badania skupiały się na stosowaniu filtrów wygładzających do danych EEG uzyskanych przy użyciu sprzętu konsumenckiego. Celem było podkreślenie, że sprzęt konsumencki należy rozpatrywać osobno, a dążenie do optymalnego filtra wygładzającego powinno być realizowane z uwzględnieniem faktu, iż sprzęt konsumencki nie dostarcza "prawdziwych" surowych danych [33, ?]. Dotychczasowa ocena testowanych metod opiera się głównie na wiedzy i wieloletnim doświadczeniu autorów w zakresie pozyskiwania i przetwarzania sygnałów biologicznych [19, 6, 7, 10, 18].

Kolejna faza tego badania obejmowała analizę danych. Zostało to osiągnięte przy użyciu różnych modeli, w tym SVM, CNN, LSTM, RNN, GRU i Deep CNN. Każdy model miał swoje mocne i słabe strony, a ich wydajność różniła się w zależności od zadania [29]. Wśród testowanych modeli model SVM nie spełnił oczekiwań pod względem dokładności klasyfikacji dla klas 'relaks' i 'skupienie'. Dla wszystkich trzech par elektrod (*C3_C4*, *F3_F4*, *P3_P4*) precyzja dla klasy 'skupienie' była znacznie niższa niż dla klasy 'relaks'. Ponadto czas treningu dla modelu SVM był znacznie dłuższy niż dla innych modeli. Na przykład czas treningu dla pary elektrod *C3_C4* wynosił 503.66 sekund, co jest znacznie dłuższe w porównaniu do modeli CNN, LSTM, RNN, GRU i Deep CNN [35]. W związku z tym, ze względu na niższą wydajność i dłuższy czas treningu, model SVM nie został uwzględniony w ostatecznym porównaniu modeli. Przyszłe rozważania mogą obejmować optymalizację modelu SVM lub zastosowanie innych technik klasyfikacji w celu lepszego zarządzania zadaniem klasyfikacji [34].

W kontekście modeli GRU i RNN podejście ensemble'ngu mogłoby poprawić wydajność. Ensemble'ng to technika w uczeniu maszynowym, w której trenuje się wiele modeli, a ich prognozy są łączone, aby dokonać ostatecznej prognozy [31]. Różne modele mogą uchwycić różne wzorce w danych, a poprzez ich łączenie, możemy często osiągnąć bardziej solidną i dokładną prognozę [28]. Modele GRU i RNN, choć podobne, mają różne architektury i mogą zatem wyróżniać się w różnych aspektach zadania. Model GRU, na przykład, ma jednostki bramkujące, które modulują przepływ informacji wewnątrz jednostki, co może pomóc mu lepiej uchwycić długoterminowe zależności w danych. Z drugiej strony, model RNN, będąc prostszym, może być mniej podatny na przeuczenie i potencjalnie szybciej się trenować [22].

Poprzez połączenie tych dwóch modeli, możnaby potencjalnie wykorzystać obie te zalety. Model zespołowy mógłby skorzystać z zdolności modelu GRU do uchwycenia długoterminowych zależności oraz z prostoty i efektywności modelu RNN [28]. Jednak warto zauważyć, że stworzenie modelu ensemble'ngowego prawdopodobnie zwiększy koszty obliczeniowe, ponieważ wymaga trenowania wielu modeli zamiast jednego. Dlatego decyzja o użyciu modelu zespołowego powinna uwzględniać potencjalną poprawę wydajności, dostępne zasoby obliczeniowe i wymagania zadania [31].

Stwierdzono również, że optymalne obliczanie tych cech sygnału powinno być przeprowadzane dla segmentów czasowych o długości 510 sekund, aby skutecznie je uchwycić. Ta wiedza może być wartościowa na korzyść przyszłych badań dotyczących klasyfikacji sygnałów EEG [30].

Dodatkowe wyniki eksperymentu wykazały, że choć analiza FFT jest doskonała do wizualnej inspekcji sygnału i jego głównych częstotliwości, nie była najefektywniejszą metodą do trenowania modeli. Czas treningu dla modeli FFT był znacznie dłuższy. Choć analiza FFT może stanowić dobry punkt wyjścia dla człowieka, sieci neuronowe lepiej radzą sobie, gdy otrzymują cechy sygnału.

W kontekście analizy cech stwierdzono, że trenowanie modeli na podstawie cech sygnału było bardziej efektywne niż przy użyciu analizy FFT i analizy falkowej. Choć analiza FFT okazała się czasochłonna i mniej efektywna, analiza falkowa okazała się kompletnie niepraktyczna ze względu

na bardzo długi czas treningu. Wyniki te podkreślają znaczenie wyboru odpowiednich cech dla wydajności modelu i efektywności procesu treningowego.

Testowano również analizę falkową, lecz dalsze testy zostały porzucone ze względu na długo-trwały proces treningowy, trwający dziesiątki minut. Podkreśla to znaczenie praktyczności i efektywności przy wyborze metody klasyfikacji sygnałów EEG. Analiza falkowa zajmowała zbyt dużo czasu na trening, co czyniło ją niepraktyczną do dalszego stosowania. Wyniki te uwypuklają konieczność uwzględnienia wielu czynników, takich jak dokładność, czas treningu i praktyczność, przy wyborze modelu do klasyfikacji sygnałów EEG.

Badanie dostarczyło cennych informacji na temat wykorzystania różnych modeli do klasyfikacji sygnałów EEG. Pomimo pewnych wyzwań, zidentyfikowano modele, które dobrze radziły sobie pod względem dokładności i czasu treningu. Istnieje jednak przestrzeń do dalszej optymalizacji, która może obejmować dostrajanie hiperparametrów modeli, eksplorację różnych metod ekstrakcji cech lub badanie innych modeli.

Przy wyborze ostatecznego modelu należy uwzględnić nie tylko dokładność i czas treningu, ale także inne czynniki, takie jak interpretowalność oraz specyficzne wymagania zadania. Na przykład, jeśli interpretowalność jest kluczowa, prostszy model może być bardziej odpowiedni, mimo niższej dokładności. Z drugiej strony, jeśli wymagana jest wysoka precyzja, bardziej złożony model może być idealny, nawet jeśli jest mniej interpretowalny. Dlatego ostateczny wybór modelu powinien opierać się na kompleksowej ocenie wszystkich tych czynników.

Pomimo tych wyzwań badanie wykazało potencjał użycia filtrów wygładzających na danych EEG do klasyfikacji sygnałów. To badanie jest kluczowym krokiem w kierunku bardziej zaawansowanych i efektywnych metod klasyfikacji sygnałów EEG.

Rozdział 5

Wnioski

Niniejsza rozprawa przedstawia kompleksowe badanie dotyczące inteligentnego monitorowania i cyfrowej analizy sygnałów biomedycznych, ze szczególnym uwzględnieniem sygnałów EEG. W badaniach zastosowano zaawansowane metody cyfrowego przetwarzania sygnałów, w tym filtry wygładzające, techniki wstępnego przetwarzania oraz modele głębokich sieci neuronowych. Celem tych badań jest wykazanie, jak taka analiza może być kluczowa dla nieinwazyjnej stymulacji mózgu, wspierając osiągnięcie pożądanej aktywności umysłowej. Kluczowe wyniki i wkład tych badań są podsumowane w poniższych sekcjach.

5.1 Główne wnioski

Teza niniejszej rozprawy dotyczy inteligentnego monitorowania i cyfrowej analizy sygnałów biomedycznych przy użyciu zaawansowanych metod cyfrowego przetwarzania sygnałów oraz sieci neuronowych. Techniki te mogą być kluczowe w identyfikacji najskuteczniejszych metod nieinwazyjnej stymulacji mózgu. Takie podejście ułatwia badania nad opracowywaniem systemów modulujących pożądane stany umysłowe i emocjonalne. Przeprowadzone w tej rozprawie badanie broni tej tezy, wykazując, że zaawansowane techniki przetwarzania sygnałów i modele sieci neuronowych skutecznie klasyfikują stany umysłowe na podstawie danych EEG. Dane te mogą być następnie użyte do wpływania na pożądane stany umysłowe i emocjonalne.

Hipoteza zakłada, że klasyfikacja cech sygnału EEG poprzez inteligentne monitorowanie i cyfrową analizę umożliwi wybór odpowiednich metod nieinwazyjnej stymulacji mózgu. To podejście znacznie ułatwia badania nad modulowaniem pożądanych stanów umysłowych i emocjonalnych u stymulowanej osoby, z potencjalnymi przyszłymi zastosowaniami w systemach rzeczywistego czasu. Hipoteza ta została potwierdzona. Różne modele i metody ekstrakcji cech skutecznie klasyfikują stany umysłowe na podstawie danych EEG, co pozwala na określenie odpowiednich metod stymulacji mózgu.

Te badania mogą mieć istotny wpływ na dziedziny interfejsów mózg-komputer, przetwarzania sygnałów i sterowania. Poprzez poprawę zrozumienia analizy i interpretacji sygnałów EEG, przyczyniają się do rozwoju bardziej efektywnych systemów BCI. Mogą one mieć szeroki zakres zastosowań: od pomagania osobom z niepełnosprawnościami w interakcji z otoczeniem [8, 36], po zwiększanie wydajności poznawczej w różnych zadaniach. W dziedzinie automatyki i robotyki wyniki tych ba-

dań mogą prowadzić do rozwoju bardziej zaawansowanych i adaptacyjnych systemów robotycznych, które reagują na stany umysłowe i emocjonalne użytkowników, poprawiając interakcję i współpracę człowiek-robot.

Ponadto wyniki tych badań mogą być cenne dla innych badaczy w wymienionych dziedzinach. Udostępnienie metodologii i wyników sprawia, że rozprawa ta może służyć jako odniesienie dla przyszłych badań, wspierając rozwój zbiorowej wiedzy. Badania te stanowią znaczący krok naprzód w zastosowaniu sieci neuronowych do analizy sygnałów EEG. Wykazując skuteczność tych modeli w klasyfikacji stanów umysłowych, badania te otwierają nowe możliwości wykorzystania AI w neuro-nauce [24, 4].

Sieci neuronowe, zwłaszcza modele głębokiego uczenia, wykazały duży potencjał w analizie sygnałów EEG. Ich zdolność do nauki złożonych wzorców i powiązań z dużych ilości danych sprawia, że są one doskonale dostosowane do zadań ekstrakcji cech i klasyfikacji. W ramach tych badań eksplorowano różne architektury sieci neuronowych, z których każda oferuje unikalne zalety w przetwarzaniu danych szeregowych EEG.

Zastosowanie sieci neuronowych w tych badaniach nie tylko poprawiło dokładność klasyfikacji stanów umysłowych, ale także dostarczyło wglądu w podstawowe wzorce i cechy w sygnałach EEG. To może prowadzić do rozwoju bardziej zaawansowanych i spersonalizowanych interfejsów mózg-komputer w przyszłości. Jednak mimo ich skuteczności, sieci neuronowe również stawiają pewne wyzwania. Wymagają dużych ilości danych do treningu, a ich "black box" może utrudniać interpretację procesu podejmowania decyzji.

Ogólnie rzecz biorąc, zastosowanie sieci neuronowych w tych badaniach stanowi znaczący postęp w analizie sygnałów EEG i interfejsach mózg-komputer. Zdolność do dokładnej klasyfikacji stanów mentalnych na podstawie danych EEG może prowadzić do rozwoju adaptacyjnych i responsywnych systemów robotycznych, poprawiając interakcję i współpracę człowiek-robot. Ponadto te postępy mogą poprawić systemy sterowania poprzez integrację monitorowania stanów umysłowych w czasie rzeczywistym, prowadząc do bardziej efektywnych i intuicyjnych rozwiązań automatyzacji.

Patrząc w przyszłość, oczekuje się, że wykorzystanie BCI w codziennym życiu stanie się coraz bardziej powszechne w nadchodzących latach. W miarę postępu technologii można wyobrazić sobie przyszłość, w której systemy BCI będą powszechnie używane w różnych środowiskach, od opieki zdrowotnej po edukację i rozrywkę. W tym kontekście wyniki tych badań są szczególnie istotne, oferując cenne wnioski, które mogą pomóc w kierowaniu rozwojem nadchodzących technologii BCI [26, 5]. Wyniki tych badań mają nie tylko znaczenie akademickie, ale również praktyczne implikacje dla rozwoju przyjaznych dla użytkownika, efektywnych i skutecznych systemów BCI do codziennego użytku.

Chociaż te badania przedstawiają obiecujące wyniki, ważne jest, aby uznać ich potencjalne ograniczenia. Na przykład, badanie opierało się na konkretnym typie urządzenia EEG i wykorzystywało określony zestaw metod przetwarzania sygnałów oraz modeli sieci neuronowych. Inne urządzenia lub metody mogą dostarczyć inne wyniki. Ponadto, badanie opierało się na konkretnym zestawie danych.

Przyszłe badania mogą czerpać wnioski z tego eksperymentu, eksplorując inne filtry wygładzające, używając różnych urządzeń EEG lub stosując metody do analizy innych sygnałów biomedycznych. Mogą również badać inne metody ekstrakcji cech lub modele sieci neuronowych. Ponadto, przyszłe badania mogą dążyć do opracowania bardziej przyjaznych dla użytkownika i efektywnych

systemów BCI na podstawie wyników tych badań. Może to obejmować poprawę sprzętu, tworzenie lepszego oprogramowania lub opracowywanie bardziej efektywnych protokołów zbierania i analizy danych.

Podsumowując, wyniki eksperymentów wykazały, że model GRU osiągnął najwyższą średnią dokładność (68%) w klasyfikacji stanów umysłowych na podstawie sygnałów EEG. Filtr wygładzający Savitzky'ego-Golaya okazał się wysoce skuteczny w przetwarzaniu danych EEG z urządzeń konsumenckich.

5.2 Kluczowe osiągnięcia

W tej rozprawie autor wniósł wkład do dziedziny inteligentnego monitorowania i cyfrowej analizy sygnałów biomedycznych, ze szczególnym naciskiem na nieinwazyjną stymulację mózgu. Poniżej przedstawiono kluczowe osiągnięcia tych badań:

- **Zbiór danych MUSE:** Autorka samodzielnie zaprojektowała scenariusze eksperymentalne, zebrała dane i przygotowała cały zestaw danych. Takie podejście zapewniło wysoki poziom kontroli nad warunkami eksperymentalnymi i jakością danych. Autorka eksperymentowała również z różnymi zestawami danych, w tym światłem stroboskopowym [9] i różnymi bodźcami audiowizualnymi, używając różnych urządzeń różnych marek. Te doświadczenia zapewniły kompleksowe zrozumienie wpływu różnych bodźców na wydajność poznawczą. Podkreśla to zaangażowanie i wiedzę autorki w prowadzeniu kompleksowych badań EEG oraz zdolność do adaptacji i innowacji w różnych ustawieniach eksperymentalnych
- **Wykorzystanie różnych modeli głębokich sieci neuronowych:** Badania opracowały i zastosowały modele głębokiego uczenia, w tym DNN, CNN, GRU, LSTM, RNN i Deep CNN, do klasyfikacji stanów umysłowych na podstawie sygnałów EEG. Wykazano, że te modele mogą dokładnie klasyfikować stany umysłowe. To osiągnięcie jest zgodne z hipotezą, pokazującą, że sieci neuronowe mogą skutecznie klasyfikować cechy sygnału EEG, umożliwiając wybór odpowiednich metod stymulacji mózgu.
- **Analiza kombinacji technik przetwarzania sygnałów:** Badania wykorzystały zaawansowane metody cyfrowego przetwarzania sygnałów, takie jak ekstrakcja cech i techniki preprocessingu, do analizy sygnałów EEG. Te techniki przyczyniły się do skutecznej klasyfikacji stanów umysłowych i dalszych badań. To wspiera tezę, pokazując znaczenie zaawansowanego przetwarzania sygnałów w identyfikacji efektywnych metod stymulacji mózgu. Kombinacja tych technik oferuje unikalną perspektywę na analizę sygnałów EEG.
- **Wybór efektywnego filtra wygładzającego:** Jednym z głównych osiągnięć tych badań jest wdrożenie i ocena filtra wygładzającego Savitzky-Golay. Ten filtr okazał się wysoce skuteczny w przetwarzaniu danych EEG z urządzeń konsumenckich. Poprzez staranny wybór i dostosowanie jego parametrów, filtr skutecznie równoważy redukcję szumów i zachowanie danych, co czyni go najbardziej odpowiednią opcją do tego zastosowania. To osiągnięcie wspiera tezę, zapewniając niezawodną metodę wstępnego przetwarzania sygnałów EEG, co jest kluczowe dla dokładnej analizy i klasyfikacji. Jego skuteczność podkreśla potencjał do ogólnego zastosowania w badaniach EEG.

- **Wpływ na dziedzinę interfejsów mózg-komputer:** Takie systemy mają potencjalne zastosowania w opiece zdrowotnej, edukacji, rozrywce, systemach sterowania i zwiększaniu wydajności poznawczej w różnych zadaniach. To osiągnięcie wspiera hipotezę, pokazując praktyczne zastosowania badań w rzeczywistych scenariuszach. Praktyczne implikacje tych badań torują drogę do przyszłych innowacji w technologii BCI.
- **Kompleksowe badanie i zastosowane metodologie:** Przeprowadzono dokładne badanie analizy sygnałów EEG, dzieląc się metodologiami i wynikami, które mogą służyć jako odniesienie do przyszłych badań w tej dziedzinie. Obejmuje to ocenę różnych modeli na podstawie ich średniej dokładności i czasu treningu oraz porównanie różnych filtrów wygładzających i metod ekstrakcji cech. Przygotowano również obszerny przegląd, zawierający podstawy aktualnej wiedzy z zakresu biologii mózgu, EEG, BCI, przetwarzania sygnałów, sztucznej inteligencji i modeli sieci neuronowych. To osiągnięcie jest zgodne z tezą, zapewniając pełne zrozumienie metod używanych w analizie sygnałów EEG. To kompleksowe podejście zapewnia wiarygodność i powtarzalność wyników.
- **Metody stymulacji:** Eksperyment zbadała wpływ różnych bodźców dźwiękowych na wydajność poznawczą, dostarczając cennych wglądów w to, jak stymulacja słuchowa może wpływać na stany umysłowe. Te badania otwierają nowe możliwości wykorzystania bodźców słuchowych do zwiększania wydajności poznawczej i rozwoju bardziej efektywnych systemów BCI. To wspiera hipotezę, pokazując potencjał wykorzystania różnych bodźców do wpływania na stany umysłowe i emocjonalne. Badanie bodźców słuchowych oferuje nowatorskie podejście do zwiększania wydajności poznawczej.
- **Interdyscyplinarne podejście:** Badania połączyły wiedzę z różnych dziedzin, w tym neuro nauki, informatyki, inżynierii biomedycznej, automatyki i systemów sterowania, aby opracować kompleksowe podejście do analizy sygnałów EEG i stymulacji mózgu. To interdyscyplinarne podejście zwiększa ogólny wpływ badań i wspiera tezę, integrując różnorodne perspektywy i metodologie. Interdyscyplinarny charakter badań umożliwia współpracę i innowacje, szczególnie w inżynierii biomedycznej, neuronauce, sztucznej inteligencji, automatyce i systemach sterowania.
- **Wkład w dziedzinę neuronauki:** Badania wykazały skuteczność modeli sieci neuronowych w klasyfikacji stanów umysłowych na podstawie danych EEG, przyczyniając się do rozwoju neuronauki. Te badania stanowią podstawę do przyszłych badań nad wykorzystaniem AI w neuronauce i rozwoju bardziej zaawansowanych interfejsów mózg-komputer. To osiągnięcie jest zgodne zarówno z tezą, jak i hipotezą, pokazując szerszy wpływ badań neuronaukowych. Ten wkład podkreśla interdyscyplinarny charakter badań, łącząc AI i neuronaukę.
- **Walidacja z danymi rzeczywistymi:** Przeprowadzono eksperymenty z wykorzystaniem rzeczywistych danych EEG z urządzeń konsumenckich, walidując skuteczność proponowanych metod w praktycznych scenariuszach. To osiągnięcie podkreśla zastosowanie badań w rzeczywistych warunkach i wspiera tezę, pokazując solidność metod. Walidacja z danymi rzeczywistymi zapewnia praktyczną istotność wyników.

- **Potencjał do przyszłych zastosowań:** Badania zidentyfikowały potencjalne przyszłe zastosowania w systemach modulacji nastroju i stanu umysłowego w czasie rzeczywistym, zapewniając podstawę do opracowania praktycznych narzędzi i technologii. To osiągnięcie jest zgodne z hipotezą, pokazując potencjał przyszłych zastosowań w czasie rzeczywistym na podstawie wyników badań. Potencjalne zastosowania tych badań podkreślają ich długoterminowy wpływ i znaczenie.

Bibliografia

- [1] Rebecca L Acabchuk, Mareyna A Simon, Spencer Low, Julie M Brisson, and Blair T Johnson. Measuring meditation progress with a consumer-grade eeg device: Caution from a randomized controlled trial. *Mindfulness*, pages 1–14, 2020. [str. 23]
- [2] Deepshikha Acharya, Asha Rani, Shivangi Agarwal, and Vijander Singh. Application of adaptive savitzky–golay filter for eeg signal processing. *Perspectives in science*, 8:677–679, 2016. [str. 23]
- [3] Turkey Alotaiby, Fathi E Abd El-Samie, Saleh A Alshebeili, and Ishtiaq Ahmad. A review of channel selection algorithms for eeg signal processing. *EURASIP Journal on Advances in Signal Processing*, 2015(1):66, 2015. [str. 6]
- [4] Ali Bashashati, Mehrdad Fatourehchi, Rabab K Ward, and Gary E Birch. A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals. *Journal of Neural engineering*, 9(3):031004, 2012. [str. 27]
- [5] Abdelkader Nasreddine Belkacem et al. Brain computer interfaces for improving the quality of life of older adults and elderly patients. *Frontiers in Neuroscience*, 14, 2020. [str. 27]
- [6] Natalia Browarska, Aleksandra Kawala-Sterniuk, and Jarosław Zygarlicki. Initial study on changes in activity of brain waves during audio stimulation using noninvasive brain–computer interfaces: choosing the appropriate filtering method. *Bio-Algorithms and Med-Systems*, 1(ahead-of-print), 2020. [str. 23, 24]
- [7] Natalia Browarska, Aleksandra Kawala-Sterniuk, Jaroslaw Zygarlicki, Michal Podpora, Mariusz Pelc, Radek Martinek, and Edward Jacek Gorzelańczyk. Comparison of smoothing filters' influence on quality of data recorded with the emotiv epoc flex brain–computer interface headset during audio stimulation. *Brain Sciences*, 11(1):98, 2021. [str. 5, 6, 11, 23, 24]
- [8] Natalia Browarska and Tomasz Stach. System to communicate disabled people with environment using brain–computer interfaces. In *International Scientific Conference BCI 2018 Opole*, pages 150–157. Springer, 2018. [str. 26]
- [9] Natalia Browarska, J. Zygarlicki, M. Pelc, M. Niemczynowicz, R. Martinek, E. Gorzelańczyk, M. Zygarlicka, and A. Kawala-Sterniuk. Initial study and concept on analysis of acute exposure to stroboscope light as a trigger for desired brain activity frequency. In *37th International Business Information Management Association (IBIMA)*, 2021. [str. 28]

- [10] Natalia Browarska, Jarosław Zygarlicki, Mariusz Pelc, Michał Niemczynowicz, Małgorzata Zygarlicka, and Aleksandra Kawala-Sterniuk. Pilot study on using innovative counting peaks method for assessment purposes of the eeg data recorded from a single-channel non-invasive brain-computer interface. In *2021 25th International Conference on Methods and Models in Automation and Robotics (MMAR)*, pages 68–72. IEEE, 2021. [str. 11, 23, 24]
- [11] Aykut Diker, Engin Avci, Erkan Tanyildizi, and Mehmet Gedikpinar. A novel ecg signal classification method using dea-elm. *Medical Hypotheses*, 136:109515, 2020. [str. 23]
- [12] Emotiv. *Emotiv Flex Website*, 2020. <https://www.emotiv.com/epoc-flex>. [str. 5, 6]
- [13] Enrique Fernandez-Blanco, Daniel Rivero, and Alejandro Pazos. Convolutional neural networks for sleep stage scoring on a two-channel eeg signal. *Soft Computing*, 24(6):4067–4079, 2020. [str. 6]
- [14] Qi Ge, Zhuo-Chen Lin, Yong-Xiang Gao, and Jin-Xin Zhang. A robust discriminant framework based on functional biomarkers of eeg and its potential for diagnosis of alzheimer's disease. In *Healthcare*, volume 8, page 476. Multidisciplinary Digital Publishing Institute, 2020. [str. 6]
- [15] Dharmendra Gurve, Denis Delisle-Rodriguez, Maria Romero-Laiseca, Vivianne Cardoso, Flavia Loterio, Teodiano Bastos, and Sri Krishnan. Subject-specific eeg channel selection using non-negative matrix factorization for lower-limb motor imagery recognition. *Journal of Neural Engineering*, 17(2):026029, 2020. [str. 6]
- [16] Aleksandra Kawala-Janik. *Efficiency evaluation of external environments control using bio-signals*. PhD thesis, University of Greenwich, 2013. [str. 6]
- [17] Aleksandra Kawala-Janik, Mariusz Pelc, and Michal Podpora. Method for eeg signals pattern recognition in embedded systems. *Elektronika ir Elektrotechnika*, 21(3):3–9, 2015. [str. 6, 11, 23]
- [18] Aleksandra Kawala-Sterniuk, Natalia Browarska, Jarosław Zygarlicki, Marcin Kamiński, Barbara Grochowicz, and Mariusz Pelc. The use of counting peaks method for the purpose of smoothing filtering efficiency assessment in analysis of electroencephalography data. In *2021 25th International Conference on Methods and Models in Automation and Robotics (MMAR)*, pages 73–78. IEEE, 2021. [str. 11, 23, 24]
- [19] Aleksandra Kawala-Sterniuk, Michal Podpora, Mariusz Pelc, Monika Blaszczyzyn, Edward Jacek Gorzelanczyk, Radek Martinek, and Stepan Ozana. Comparison of smoothing filters in analysis of eeg data for the medical diagnostics purposes. *Sensors*, 20(3):807, 2020. [str. 6, 8, 23, 24]
- [20] Dean J Krusienski, Eric W Sellers, Dennis J McFarland, Theresa M Vaughan, and Jonathan R Wolpaw. Toward enhanced p300 speller performance. *Journal of neuroscience methods*, 167(1):15–21, 2008. [str. 6]
- [21] Jinuk Kwon, Jaeyoung Shin, and Chang-Hwan Im. Toward a compact hybrid brain-computer interface (bci): Performance evaluation of multi-class hybrid eeg-fnirs bcis with limited number of channels. *Plos one*, 15(3):e0230491, 2020. [str. 6]

- [22] Ji-Seon Bang Seong-Whan Lee. Motor imagery classification based on cnn-gru network with spatio-temporal feature representation. *Pattern Recognition*, 2022. [str. 24]
- [23] Yang Liu, Zongtan Zhou, and Dewen Hu. Gaze independent brain-computer speller with covert visual search tasks. *Clinical Neurophysiology*, 122(6):1127–1136, 2011. [str. 6]
- [24] Fabien Lotte, Laurent Bougrain, Andrzej Cichocki, Maureen Clerc, Marco Congedo, Alain Rakotomamonjy, and Florian Yger. A review of classification algorithms for eeg-based brain-computer interfaces: a 10 year update. *Journal of neural engineering*, 15(3):031005, 2018. [str. 27]
- [25] Shalini Mahato, Nishant Goyal, Daya Ram, and Sanchita Paul. Detection of depression and scaling of severity using six channel eeg data. *Journal of Medical Systems*, 44:1–12, 2020. [str. 6]
- [26] Baraka Maiseli et al. Brain-computer interface: trend, challenges, and threats. *Brain Informatics*, 10(20), 2023. [str. 27]
- [27] Rytis Maskeliunas, Robertas Damasevicius, Ignas Martisius, and Mindaugas Vasiljevas. Consumer-grade eeg devices: are they usable for control tasks? *PeerJ*, 4:e1746, 2016. [str. 23]
- [28] Bishwajit Roy others. Hybrid deep learning approach for stress detection using decomposed eeg signals. *Diagnostics*, 2023. [str. 24]
- [29] Farhad Mortezapour Shiri others. A comprehensive overview and comparative analysis on deep learning models: Cnn, rnn, lstm, gru. *arXiv preprint arXiv:2305.17473*, 2023. [str. 24]
- [30] Hafeez Ullah Amin others. Feature extraction and classification for eeg signals using wavelet transform and machine learning techniques. *Australasian Physical Engineering Sciences in Medicine*, 2015. [str. 24]
- [31] M.A. Ganaie others. Ensemble deep learning: A review. *Engineering Applications of Artificial Intelligence*, 2022. [str. 24]
- [32] Md Asadur Rahman, Md Mahmudul Haque, Anika Anjum, Md Nurunnabi Mollah, and Mo-hiuddin Ahmad. Classification of motor imagery events from prefrontal hemodynamics for bci application. In *Proceedings of International Joint Conference on Computational Intelligence*, pages 11–23. Springer, 2020. [str. 23]
- [33] Elena Ratti, Shani Waninger, Chris Berka, Giulio Ruffini, and Ajay Verma. Comparison of medical and consumer wireless eeg systems for use in clinical trials. *Frontiers in human neuroscience*, 11:398, 2017. [str. 23, 24]
- [34] Veronica Piccialli Marco Sciandrone. Nonlinear optimization and support vector machines. *Annals of Operations Research*, 2022. [str. 24]
- [35] Manisha Singla K. K. Shukla. Robust statistics-based support vector machine and its variants: a survey. *Neural Computing and Applications*, 2019. [str. 24]

- [36] Tomasz Stach, Natalia Browarska, and Aleksandra Kawala-Janik. Initial study on using emotiv epoc+ neuroheadset as a control device for picture script-based communicators. *IFAC-PapersOnLine*, 51(6):180–184, 2018. [str. 26]
- [37] M Teplan, A Krakovska, and S Štolc. Eeg responses to long-term audio–visual stimulation. *International journal of psychophysiology*, 59(2):81–90, 2006. [str. 5]
- [38] Nikolas S Williams, Genevieve M McArthur, Bianca de Wit, George Ibrahim, and Nicholas A Badcock. A validation of emotiv epoc flex saline for eeg and erp research. *PeerJ*, 8:e9713, 2020. [str. 6]
- [39] Minpeng Xu, Hongzhi Qi, Lan Ma, Changcheng Sun, Lixin Zhang, Baikun Wan, Tao Yin, and Dong Ming. Channel selection based on phase measurement in p300-based brain-computer interface. *PloS one*, 8(4):e60608, 2013. [str. 6]
- [40] Jian-Zhong Xue, Hui Zhang, Chong-Xun Zheng, and Xiang-Guo Yan. Wavelet packet transform for feature extraction of eeg during mental tasks. In *Proceedings of the 2003 International Conference on Machine Learning and Cybernetics (IEEE Cat. No. 03EX693)*, volume 1, pages 360–363. IEEE, 2003. [str. 6]
- [41] Mahendra Yadava, Pradeep Kumar, Rajkumar Saini, Partha Pratim Roy, and Debi Prosad Dogra. Analysis of eeg signals and its application to neuromarketing. *Multimedia Tools and Applications*, 76(18):19087–19111, 2017. [str. 23]
- [42] Tomasz Piotr Zieliński. *Cyfrowe przetwarzanie sygnałów: od teorii do zastosowań*. Wydawnictwa Komunikacji Łączności, 2005. [str. 6]