

**POLITECHNIKA WARSZAWSKA**

**Wydział Elektryczny**

**ROZPRAWA DOKTORSKA**

mgr inż. Marcin Kołodziej

**Przetwarzanie, analiza i klasyfikacja sygnału EEG  
na użytek interfejsu mózg-komputer**

Promotor

Prof. dr hab. inż. Remigiusz J. Rak

Warszawa 2011



*Serdecznie dziękuję mojemu promotorowi,  
Panu prof. dr hab. inż. Remigiuszowi Rakowi  
za wsparcie i wszechstronną pomoc w trakcie realizacji pracy*

*Dziękuję również Kolegom z zespołu  
w szczególności Panu dr inż. Andrzejowi Majkowskiemu  
za współpracę i cenne dyskusje*



***Rodzinie i przyjaciołom***



## *Przetwarzanie, analiza i klasyfikacja sygnału EEG na użytek interfejsu mózg-komputer*

### **Streszczenie**

Głównym celem pracy jest porównanie różnych typów algorytmów przetwarzania, analizy i klasyfikacji sygnału EEG na użytek asynchronicznego interfejsu mózg-komputer. Ważnym elementem rozprawy jest próba dokonania wyboru jak najlepszego zestawu elektrod (w sensie ich rozmieszczenia na powierzchni głowy), w celu doboru odpowiednich algorytmów ekstrakcji, selekcji oraz klasyfikacji sygnału EEG. Dlatego też najwięcej uwagi poświęcono kwestii minimalizacji liczby elektrod oraz sprawdzeniu, które algorytmy są najbardziej przydatne, do uprzednio ograniczonego zbioru elektrod. Badania, które podjęto w trakcie eksperymentów wymagały zastosowania wielu różnych metod przetwarzania, analizy i klasyfikacji sygnału. Ocena efektywności wybranych metod przetwarzania sygnału oraz ekstrakcji czy selekcji cech, możliwa była dopiero w końcowym etapie - to jest po klasyfikacji. Wnioski otrzymane podczas eksperymentów pozwoliły na wyselekcjonowanie zaledwie 8 elektrod i implementację przy użyciu tych elektrod asynchronicznego interfejsu mózg-komputer. Zaprojektowany interfejs został przetestowany w działaniu na wybranym użytkowniku i spełnił swoje zadanie.

## *Preprocessing, analysis and classification of EEG signals for Brain-Computer Interface*

### **Abstract**

The main aim of this thesis is to compare different types of algorithms for EEG signal analysis and classification for the use in asynchronous brain-computer interfaces. An important part of the thesis is to try to choose the best set of electrodes (in terms of their distribution on the head surface), in order to optimize the extraction, selection and classification algorithms. Therefore, the author devoted much attention to the minimization of the number of electrodes and the verification of which algorithms are most useful to the previously limited set of electrodes. Evaluation of the effectiveness of the chosen method of signal processing was possible only in the final stage - that is, after classification. Results obtained during the experiments allowed the selection of only 8 electrodes and an asynchronous brain-computer interface was implemented using these electrodes. The designed interface has been tested in action on a volunteer and fulfilled its task.





---

# SPIS TREŚCI

---

<b>1. WSTĘP</b> .....	<b>11</b>
1.1 Cel i teza pracy .....	12
<b>2. INTERFEJS MÓZG-KOMPUTER</b> .....	<b>14</b>
2.1 Nowoczesne interfejsy człowiek-komputer.....	14
2.2 Potrzeba i zastosowanie komunikacji bezpośredniej: mózg-komputer .....	16
2.3 Historia i definicja interfejsu mózg-komputer (BCI) .....	20
2.4 Metody badania aktywności mózgu .....	21
2.5 Interfejsy synchroniczne i asynchroniczne.....	24
2.6 Etapy działania interfejsów mózg-komputer .....	25
<b>3. POTENCJAŁY MÓZGOWE WYKORZYSTYWANE W BCI</b> .....	<b>28</b>
3.1 Elektroencefalografia.....	28
3.2 Rytm EEG .....	31
3.3 Potencjały wywołane .....	32
3.3.1 P300 .....	33
3.3.2 Stabilny potencjał wywołany wzrokowo (SSVEP) .....	37
3.4 Potencjały mózgowie związane z ruchem .....	39
3.5 Specyficzne aktywności myślowe .....	42
3.6 Potencjały korowe wolnozmiennie (SCPSs).....	43
3.7 Miary oceny jakości systemów BCI.....	43
<b>4. AKWIZYCJA SYGNAŁU EEG</b> .....	<b>47</b>
4.1 Procedura rejestracji sygnału EEG .....	47
4.2 Artefakty w EEG .....	49
4.3 Charakterystyka danych eksperymentalnych .....	52
4.3.1 Opis danych z ogólnodostępnej bazy.....	53
4.3.2 Opis danych własnych .....	53
<b>5. PRZETWARZANIE WSTĘPNE SYGNAŁU</b> .....	<b>55</b>
5.1 Filtracja częstotliwościowa.....	55
5.2 Filtry przestrzenne .....	58
5.2.1 Filtry Laplace'a.....	58
5.2.2 Wspólny uśredniony potencjał odniesienia .....	60
5.2.3 Wspólne wzorce przestrzenne.....	61
5.3 Ślepa separacja sygnału .....	64
5.3.1 Wybielanie sygnału.....	66
5.3.2 Analiza składowych niezależnych .....	70
<b>6. EKSTRAKCYJA CECH Z SYGNAŁU EEG</b> .....	<b>77</b>

6.1	Wariancja.....	78
6.2	Widmo sygnału.....	80
6.3	Statystyki wyższych rzędów detali transformacji falkowej.....	83
6.4	Współczynniki modelu autoregresyjnego (AR) .....	86
6.5	Oprogramowanie autorskie "Feature_Toolbox" .....	87
<b>7.</b>	<b>SELEKCJA CECH .....</b>	<b>90</b>
7.1	Metoda wizualnego wyboru elektrod .....	92
7.2	Metody rankingowe.....	94
7.2.1	T-statystyki .....	94
7.2.2	Współczynnik K-Fischera.....	97
7.2.3	Korelacja wzajemna.....	100
7.3	Sekwencyjne przeszukiwanie w przód (SFS).....	103
7.4	Algorytmy genetyczne.....	107
7.5	Metody transformacyjne.....	112
7.5.1	Analiza składowych głównych (PCA).....	113
7.5.2	Analiza Dyskryminacyjna (LDA, QDA) .....	115
<b>8.</b>	<b>KLASYFIKATORY EEG .....</b>	<b>120</b>
8.1	Klasyfikator K- najbliższych sąsiadów (K-NN).....	122
8.2	Analiza dyskryminacyjna (LDA, QDA).....	124
8.3	Sieci neuronowe MLP .....	125
8.4	Maszyna wektorów wspierających (SVM).....	132
8.5	Inne parametry wpływające na trafność klasyfikacji.....	137
<b>9.</b>	<b>EKSPERYMENTY FINALNE .....</b>	<b>142</b>
9.1	Ograniczenie liczby elektrod .....	144
9.2	Przetwarzanie wstępne .....	144
9.3	Ekstrakcja cech.....	147
9.4	Selekcja cech .....	148
9.5	Klasyfikacja .....	151
9.6	Badania kompleksowe dla wszystkich użytkowników.....	153
9.7	Eksperymenty na danych własnych.....	154
9.8	Wnioski z eksperymentów <i>off-line</i> .....	156
9.9	Eksperymenty w czasie rzeczywistym .....	158
<b>10.</b>	<b>ZAKOŃCZENIE .....</b>	<b>161</b>
	<b>BIBLIOGRAFIA .....</b>	<b>163</b>
	<b>D1. Parametry wzmacniacza i elektrod.....</b>	<b>172</b>
	<b>D2. Wykaz symboli oznaczeń i skrótów .....</b>	<b>174</b>

---

# 1. WSTĘP

---

Kilka lat temu, trudno było przewidzieć, że tak wielkie zainteresowanie wzbudzi tematyka *interfejsu mózg-komputer*. Dzisiaj możemy patrzeć nań, już nie jak na ciekawostkę, ale jak na funkcjonalny interfejs umożliwiający niejednokrotnie jedyną formę komunikacji człowieka z otaczającym go światem. Zagadnienie interfejsu mózg-komputer (*Brain-Computer Interface - BCI*) pojawiało się już w latach siedemdziesiątych ubiegłego wieku, tym nie mniej, dopiero znaczący rozwój technologii, jaki dokonał się w ostatnich latach, umożliwił praktyczną jego realizację.

Zagadnienie interfejsu mózg-komputer jest problemem interdyscyplinarnym, a zakres pracy obejmuje tylko wybrane jego elementy, związane z przetwarzaniem, analizą i klasyfikacją sygnału EEG. Autor musiał poznać i uwzględnić zagadnienia z zakresu wielu dziedzin pozatechnicznych, choćby psychologii czy medycyny. Taka wiedza jest nieodzowna do tego, aby móc skutecznie konstruować interfejsy mózg-komputer. Dlatego, aby w pełni zrozumieć problematykę systemu BCI, również te zagadnienia pokrótce zostaną omówione w pracy.

Autor skupił uwagę głównie na interfejsie asynchronicznym. Interfejs taki wymaga analizowania fal mózgowych w czasie rzeczywistym bez wykorzystania tzw. potencjałów wywołanych. Głównym zadaniem było porównanie różnych typów algorytmów przetwarzania, analizy i klasyfikacji sygnału na użytek interfejsu asynchronicznego. Ważnym elementem pracy jest próba wyselekcjonowania jak najlepszego zestawu elektrod (w sensie ich rozmieszczenia) w celu dostosowania algorytmów ekstrakcji, selekcji i klasyfikacji cech. Dlatego też najwięcej uwagi autor poświęca właśnie minimalizacji liczby elektrod oraz sprawdzeniu, które algorytmy są najbardziej przydatne dla ograniczonego zbioru elektrod.

Badania i eksperymenty wykonane w pracy przeprowadzono w ramach projektu MNiSW: pt.: *Opracowanie efektywnych metod akwizycji i nowych algorytmów przetwarzania sygnału EEG na użytek interfejsów mózg-komputer*, Nr N 510526239 oraz w ramach Grantu Rektorskiego Promotorskiego pt.: *Przetwarzanie analiza i klasyfikacja sygnału EEG na potrzeby interfejsu mózg-komputer*. Prace wykonano również z wykorzystaniem środków Europejskiego Funduszu Społecznego i Budżetu Państwa w ramach Zintegrowanego programu Operacyjnego Rozwoju Regionalnego, działania 2.6 "Regionalne Strategie

*Innowacyjne i transfer wiedzy" - projektu własnego Województwa Mazowieckiego "Mazowieckie Stypendium Doktoranckie".*

## **1.1 Cel i teza pracy**

Na potrzeby pracy doktorskiej autor sformułował tezę:

*Odpowiedni dobór algorytmów przetwarzania, analizy i klasyfikacji sygnału EEG pozwala na znaczące ograniczenie liczby elektrod na użytek asynchronicznego interfejsu mózg-komputer.*

Badania, które podejmował wymagały zastosowania wielu skomplikowanych metod przetwarzania, analizy i klasyfikacji sygnału. Ocena efektywności wybranej metody przetwarzania sygnału, ekstrakcji czy selekcji cech możliwa jest dopiero w końcowym etapie - to jest klasyfikacji. Ogromnie trudnym zadaniem było opisywanie, czy też porównanie algorytmów bez przechodzenia całego toru przetwarzania sygnału. Warto zaznaczyć, że ze względu na objętość, nie było możliwe przedstawienie wszystkich wyników otrzymanych w czasie eksperymentów. Dlatego autor skoncentrował się na opisie wybranych eksperymentów, przeprowadzonych z nastawieniem na minimalizację liczby elektrod.

Praca składa się z rozdziałów teoretycznych (rozd. 2 i 3) oraz praktycznych, doświadczalnych (rozd. 4-9). Rozdziały 2 i 3 zawierają opis teorii dotyczącej interfejsów mózg-komputer oraz wskazanie najistotniejszych problemów stojących na drodze do ich upowszechnienia. W drugim rozdziale autor starał się wykazać, że nie ma uniwersalnych interfejsów do komunikacji człowieka z maszyną oraz wskazać na konieczność wykorzystania interfejsu mózg-komputer w pewnych konkretnych przypadkach. W pozostałych rozdziałach opisano problemy, z którymi zetknął się autor w trakcie badań. I tak w rozdziale 4, opisany został wykorzystywany w trakcie badań materiał doświadczalny (zarejestrowane sygnały EEG). Kolejny rozdział poświęcony jest krytycznemu opisowi metod wstępnego przetwarzania sygnału EEG, wskazane są ich wady i zalety. W rozdziale 6, dotyczącym ekstrakcji cech, autor przedstawia metody generowania cech z sygnału EEG zarówno za pomocą znanych jak i nowo zaproponowanych metod przetwarzania sygnału. Wszystkie wskazane metody były później stosowane podczas eksperymentów. W kolejnym rozdziale (rozd. 7) przedstawiono wykorzystane w trakcie badań metody selekcji cech. Oprócz opisu algorytmów i ich analizy, zawarte są w tym rozdziale wyniki prowadzące do skutecznego ograniczenia liczby elektrod i wskazane metody radzenia sobie z nadmiarowością cech. W rozdziale 8 autor opisuje stosowane metody klasyfikacji i rozpoznawania wzorców oraz przedstawia wyniki otrzymane podczas eksperymentów.

Ważną częścią rozdziału jest zestawienie metod testowania klasyfikatorów. W rozdziale 9 zawarte są opisy eksperymentów przeprowadzone na wyselekcjonowanej liczbie tylko ośmiu elektrod. Autor, ponownie bada użyteczność metod przetwarzania sygnału, ekstrakcji i selekcji oraz klasyfikacji sygnału EEG dla ograniczonego zbioru elektrod. Wyniki zawierają wykaz błędów klasyfikacji. Kolejnym etapem jest przetestowanie wybranego algorytmu dla większej liczby użytkowników. Wreszcie, kompleksowe przebadanie algorytmu z wykorzystaniem zarejestrowanych we własnym zakresie sygnałów EEG oraz propozycja i implementacja algorytmu działającego w czasie rzeczywistym.

---

## 2. INTERFEJS MÓZG-KOMPUTER

---

Na przestrzeni dziejów, obsługa różnego rodzaju maszyn odbywała się na bardzo różne sposoby. Najstarsze maszyny sterowano za pomocą dźwigni i korb. Kolejnym etapem było zastosowanie kart perforowanych. Za twórcę tej koncepcji uważa się Joseph Jacquarda. W 1805 roku użył on tabliczek do sterowania nimi podczas tkania, co pozwalało tworzyć tkaninę o powtarzalnym wzorze.

Obecnie najczęściej komputer, użyty do sterowania maszyną, stanowi ogniwo pośrednie w kontakcie człowiek-maszyna. Stąd komunikacja człowiek-komputer (*Human-Computer Interaction* - HCI) nabiera nowego znaczenia i jest elementem nieodzownym naszego życia.

Początkowo, aż do lat 80. XX wieku, do programowania komputerów używane były karty perforowane. Dopiero w 1984 roku wynaleziona została przez Douglasa Engelbarta, dobrze wszystkim znana mysz komputerowa. Stosowana do tej pory umożliwia poruszanie kursorem po ekranie monitora poprzez przesuwanie jej po płaskiej powierzchni. Oczywiście nieodzownym elementem jest klawiatura, którą posługujemy się w celu wprowadzania poleceń i tekstu.

### 2.1 Nowoczesne interfejsy człowiek-komputer

Aktualnie, coraz większą popularność zdobywa interfejs dotykowy (*touchscreen*). Najczęściej, interfejs taki kojarzony jest z ekranami dotykowymi stosowanymi w urządzeniach przenośnych. Istnieje kilka typów konstrukcji takich ekranów. Zwykle do ich budowy wykorzystywane są nakładki pojemnościowe i rezystancyjne. W innych typach ekranów dotykowych wykorzystuje się na przykład fakt przerywania strumienia światła podczerwonego emitowanego przez diody LED. Istnieją również konstrukcje, które działają na zasadzie zaburzania fali akustycznej, rozchodzącej się na powierzchni ekranu wskutek dotyku użytkownika.

Zupełnie innym podejściem, jest interfejs wielodotykowy lub wielopunktowy (*multi-touch*). Technologia ta pozwala na obsługę interfejsów graficznych więcej niż jednym palcem. Takie podejście umożliwia tworzenie interaktywnych interfejsów, ale zmusza programistów do pisania aplikacji w inny niż dotychczas sposób. Twórca programowania oprócz wykrycia samego miejsca dotyku ekranu, musi brać również pod uwagę sposób

zmiany jego położenia. Takie wykonywanie gestów na powierzchni ekranu jest bardzo naturalne i umożliwia na przykład przeglądanie zdjęć czy grę zespołową.

Bardzo ciekawym podejściem jest wykorzystanie interfejsów z rozpoznawaniem gestów użytkownika przez analizę obrazu zarejestrowanego za pomocą kamery. Zasadniczą rolę, w jakości takiego systemu odgrywa przetwarzanie i analiza obrazu. Jedną z największych trudności w tym przypadku, jest odróżnienie obiektu jako źródła gestów od otoczenia zmieniającego się w czasie. Istnieją już systemy, które wykonywane gesty, na przykład ruch rąk, dłoni, czy palców, odczytują jako odpowiednie polecenia. Trwają prace nad zastosowaniem tej technologii do rozpoznawania języka migowego. Już opracowano i wdrożono systemy pozwalające na zdalne sterowanie za pomocą gestów urządzeniami domowymi, na przykład odbiornikiem TV.

Kilka firm komercyjnych już opracowało i z powodzeniem zastosowało technologię *eyetrackingu*. Zasada działania takich systemów sprowadza się do analizy obrazu oczu i „wskazania” miejsca, na które patrzy użytkownik. Opracowane systemy są nadal zbyt drogie by mogły doczekać się powszechnego zastosowania. Kilka ośrodków naukowych z krajów UE połączyło siły w ramach projektu pod nazwą COGAIN. Celem projektu jest opracowanie efektywnych i ekonomicznych technologii opartych na *eyetrackingu*, przeznaczonych do wspomagania osób niepełnosprawnych. Zostanie opracowany system, składający się z niezależnych od siebie komponentów (na przykład kamer i oprogramowania). Użytkownik końcowy zaś będzie mógł złożyć „z klocków”, użyteczną dla niego konfigurację sprzętowo-programową, bez konieczności zakupu pełnego wyposażenia od jednego producenta.

Najbardziej naturalną dla człowieka formą komunikacji z otoczeniem jest mowa. Stąd pomysł wykorzystania mowy do sterowania komputerem. Próby związane z rozpoznawaniem mowy rozpoczęto już w roku 1952, kiedy to K. H. Davis, R. Biddulph, i S. Balashek opracowali system rozpoznawania wypowiedzianych cyfr. Rozpoznawanie mowy potocznej, pochodzącej od dowolnej osoby, jest bardzo złożonym problemem. Dlatego też stosuje się pewne uproszczenia polegające na rozpoznawaniu mowy konkretnej osoby lub zawężeniu rozpoznawanego zbioru słów [139]. W pierwszym przypadku poprzez sesję wstępną, algorytm uczy się rozpoznawać słowa czy też zwroty wypowiedziane przez konkretnego użytkownika. Taka sesja polega najczęściej na wielokrotnym powtarzaniu konkretnych fraz. W drugim przypadku tematyka rozpoznawanej mowy jest zawężana do konkretnej problematyki na przykład medycznej (zmniejszenie zasobu słów). Najczęściej rozpoznawanie mowy stosuje się do sterowania obiektami (wydawanie krótkich poleceń - rozkazów) lub do transkrypcji (zapis tekstu mówionego). Większość oprogramowania komercyjnego dla mowy

angielskiej osiąga trafność rzędu 98% a nawet 99%. Oczywiście tak duża skuteczność jest możliwa, gdy spełnione są pewne warunki zewnętrzne, na przykład brak szumów (tła) podczas rejestracji sygnału. Dla języka polskiego istnieją programy umożliwiające rozpoznanie od 50% do 90% słów.

Zupełnie inną formą komunikacji jest wykorzystanie biopotencjałów np. do sterowania protezą czy klawiaturą wirtualną. Najczęściej wykorzystywanymi, w tym przypadku, potencjałami są elektromiogram oraz elektrookulogram. Elektromiogram (*electromyogram*, EMG) to zapis sygnałów elektrycznych związanych z pracą mięśni. Elektrookulogram (*electrooculogram*, EOG) to zapis przebiegu napięcia występującego między przednim (dodatnim) a tylnym (ujemnym) biegunem gałki ocznej. Pobudzanie mięśni wywołuje zmianę biopotencjałów. W ten sposób, po odpowiednim treningu, można nauczyć się „generować” właściwe biosygnały i komunikować z komputerem. Interfejsy takie najczęściej przeznaczone są dla osób niepełnosprawnych. Najbardziej znaną na świecie osobą dotkniętą tym problemem jest Stephen Hawking. Cierpi on na stwardnienie zanikowe boczne. Choroba ta sprawiła, że jest on prawie całkowicie sparaliżowany, porusza się na wózku inwalidzkim. Komunikację ze światem umożliwia mu generator mowy sterowany ruchami gałek oczu (EOG).

Jak można zauważyć dysponujemy już całkiem szeroką gamą interfejsów człowiek-komputer. Nie ma jednego uniwersalnego interfejsu, który może spełnić wymagania i oczekiwania wszystkich użytkowników. Większość z dostępnych systemów zdaje egzamin w szczególnych przypadkach. Niektóre z nich, choć cechują się niskim poziomem transferu informacji człowiek-komputer (małą przepływnością danych), są używane, gdyż stanowią jedyną drogę komunikacji ze światem dla konkretnego użytkownika. Łatwo zauważyć, że może dochodzić do błędów w procesie komunikacji człowieka z maszyną. Z tego powodu często wymagany jest od użytkownika trening.

### **2.2 Potrzeba i zastosowanie komunikacji bezpośredniej: mózg-komputer**

Idealem interfejsu HCI byłaby komunikacja człowieka z maszyną „za pomocą myśli”. Jak dotychczas taki interfejs kojarzył się raczej z literaturą *science-fiction*. Obecne systemy BCI pracujące z wykorzystaniem sygnału EEG nie pozwalają na swobodną komunikację za pomocą "bezpośrednich myśli". Zasadniczym ograniczeniem tych interfejsów jest szybkość komunikacji. Zatem dlaczego podejmowane są tak olbrzymie wysiłki sporych zespołów



badawczych do usprawnienia ich działania? Do czego wykorzystujemy bezpośrednia informacje o pracy mózgu?

Możliwość bezpośredniej interakcji człowieka z komputerem (bez manualnej obsługi urządzeń peryferyjnych) otwiera nowe kanały przekazu informacji w medycynie, psychologii, technikach multimedialnych i wojskowych. Szczególne znaczenie mają tutaj zastosowania tego interfejsu w medycynie zarówno w aspekcie poznawczym, funkcjonowania ludzkiego mózgu, jak i praktycznym jako jedyna szansa rozwoju dla osób dotkniętych chorobami neurologicznymi. Interfejs mózg-komputer może pomóc w komunikacji ze światem zewnętrznym osobom w ciężkich stadiach chorób neurologicznych jak stwardnienie zanikowe boczne, udar mózgowy podkorowy, zespół Guillain-Barre'a, mózgowy porażenie dziecięce czy stwardnienie rozsiane [131]. Rocznie około dwa tysiące osób w Polsce (a we wszystkich krajach Unii Europejskiej około 24 tysiące) zapada na stwardnienie zanikowe boczne, neurodegeneracyjną chorobę układu nerwowego, która niszczy część centralnego układu nerwowego odpowiedzialną za ruch, nie zaburza natomiast czucia, zdolności poznawczych i intelektu. Osoby, które na nią zapadają, stopniowo tracą kontrolę nad własnym ciałem i w ciągu 2 do 3 lat osiągają stan, w którym nie mają żadnej możliwości komunikacji z otoczeniem. Kolejną grupą ludzi, którym należy zapewnić możliwość porozumiewania się z otoczeniem za pomocą BCI, jest ok. 14 tysięcy osób, jakie w ciągu roku w Polsce zapada na udary mózgu, a w szczególności udary pnia mózgu. Do wymienionych grup należałoby dołączyć ok. 1,2 tysiąca ofiar wypadków komunikacyjnych, w wyniku których doszło do uszkodzenia szyjnego odcinka rdzenia kręgowego [36]. W takich wypadkach interfejs mózg-komputer ma umożliwić prostą komunikację z otoczeniem, sterowanie protezami, wózkiem inwalidzkim czy wręcz inteligentnym budynkiem (rys 2.1 ).



Rys 2. 1. Interfejs mózg-komputer opracowany w National Institute of Biomedical Imaging and Bioengineering

Inną formą komunikacji bezpośredniej mózg-komputer jest również *neurofeedback*. Jest to jeden z rodzajów *biofeedbacku*, czyli biologicznego sprzężenia zwrotnego, pomagającego uzyskać samokontrolę nad funkcjami organizmu. Obejmuje on różnorodne techniki treningowe i terapeutyczne, usprawniające funkcje mózgu (koncentracja uwagi, opanowanie emocji, usprawnienie procesów myślowych, szybka nauka, pamięć, twórczość, sen). W *neurofeedbacku* wykorzystuje się sygnał EEG do oceny funkcji mózgu, zaś sprzężenie zwrotne do przesłania informacji o tym - do pacjenta (rys. 2.2).



Rys 2. 2. Typowa sesja neurofeedbacku (zdjęcie pochodzi ze strony doktora Daniela Rossa)

Sygnał EEG można również wykorzystać w konstrukcji wariografu. Z powodzeniem podjęto takie próby. Standardowo wariografy służą do analizy fizjologicznych reakcji organizmu człowieka, które są wykładnią emocji, jako reakcji na pewne bodźce zewnętrzne. Najczęściej rejestruje się takie wielkości jak ciśnienie krwi, puls, częstość oddechu, reakcję skórno-galwaniczną lub aktywność ruchową. Badania za pomocą wariografu muszą być przeprowadzane przez wykwalifikowane osoby. Alternatywą dla tego typu badań jest właśnie rejestracja tak zwanych potencjałów wywołanych (najczęściej P300), pojawiających się w sygnale EEG jako odpowiedź na wystąpienie określonego bodźca [94]. Zaobserwowano, że bodźce, rodzące skojarzenia z pewnymi zdarzeniami wywołującymi emocje (na przykład zdjęcia z miejsca zbrodni, uprzednio oglądanego), powodują silną reakcję, mającą wyraźne odzwierciedlenie w rejestrowanych sygnałach EEG.

Bezpośrednie reakcje mózgu na bodźce zewnętrzne wykorzystywane są również w neuromarketingu [97]. Stosuje się tam narzędzia stosowane w badaniach psychofizjologicznych. Dzięki nim można dobierać i optymalizować bodźce marketingowe, na przykład billboardy czy sekwencje filmowe. W praktyce, sprowadza się to do kilkukrotnego skrócenie czasu trwania ujęcia z filmu reklamowego.

Trwają prace nad wykorzystaniem sygnału EEG do predykcji napadów epileptycznych [141,142,143]. W szczególności chodzi o miary chaotyczności sygnału (na przykład wykładniki Lapunowa czy entropię). Specjalistyczny analizator EEG, po wystąpieniu charakterystycznych zmian w sygnale, mógłby generować odpowiedni sygnał ostrzegawczy przed zbliżającym się napadem padaczki. Umożliwiłoby to stosowne przygotowanie się do napadu, zażycie odpowiednich leków itp.

Zauważono, że zapis sygnału EEG wykonany podczas snu (polisomnografia) może zawierać cechy świadczące o predyspozycji do choroby alkoholowej [78]. W ocenie predyspozycji do nałogu posłużyć mogą również potencjały wywołane w szczególności załamek P300. Stwierdzono, że u osób z predyspozycją do alkoholizmu oraz innych nałogów jest on znacznie słabszy [111,24].

Zapis sygnału EEG, z powodzeniem wykorzystać też można w biometrii. Typowe biometryki takie jak: odciski palca, brzmienie głosu, wzór siatkówki oka nie są uniwersalne i mogą ulec zniszczeniu (otarcia skóry, rany, utrata głosu). Ponadto stwierdzono, że około 2-4% populacji nie ma tych biometryk (brak organów lub ich uszkodzenie) lub są one słabej jakości, co uniemożliwia rozpoznanie tych osób. Z drugiej strony wiadomo, że u każdego człowieka zawsze występuje praca mózgu (sygnał EEG) oraz serca (sygnał EKG). Ważny jest również fakt, że sygnał EEG występuje cały czas od narodzin do śmierci - bez przerwy. Co najważniejsze, każdy osobnik ma inną „konfigurację mózgu” (mózg ludzki składa się z około  $10^{11}$  neuronów i  $10^{15}$  synaps). Spontaniczna aktywność mózgu jest bardzo różna dla różnych osobników. Stąd sygnał EEG jest charakterystyczny, zawiera cechy indywidualne dla każdej osoby i pozwala na użycie go jako biometryki [121,112]. W tym kontekście warto wspomnieć, że trwają również zaawansowane prace nad zastosowaniem potencjałów wywołanych w procesie identyfikacji osób. Pod uwagę bierze się wtedy kształt i amplitudę załamka.

Należy jednak stwierdzić, że biometria EEG rozwija się powoli. Spowodowane jest to między innymi skomplikowanym pomiarem sygnału EEG w porównaniu z innymi metodami (zdejmowanie odcisków palca, skanowaniem tęczówki). Podejmowane są jednak próby wykorzystania znacznie łatwiejszych w użyciu, suchych elektrod - na przykład wykonanych z nanorurek zamocowanych na wygodnej czapce (rys. 2.3) [7,122].



Rys 2. 3. System biometryczny firmy, rolę czepka do zbierania sygnałów pełni czapka z wbudowanymi elektrodami ENOBIO [15]

Trwają też intensywne próby zastosowania technologii BCI do celów militarnych. Docelowo systemy wspomagające mają sterowanie myśliwcami czy ułatwiać komunikację na polu walki. Jednak zaznaczyć należy, że są to zaledwie próby i do końcowego rezultatu jeszcze daleka droga. Na chwilę obecną istnieje możliwość realizacji systemów, które wspomagają proces sterowania.

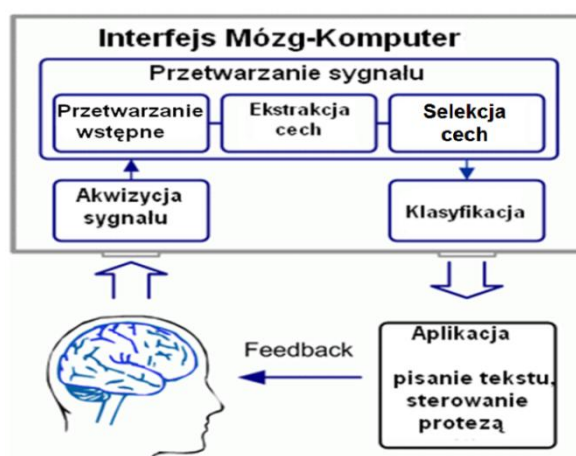
Duże nadzieje z interfejsami mózg-komputer wiąże przemysł rozrywkowy. Już udało się zastosować systemy BCI do sterowania *avatarem* (uczestnik świata wirtualnego). Finalnym efektem prac ma być ergonomiczny i przyjazny interfejs dla każdego użytkownika.

### 2.3 Historia i definicja interfejsu mózg-komputer (BCI)

Badania nad interfejsem mózg-komputer (BCI) rozpoczęto w latach 70-tych XX wieku na Uniwersytecie Kalifornijskim w Los Angeles. Za pierwszą publikację naukową opisującą BCI można uznać pracę: Jacques Vidala [149]: "*Toward Direct Brain-Computer Communication*", Annual Review of Biophysics and Bioengineering, Vol. 2, 1973. Pierwsza międzynarodowa konferencja poświęcona BCI miała miejsce w 1999 roku, w Nowym Jorku, gdzie Jonathan R. Wolpaw podał definicję interfejsu mózg-komputer: "*A brain-computer interface (BCI) is a communication or control system in which the user's messages or commands do not depend on the brain's normal output channels. That is, the message is not carried by nerves and muscles, and, furthermore, neuromuscular activity is not needed to produce the activity that does carry the message*".

W ostatniej dekadzie ubiegłego wieku, w kilkunastu ośrodkach naukowych, rozpoczęto intensywne prace nad systemami BCI. Aktualny stan badań sprowadza się do wykorzystania

pewnych właściwości fal elektromagnetycznych mózgu rejestrowanych za pomocą technik elektroencefalograficznych (sygnały EEG odczytane z elektrod przymocowanych do skóry głowy). W systemie BCI intencje użytkownika odczytywane są bezpośrednio z fal EEG. Pewne, wyekstrahowane cechy tych fal (sygnałów) są klasyfikowane i „tłumaczone” w czasie rzeczywistym na rozkazy wykorzystywane do sterowania komputerem, protezą, wózkiem inwalidzkim lub też innym urządzeniem. Schemat najważniejszych etapów działania interfejsu mózg-komputer przedstawiono na rys. 2.4.



Rys 2. 4. Zasada pracy interfejsu mózg-komputer

Warto pamiętać, że systemy BCI funkcjonują również pod nazwą interfejs mózg-maszyna (*Brain-Machine Interface* - BMI). Jednak najczęściej w literaturze spotyka się określenie „interfejs mózg-komputer”. Spowodowane jest to faktem, że nawet podczas sterowania robotem, wózkiem inwalidzkim czy protezą zwykle korzysta się z pośrednictwa komputera. Komputer jest tutaj nieodzownym elementem, którego zadaniem jest przetwarzanie i klasyfikacja sygnału. To właśnie ten etap jest krytycznym elementem działania interfejsu i od niego zależy w dużej mierze jego sprawność.

## 2.4 Metody badania aktywności mózgu

Istnieje wiele metod badania aktywności mózgu. Najbardziej znane są metody **inwazyjne**:

- implantowane elektrody domózgowe (IntraCortical Recordings, IR),

**częściowo inwazyjne**:

- elektrokortykografia, (*Electrocorticography*, ECoG),

### **nieinwazyjne:**

- magnetoencefalografia, (*Magnetoencephalography*, MEG),
- funkcjonalny magnetyczny rezonans jądrowy (*functional Magnetic Resonance Imaging*, fMRI),
- tomografia optyczna światła rozproszonego (*Near InfraRed Spectroscopy*, NIRS),
- pozytronowa emisyjna tomografia komputerowa (*Positron emission tomography*, PET),
- elektroencefalografia (*Electroencephalography*, EEG).

Jednak, jak już wspomniano, najczęściej wykorzystywaną techniką w systemach BCI jest elektroencefalografia (EEG). Spowodowane jest to kilkoma czynnikami. Po pierwsze MEG, PET, fMRI i metody optyczne są stosunkowo drogie. Dodatkowo metody te są skomplikowane pod względem technicznym i stąd nie znajdują zastosowania w urządzeniach powszechnego użytku. Metody obrazowe, z kolei, charakteryzują się lepszą lokalizacją aktywności mózgu, ale aktywność ta jest zależna od przepływu krwi, który charakteryzuje się dużą stałą czasową i uniemożliwia szybką komunikację [152]. Do największych zalet elektroencefalografii, w zastosowaniu do BCI należą: ocena aktywności mózgu występującej dokładnie w chwili rejestracji sygnału, praca w wielu warunkach środowiskowych, niski koszt realizacji w porównaniu z innymi metodami. Bardzo znaczącym atutem elektroencefalografii jest stosunkowa łatwość w użytkowaniu. Po krótkim przeszkoleniu użytkownika może być stosowana w warunkach domowych.

Do zebrania sygnału EEG wykorzystywane są elektrody (od kilku do 128 elektrod) naklejane na skórę głowy za pomocą żelu. Następnie sygnał przekazywany jest do elektroencefalografu, gdzie sygnały są wzmocnione i w postaci cyfrowej przekazywane do komputera. Zapis tych sygnałów tworzy tak zwany elektroencefalogram.

Rejestrowane sygnały pochodzą ze zbiorowej aktywności neuronów i są efektem tzw. pomiaru biologicznego. Przy pomiarze technicznym badacz ma świadomość, że wyznaczany parametr obiektywnie istnieje, a niedokładności jego określenia wynikają z niedoskonałości metody i aparatury pomiarowej. W biologii i medycynie samo mierzone zjawisko często nie jest do końca zdefiniowane. Ponadto, na pomiar składa się wiele czynników ubocznych, które niejednokrotnie mają ogromny wpływ na wynik pomiaru. Dlatego pojedyncza obserwacja nie jest miarodajna. Wszystkie eksperymenty i obserwacje medyczne muszą odnosić się do zbiorowości, a obserwacje trzeba powtarzać wielokrotnie [144]. Stąd też wynika zasadnicza trudność w konstruowaniu sprawnych interfejsów mózg-komputer.

Z pomocą przychodzi statystyczne uczenie maszynowe (*statistical machine learning*) oraz techniki eksploracji danych (*data-mining*). To dzięki tym metodom można wydobyć użyteczną informację z sygnału EEG i poddać ją klasyfikacji. Jak pokazano na rysunku 2.6 przetwarzanie sygnału obejmuje: przetwarzanie wstępne, ekstrakcję cech (w procesie eksperymentu i nauki także selekcję cech) oraz klasyfikację. Zadania te realizowane są przy pomocy komputera, w czasie rzeczywistym.

Przetwarzanie wstępne najczęściej obejmuje filtrację sygnału i inne metody usuwania szumów i zakłóceń (np. artefaktów fizjologicznych). Na tym etapie wykorzystywane są: filtry cyfrowe, filtry przestrzenne, metody wybielania sygnału (np. analiza składowych niezależnych - ICA) czy ślepa separacja. Po tym etapie otrzymuje się sygnały, z których można dokonywać ekstrakcji cech.

Ekstrakcja cech jest procesem, który umożliwia wydobycie z zapisu EEG najbardziej użytecznych informacji. Stosuje się całą gamę metod analizy sygnału na przykład: statystyki wyższych rzędów (HOS), analizę czas-częstotliwość (t/f), modele autoregresyjne (AR), analizę falkową (DWT). W wyniku ekstrakcji powstają wektory cech. Dysponując wiedzą o przynależności cech do danej klasy można przystąpić do budowy (i trenowania) klasyfikatora.

Zadaniem klasyfikatora jest przydzielenie nowo zarejestrowanego zapisu EEG do konkretnej, uprzednio zdefiniowanej klasy. Najczęściej na tym etapie wykorzystuje się sztuczne sieci neuronowe (ANN), liniową analizę dyskryminacyjną (LDA), naiwny klasyfikator Bayesa (NBC), maszynę wektorów wspierających (SVM) oraz drzewa decyzyjne (DT).


Sklassyfikowane sygnały EEG wykorzystywane są najczęściej do sterowania wirtualną klawiaturą (komunikacja z otoczeniem za pośrednictwem tekstu). Podejmowane są również próby stosowania systemów BCI do sterowania robotem, protezą, a nawet inteligentnym budynkiem. Warto zauważyć, że obiekty sterowane przez interfejsy mózg-komputer mogą mieć wbudowaną „własną inteligencję”. Na przykład wózek inwalidzki lub robot ma wbudowane czujniki i elementy wykonawcze, które nie pozwalają na zderzenie z przeszkodą.

Bardzo ważnym elementem pełnego systemu BCI jest sprzężenie zwrotne (*feedback*). Użytkownik interfejsu mózg-komputer nieustannie obserwuje efekty swoich działań poprzez obserwację działania wirtualnej klawiatury, protezy czy robota. Pomaga mu to wygenerować nowe, odpowiednie sygnały EEG. Jest to jeden z ważnych elementów systemu, bowiem niektóre interfejsy wymagają świadomego generowania konkretnych stanów mózgu. Poprzez obserwację efektów użytkownik może uczyć się lepszej kontroli nad aktywnością własnego mózgu.


## 2.5 Interfejsy synchroniczne i asynchroniczne

Interfejsy mózg-komputer można podzielić na synchroniczne i asynchroniczne. System synchroniczny, to taki, w którym znana jest chwila wystąpienia oczekiwanej aktywności mózgu tzn. wiadomo, który fragment sygnału EEG poddać analizie i klasyfikacji. Najczęściej działanie systemu synchronicznego polega na wykryciu w sygnale EEG odpowiedzi na pewien bodziec, czyli wykryciu tzw. potencjału wywołanego (rys 2.5). W takich systemach bodźce można powtarzać wielokrotnie, a odpowiedzi uśredniać, co znakomicie ułatwia analizę. Innym przykładem interfejsu synchronicznego może być system, w którym użytkownik wykonuje wybraną czynność myślową w ściśle określonej chwili czasu. Tak powstały potencjał (w sygnale EEG) jest również znacznie prostszy do analizy i klasyfikacji.

Asynchroniczne systemy BCI wymagają ciągłej analizy i klasyfikacji sygnału EEG (rys. 2.6). Nie wiadomo bowiem, w której chwili czasu użytkownik wykonał planowane zadanie myślowe.



Rys 2. 5. Interfejs synchroniczny - klasyfikacja zadania myślowego następuje w konkretnej chwili czasu



Rys 2. 6. System asynchroniczny - klasyfikacja zdarzeń trwa nieustannie



### 2.6 Etapy działania interfejsów mózg-komputer

Ważnym etapem w procesie uruchomienia systemu BCI jest, niezależnie od typu wykorzystanych potencjałów, wzajemne przystosowanie do siebie systemu i użytkownika. Z jednej strony proces przystosowania ma na celu dokonanie wyboru optymalnych cech z sygnału EEG, które pozwolą na efektywne działanie interfejsu. Dlatego potrzebne jest przeprowadzenie jednej lub kilku sesji treningowych, w sensie uczenia systemu. Z drugiej strony wymagany będzie trening użytkownika. Działanie interfejsów mózg-komputer można więc podzielić na trzy etapy:

- sesja treningowa (wybór cech i uczenie klasyfikatora),
- trening użytkownika (sesje z biofeedbackiem),
- eksploatacja interfejsu (wykorzystanie do komunikacji).

Sesja treningowa to etap, w którym użytkownik realizuje pewne zadania myślowe związane z konkretnym modelem interfejsu mózg-komputer. Użytkownik wie na czym skupiać swoją uwagę lub jaki ruch sobie wyobrażać. Zadaniem systemu na tym etapie jest wyznaczenie parametrów (cech) sygnału, które następnie używane będą do klasyfikacji w trakcie działania systemu. Choć w ogólności, dla konkretnych potencjałów, wiadomo w przybliżeniu gdzie i jakich cech poszukiwać w sygnale EEG, to zwykle dla konkretnego użytkownika warto dobrać odpowiednie, indywidualne parametry systemu.

Dla interfejsów opartych na potencjale P300 do parametrów indywidualnych dla konkretnego użytkownika należą:

- lokalizacja elektrod (dla których załamek P300 ma największą amplitudę),
- chwila czasu (opóźnienie) występowania maksymalnej amplitudy potencjału P300,
- wartość amplitudy i kształt potencjału.

Dla potencjałów SSVEP będą to parametry takie jak:

- lokalizacja elektrod na których występują sygnały o częstotliwościach pobudzenia,
- dobór najlepszych częstotliwości pobudzeń,
- amplituda rejestrowanych sygnałów (potencjałów wywołanych).

Dla interfejsów z potencjałami związanymi z wyobrażeniem ruchem będą to parametry takie jak:

- lokalizacja elektrod na których obserwuje się największe zmiany potencjałów,
- wartości częstotliwości zmian tych potencjałów,

- amplitudy potencjałów.

Zwykle doboru parametrów systemu dokonuje osoba asystująca użytkownikowi interfejsu. Niestety, dobór parametrów nie zawsze jest optymalny, co może być wynikiem braku doświadczenia ze strony tej osoby. Ponadto, parametry sygnału zawierają cechy indywidualne i dla konkretnego użytkownika mogą ulegać zmianom, w zależności od pory dnia, nastroju itp. Dlatego też, dąży się do opracowania metod automatycznego wyboru cech. W interfejsach asynchronicznych, dla potencjałów związanych z ruchem, najczęściej wykorzystuje się cechy w postaci prążków widma rejestrowanych sygnałów. Autor ma nadzieję, że istnieją inne, lepsze cechy (lub ich kombinacja), które przyczynią się do sprawniejszego działania interfejsu mózg-komputer. Autor postawił sobie za zadanie zweryfikowanie tej tezy.

Ważnym etapem w sesji treningowej jest uczenie (trenowanie) klasyfikatora. W interfejsach mózg-komputer próbowano zastosować całą gamę klasyfikatorów. W interfejsach pracujących w trybie *on-line* najczęściej wykorzystuje się klasyfikator progowy. Po przekroczeniu zadanej wartości, na przykład amplitudy sygnału na danej elektrodzie, sygnał zostaje zakwalifikowany do konkretnej klasy. Działanie takiego klasyfikatora jest proste, ale nie zawsze daje najlepsze rezultaty.

Po nauczeniu klasyfikatora system jest gotowy do działania. Kolejnym etapem są sesje treningowe, kiedy to użytkownik uczy się generować jak najlepsze sygnały (na przykład obserwując wyniki na monitorze). Taki proces nazwany jest treningiem użytkownika z *neurofeedbackiem* i tylko dzięki niemu użytkownik jest w stanie osiągać zadowalające rezultaty. Najczęściej sesje takie stosuje się w interfejsach z samodzielnym generowaniem określonych stanów umysłowych (zadań myślowych), to jest w potencjałach skojarzonych z ruchem czy też wyspecjalizowanych aktywnościach myślowych. Trening użytkownika może potrwać kilka tygodni, a nawet miesięcy. Może się okazać, że po wielu sesjach należy skorygować cechy lub na nowo nauczyć klasyfikator.

Kolejnym etapem jest właściwe wykorzystanie interfejsu, do komunikacji lub sterowania obiektami przez osobę sparaliżowaną, przy minimalnej pomocy osoby asystującej. Najczęściej dzięki odpowiedniej generacji potencjałów lub obserwacji bodźców użytkownik (osoba sparaliżowana) może:

- używać prostej klawiatury wirtualnej do wyboru znaków,
- poruszać kursorem,
- używać tablicy z symbolami do przekazania swoich intencji,
- sterować ruchem wózka inwalidzkiego,

- sterować inteligentnym budynkiem,
- sterować sztuczną protezą,
- poruszać się w wirtualnym środowisku.

Podczas działania interfejsu może się zdarzyć, że osoba wygeneruje nieodpowiedni sygnał lub też system niewłaściwie ten sygnał zaklasyfikuje. Należy o tym pamiętać i uwzględnić ten problem podczas projektowania systemu.

---

## 3. POTENCJAŁY MÓZGOWE WYKORZYSTYWANE W BCI

---


W interfejsach mózg-komputer wykorzystuje się kilka charakterystycznych potencjałów sygnału EEG, wywoływanych pewnymi procesami myślowymi lub koncentracją uwagi użytkownika na określonym zdarzeniu. Najtrudniejsze do wykrycia są sygnały spontanicznej aktywności mózgu (asynchroniczne), powstałe podczas wykonywania pewnych czynności myślowych, np. związanych z zamiarem wykonania ruchu kończyną. Najwygodniejsze w użyciu (i najszybsze) są interfejsy synchroniczne. W ich przypadku sygnały rejestrowane poddaje się odpowiedniemu uśrednieniu, co znacznie ułatwia ich identyfikację. W niniejszym rozdziale zostaną sklasyfikowane potencjały mózgowo wykorzystywane w BCI.

### 3.1 Elektroencefalografia

Aktywność elektryczna mózgu rozpoczyna się pomiędzy siedemnastym a dwudziestym trzecim tygodniem rozwoju płodu i trwa do końca życia człowieka. Jak już wspomniano, jedną z metod pomiaru tej aktywności jest elektroencefalografia. W 1875 roku Richard Caton, naukowiec z Liverpoolu, wykorzystał galwanometr i dwie elektrody do zarejestrowania potencjałów na powierzchni czaszki zwierząt (psów i małąp) [152,153]. Odkrycia i pierwszego zapisu aktywności mózgu u człowieka dokonał Hans Berger. Swoje prace nad badaniem zapisu elektroencefalograficznego u człowieka rozpoczął w 1920 roku. W 1929 roku zarejestrował on trzyminutowy zapis sygnału elektroencefalograficznego z wykorzystaniem tylko jednego bipolarnego kanału. W swoim raporcie opisał fale alfa, jako główny składnik sygnału EEG.

Obecnie pod pojęciem elektroencefalografia (EEG) rozumie się nieinwazyjną metodę diagnostyczną, która służy do badania bioelektrycznej czynności mózgu. Badanie wykorzystywane jest najczęściej w medycynie i polega na odpowiednim rozmieszczeniu elektrod na powierzchni skóry głowy. Elektrody rejestrują zmiany potencjału elektrycznego, pochodzące od aktywności neuronów kory mózgowej. Po odpowiednim wzmocnieniu potencjałów za pomocą elektroencefalografu można zarejestrować zapis tych sygnałów w postaci tzw. elektroencefalogramu.

Przy użyciu elektrod rejestrowane są potencjały elektryczne występujące w danym miejscu. Potencjał rejestrowany za pomocą elektrody jest wypadkową wszystkich potencjałów, generowanych przez różne źródła pola elektrycznego (elektromagnetycznego). Musimy zatem pamiętać, że zapis EEG zawiera potencjały pochodzące z wnętrza czaszki (aktywność mózgu) jak również inne sygnały elektrofizjologiczne oraz sygnały pochodzące od zakłóceń zewnętrznych (sieć elektroenergetyczna). Na szczęście, im dalej od źródła pola, tym mniejszy jego wkład do sygnału EEG, a ponieważ najbliżej elektrod naklejonych na czaszce znajduje się kora mózgowa, to właśnie jej aktywność decyduje o sygnale EEG. Uważa się, że największy wkład do sygnału EEG wnoszą komórki piramidalne [47]. Jednak potencjały odczytywane za pomocą EEG, nie są potencjałami czynnościowymi samych komórek. Prawdopodobnie są to potencjały pobudzające i hamujące synapsy, które trwają dziesiątki czy nawet setki milisekund. Pole wytworzone przez dipol pojedynczego neuronu jest zbyt słabe, aby mogło zostać wykryte. Jednak komórki piramidalne mają podobną orientację, a wiele z nich pobudzanych jest jednocześnie (synchronicznie). Kiedy więc pewien ośrodek kory mózgowej jest w stanie przetwarzania informacji, elektroda umieszczona w jego pobliżu będzie rejestrować tę aktywność (rys 3.1).



Rys 3.1. Schematyczny obraz drogi sygnału EEG, sygnał musi przejść przez wiele warstw błon, warstwę czaszki i skóry - jest znacznie osłabiony

W rzeczywistości więc nie mierzy się aktywności pojedynczych neuronów lecz wypadkowe pole elektryczne, generowane przez ogromną liczbę neuronów znajdujących się stosunkowo blisko elektrody. EEG odzwierciedla wypadkową aktywność elektryczną komórek mózgu (w szczególności kory mózgowej) w danej chwili. Aktywność ta jest związana ze wszystkimi procesami w jakie „zaangażowany” jest mózg. Do czynności tych zaliczyć można między innymi: planowanie, wspomnianie, uczenie się, odbiór bodźców, analizę bodźców, podejmowanie decyzji czy koncentrację uwagi. Dodatkowo kora zawiaduje procesami, których sobie nie uświadamiamy, takimi jak: funkcjonowanie układu pokarmowego, koordynacja ruchów złożonych, oddychanie. Dlatego też sam fakt, że potrafimy zarejestrować czynność elektryczną mózgu, nie oznacza, że sygnały te odzwierciedlają użyteczną dla nas informację!

Pomimo tak dużej złożoności procesów zachodzących w mózgu doświadczony lekarz (neurolog), potrafi wyciągnąć pewne wnioski z analizy sygnału EEG. Najczęściej EEG wykorzystywane jest w zastosowaniach medycznych takich jak:

- monitorowanie czujności, śpiączki i śmierci mózgu,
- lokalizacja obszarów mózgu zniszczonych po urazie głowy,
- diagnostyka udaru mózgu,
- diagnostyka nowotworu mózgu,
- testowanie układu nerwowego (badanie potencjałów wywołanych),
- monitorowanie zaangażowania poznawczego (rytm alfa),
- kontrola głębokości narkozy,
- badanie epilepsji i lokalizacja ognisk napadów padaczkowych,
- testowanie wpływu leków,
- pomoc w usunięciu ognisk napadów padaczkowych,
- monitorowanie rozwoju mózgu,
- badania zaburzeń snu,
- badania zaburzeń psychicznych,
- diagnostyka choroby alkoholowej,
- realizacja biofeedbacku/neurofeedbacku.

## 3.2 Rytmy EEG

Jak już wspomniano we wstępie rozprawy, sygnał EEG jest indywidualny dla każdej osoby, ale ulega znacznym, specyficznym zmianom zależnie od czynników psychofizycznych oddziałujących na osobę w danej chwili. Dlatego też, można by się zastanawiać, czy istnieje w ogóle coś takiego jak „prawidłowy zapis sygnału EEG”? Pytanie to wykracza poza zakres tej rozprawy. Jednak wiadomo, że można wykryć pewne patologiczne zmiany w sygnale EEG, co potrafi zrobić wykwalifikowany neurolog. Ważnym pytaniem jest: Kiedy i w jakich warunkach sygnał EEG zmienia się w sposób specyficzny u zdrowego człowieka?. Stwierdzono, że w przypadku dobrze funkcjonującego, zdrowego organizmu wyróżnić można pewne specyficzne rytmy (fale) EEG. Rytmy charakteryzowane są za pomocą takich parametrów jak kształt, amplituda i częstość zmian. Warto wspomnieć, że fale zależą od wielu czynników psychofizycznych i zmieniają się wraz z wiekiem. Najczęściej wyróżnia się następujące rytmy:

**Gamma** (powyżej 40 Hz) – opisują stan związany ze świadomością, percepcją, aktywnością umysłową.

**Beta** (od 12 do ok. 28 Hz) - występują podczas codziennej aktywności, w stanach niepokoju, oraz pod wpływem pewnych leków.


**Alfa** (od 8 do 13 Hz) - charakterystyczne dla stanu czuwania w warunkach relaksu, szczególnie przy zamkniętych oczach.

**Mu** (od ok. 8 do 12 Hz) - rytmy sensomotoryczne, maksymalna wartość amplitudy tych rytmów pojawia się w korze sensomotorycznej w stanie spoczynku.

**Theta** (od 4 do 7 Hz) - występują podczas głębokiej medytacji, intensywnej marzeń, oraz intensywnych emocji.

**Delta** (od ok. 0,5 do 3 Hz) - występują w stanie głębokiego snu, u małych dzieci i w przypadku pewnego rodzaju uszkodzeń mózgu.

Przykłady fal EEG zobrazowano na rysunku 3.2. Wskazano na nim amplitudę i kształt sygnałów EEG.



Rys 3.2. Fale EEG z podaniem najczęściej występujących aktywności mózgu

Większość fal można zaobserwować na całej powierzchni czaszki. Fale gamma, theta i alfa występują w korze mózgu, hipokampie, wzgórzu oraz pniu mózgu. Oprócz wymienionych wyróżnić można kilka innych fal, a również w stosunku do wyżej wymienionych można spotkać się z dyskusją na temat zakresów częstotliwości.

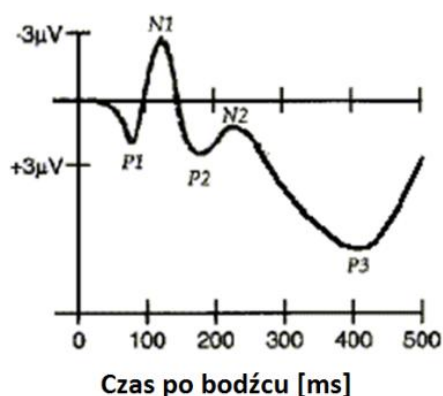
### 3.3 Potencjały wywołane

W diagnostyce medycznej stosuje się badanie tak zwanych potencjałów wywołanych (*Evoked Potentials* - EP). Są to, potencjały elektryczne rejestrowane na powierzchni głowy, powstałe w efekcie wystąpienia aktywności mózgu, jako skutku określonego bodźca. Najczęściej jest to bodziec wzrokowy, słuchowy lub czuciowy. Stąd wyróżnia się wzrokowe, słuchowe i somatosensoryczne potencjały wywołane. Potencjały wywołane stanowią również przedmiot badań medycznych. Badanie potencjałów wywołanych wykonywane jest między innymi w przypadku podejrzenia o uszkodzenie „drogi” wzrokowej, słuchowej czy czuciowej, podejrzenia o wystąpienie choroby demielizacyjnej (np. stwardnienie rozsiane) lub uszkodzenia pnia mózgu. Badanie potencjałów wzrokowych, najczęściej, przeprowadzane jest po umieszczeniu pacjenta przed monitorem (w odległości około 1,5 metra), na którym pojawiają się błyski lub wzorce zmieniającej się szachownicy. Błysk powtarzany jest około 200 razy.

Wielokrotne powtarzanie bodźca, z jednoczesnym uśrednianiem wyników stosuje się dlatego, że amplituda odpowiedzi na pojedynczy bodziec jest zbyt mała i „ginie” wśród sygnałów powstałych w wyniku spontanicznych czynności elektrycznych mózgu. Uśredniony obraz potencjału zamieszczono na rys. 3.3. Widoczne są tu tak zwane załamki P1, N1, P2 czy



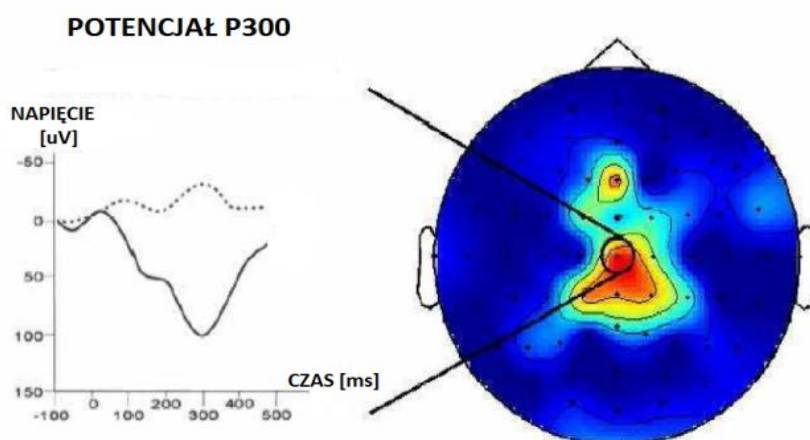
P3. Doświadczony lekarz patrząc na taki wykres, oceniając czas trwania oraz amplitudę załamków, może wyciągnąć wnioski co do funkcjonowania niektórych części organizmu.



Rys 3.3. Typowa uśredniona odpowiedź wywołana bodźcami wzrokowymi

### 3.3.1 P300

Potencjał P300 związany jest z reakcją osoby na oczekiwane zdarzenie (bodziec). Wywołać go mogą, nie tylko bodźce wzrokowe, ale również słuchowe i somatosensoryczne. Pojawia się po upływie około 300 ms od chwili wystąpienia bodźca - stąd jego nazwa (rys. 3.4). Jednak zarówno amplituda potencjału jak i czas jego trwania mogą być różne dla różnych użytkowników. Najsilniej potencjał P300 jest obserwowany na płacie ciemieniowym (elektroda Cz). Zwykle jest to symetryczna dodatnia fala o latencji 250-600 ms w stosunku do bodźca. Typowy, pojedynczy pik potencjału P300 ma amplitudę od 2 do 5µV i leży poniżej aktywności „tła” mózgu. Oznacza to, że pojedynczy załamek P300 opisany jest bardzo niskim poziomem stosunku sygnału do szumu.




Rys 3.4. Potencjał P300 wraz z rozkładem na powierzchni głowy

W 1964 roku dwaj naukowcy Champan i Bragdon [105] zauważyli, że odpowiedzi na bodźce wzrokowe różniły się w zależności od tego czy bodźce miały jakieś znaczenie emocjonalne dla danej osoby, czy też nie. Badana osoba obserwowała dwa bodźce: błysk i liczbę. Tylko w odpowiedziach po wyświetlonej liczbie, z opóźnieniem około 300 milisekund, pojawiał się nowy nieznaną załamek, określony później mianem P3B. Kolejne badania nad załamkiem P300 wykonywał Sutton w 1965 i w 1967 roku [8].

W połowie lat 80-tych podjęto próby wykorzystania potencjału P300 do wykrywania kłamstwa (dr Lawrence Frawell). Ponadto uważa się, że potencjał P300 pozwala ocenić jakość procesów pamięciowych, zdolność podejmowania decyzji oraz koncentracji uwagi.


Wykorzystanie potencjału P300 w zastosowaniu do interfejsu BCI jest jedną z najprostszych koncepcji. Najczęściej użytkownik obserwuje monitor, na którym podświetlane są losowo pewne symbole zebrane w tablicy. W chwili, gdy, zostanie podświetlony symbol, na którym swoją uwagę koncentrował użytkownik, powstaje potencjał P300 o stosunkowo dużej amplitudzie. Jak już wspomniano wygodnie jest potencjał wywołany uśrednić. W tym celu trzeba wielokrotnie podświetlać wszystkie symbole w celu wyłonienia potencjału o odpowiednio dużej amplitudzie.

Parametry takie jak czas trwania bodźca, kolor podświetlenia, kolor pola, kolor tła, jak również cechy psychofizyczne użytkownika mają duży wpływ na jakość działania interfejsu. Zmiany te wpływać mogą na opóźnienie (latencję), kształt i wartość amplitudy załamka. Stwarza to konieczność kalibracji systemu, dopasowania parametrów klasyfikacji do użytkownika. Dlatego zawsze wykonywana jest sesja treningowa, w której użytkownik skupia swoją uwagę na wskazanym symbolu. W ten sposób badane są parametry (latencja i amplituda) załamka P300, które, w trybie eksploatacji systemu BCI, zostaną wykorzystane do konfiguracji klasyfikatora (rys 3.5).




Rys 3.5. Potencjał P300: A-rozkład potencjału na powierzchni głowy, B - amplituda uśredniona dla kilku bodźców. c-Współczynnik  $r^2$  determinacji odpowiedzi czasowej potencjału P300

Najczęściej potencjał P300 wywołany jest z użyciem wyświetlanej na ekranie monitora, tablicy znaków (np. liter), zaproponowanej przez Dochina (rys 3.6). Wiersze i kolumny tablicy są podświetlane losowo z częstotliwością od kilku do kilkudziesięciu błysków na sekundę. Zadaniem użytkownika interfejsu jest skoncentrowanie uwagi na wybranym znaku. Podświetlane wiersze i kolumny wywołują potencjał P300 jeśli znajdował się na nich wybrany znak. Po kilku lub kilkudziesięciu uśrednieniach rejestrowanego potencjału P300 (zależnie od użytkownika) można określić, który znak został wybrany. W ten sposób, w przypadku, gdy znakami są litery alfabetu pisana jest pojedyncza litera, a powtarzanie procesu umożliwia pisanie słów oraz całych zdań.

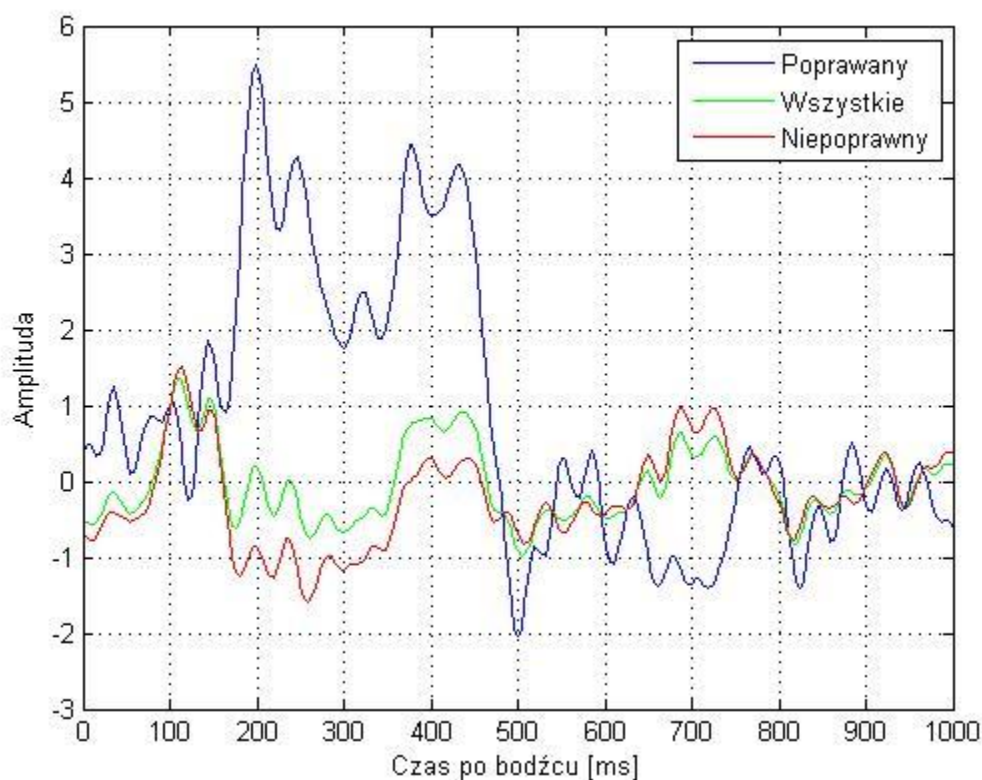


Rys 3.6. Popularna tablica, wykorzystywana jako wirtualna klawiatura w systemie BCI z potencjałem P300



Rys 3.7. Zestawiony przez autora system BCI (P300) wykorzystywany do pisania tekstu

Tytułem eksperymentu autor zestawiał i przetestował interfejs mózg-komputer z wykorzystaniem potencjału P300 (rys. 3.7). Uzyskano bardzo dobre rezultaty. W zaprojektowanym systemie, wybrany znak rozpoznawany był po kilku uśrednieniach potencjału. Wybór jednego spośród 36 znaków dokonywany był w zaledwie 8 sekund. Poprawność działania interfejsu wynosiła 98%. Interfejs pozwolił na swobodne pisanie tekstu. Okazało się, że użytkownik może korzystać z interfejsu po minutowym przeszkoleniu. Bardzo dobre wyniki uzyskane w efekcie działania systemu możliwe były do osiągnięcia dzięki kliku czynnikom. Ogromne znaczenie miało zastosowanie profesjonalnego wzmacniacza EEG z aktywnymi elektrodami<sup>1</sup>. Do rejestracji sygnału EEG wykorzystano tylko 8 elektrod. Bardzo ważnym elementem, była filtracja pasmowa sygnału (0,5Hz-30Hz) w czasie rzeczywistym, która redukowała znacząco artefakty i szумы. Analiza sygnału obejmowała okres czasu 600 ms po wystąpieniu bodźca. Jako cechy wybrano amplitudy uśrednionych sygnałów. Sygnały otrzymane dla poszczególnych "zdarzeń" zamieszczono na rysunku 3.8. W klasyfikacji zastosowano liniową analizę dyskryminacyjną.



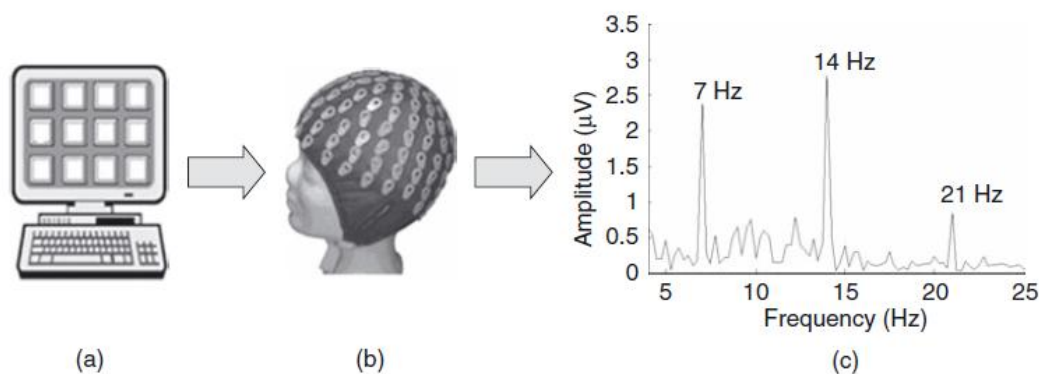
Rys 3.8. Potencjały wywołane P300 otrzymane w czasie eksperymentów: poprawny - po skupieniu uwagi na znaku; niepoprawny - gdy użytkownik nie skupiał uwagi na wybranym znaku; wszystkie – średnia wszystkich odpowiedzi

<sup>1</sup> Elektrody aktywne g.LADYbird firmy g.Tec (Patrz dodatek D1)

### 3.3.2 Stabilny potencjał wywołany wzrokowo (SSVEP)

W interfejsach mózg-komputer wykorzystuje się również potencjał, który najczęściej określany jest jako „stabilny potencjał wywołany wzrokowo”<sup>2</sup> - *Steady State Visually Evoked Potential* (SSVEP). Są to potencjały mózgowo pojawiające się na korze wzrokowej po stymulacji bodźcem świetlnym o ustalonej częstotliwości migotania. Jeśli pobudzimy siatkówkę oka bodźcem wzrokowym o częstotliwości od około 3,5Hz do 75Hz (a nawet 90 Hz) to na elektrodach umieszczonych w obszarze kory wzrokowej (elektrody O1 lub O2) pojawi się sygnał o tej samej częstotliwości (lub jej wielokrotności). Charakteryzuje się on dużym stosunkiem sygnału do szumu i dość dobrą odpornością na artefakty [18].

Obiektami świetlnymi dla SSVEP mogą być specjalnie przygotowane matryce. Podczas gdy użytkownik interfejsu skupia wzrok na wybranym polu (działaniu), wywołuje to pojawienie się sygnału o określonej częstotliwości w obszarze kory wzrokowej. Analizując widmo sygnału, można określić na co patrzył użytkownik, a co za tym idzie jakie działanie miał na myśli (rys 3.9).



Rys 3.9. Poglądowy schemat wykorzystania potencjału SSVEP, A) pulsujące z różną częstotliwością pola, B) osoba obserwuje wybrane pulsujące pole, C) w korze wzrokowej pojawiają się częstotliwości dominujące związane z wybranym pulsującym polem

Przykład praktycznego wykorzystania potencjału SSVEP do wybierania numeru telefonu przedstawiono na zdjęciu (rys. 3.10). Autor jest pod wrażeniem rozwiązania w zespole prof. Andrzeja Materki z Politechniki Łódzkiej [84,85]. Zespół ten zaproponował system SSVEP z wykorzystaniem metody naprzemiennej stymulacji pól wzrokowych, która w połączeniu z różnicowym pomiarem sygnału EEG z odpowiednio umiejscowionych elektrod umożliwia znaczną poprawę jakości mierzonych sygnałów, a tym samym umożliwia zwiększenie szybkości komunikacji. Na Uniwersytecie Warszawskim zespół pod kierownictwem prof.

<sup>2</sup> tłumaczenie autorskie



Piotra Durki skonstruował interfejs z wykorzystaniem potencjału SSVEP z dynamicznie zmieniającymi się elementami menu (do wyboru) [21].

Interfejsy, w których wykorzystuje się wzrokowe potencjały wywołane mają wady. I tak, interfejsy z potencjałami SSVEP wymagają pewnej sprawności ruchowej użytkownika. Musi on samodzielnie poruszać oczami i skupiać swoją uwagę na różnych fragmentach ekranu monitora (lub kilku odległych od siebie ekranów czy matryc), aby wybrać odpowiedni bodziec. Osoby całkowicie sparaliżowane mogą nie być w stanie wykonać takiego ruchu.




Rys 3.10. Stanowisko laboratoryjne (Institute of Neural Engineering, Tsinghua University) [35]

W przypadku, gdy użytkownik ma możliwość wykonania jakiegokolwiek ruchu oczami, prościej jest wykorzystać do realizacji interfejsu sygnały elektrookulograficzne (EOG). Kolejną bardzo poważną wadą interfejsów SSVEP oraz P300 jest to, że bodźce stymulujące wywołują zmęczenie i dyskomfort, a nawet mogą doprowadzić do wywołania ataku epilepsji (jeśli użytkownik ma takie predyspozycje). Kolejnym problemem ograniczającym zastosowanie praktyczne interfejsu, w przypadku potencjału P300, jest efekt habituacji. Habituacja (przywykanie) to zjawisko neurologiczne, występujące w układzie nerwowym. W przypadku wielokrotnie powtarzanego bodźca, odpowiedź układu staje się coraz słabsza [105]. Do zalet interfejsów z potencjałami wywołanymi należy przede wszystkim łatwość posługiwania się nimi, co przekłada się na bardzo krótki czas nauki obsługi tych interfejsów. Potencjały wywołane występują praktycznie u każdej osoby. Oczywiście są osoby, u których występują odpowiedzi o lepszych lub gorszych parametrach (głównie amplitudzie).

### 3.4 Potencjały mózgowie związane z ruchem

W latach 1964/65 prof. Hans Helmut Kornhuber i jego doktorant Lüder Deecke (University Hospital Freiburg im Breisgau) podjęli badania dotyczące aktywności elektrycznej mózgu przed i podczas wykonywania dobrowolnego ruchu. Ochotnicy poddawani badaniom, w dowolnie wybranej przez siebie chwili wykonywali ruch palcem (zgięcie palca). Podczas wielokrotnych prób rejestrowano przebieg sygnału EEG, a następnie przebiegi uśredniano. W efekcie stwierdzono, że potencjały mózgowie zmieniają się już na około sekundę przed ruchem! W ten sposób odkryto tak zwany „potencjał gotowości” (*pre-motor potential* lub *readiness potential*). Z języka niemieckiego w oryginale nazwano ten potencjał *Bereitschaftspotential* (BP) [70,71].

Potencjał BP jest dziesięć razy słabszy niż rytmy *alpha* występujące w sygnale EEG. Tylko wielokrotne uśrednianie zbioru wszystkich sygnałów EEG pochodzących od wykonanych przez danego użytkownika ruchów palcem umożliwia obejrzenie tego potencjału. Na rysunku 3.11 widać typowy przebieg potencjału BP. Badania wykonano dla samowolnego ruchu palcem wskazującym prawej ręki. Pionowa linia wskazuje chwilę wystąpienia ruchu (oznaczoną jako  $t=0$ ). Przebiegi sygnałów obrazują uśrednione potencjały dla elektrod C3, C4, oraz Pz. Dodatkowo przedstawiono różnicę pomiędzy sygnałami pochodzącymi z elektrod C3 i C4. Przedstawione wyniki obrazują średnią sygnałów otrzymanych dla tego ochotnika dla 8 różnych dni. Można zaobserwować, że potencjał BP składa się z dwóch załamek. Pierwszy z nich BP1 pojawia się około 1,2 do 0,5 sekundy, a drugi BP2 od 0,5 sekundy do 0 sekund, przed wykonaniem ruchu.



Rys 3.11. Potencjał BP w sygnale EEG [24,25]

Rytmu sensomotoryczne należą do fal mózgowych typu  $\mu$  (*mu*) (8-12 Hz) oraz  $\beta$  (18-26 Hz), występujących w zapisie elektroencefalograficznym. Maksymalna wartość amplitudy tych rytmów pojawia się w korze sensomotorycznej w stanie spoczynku (gdy osoba nie wykonuje żadnego ruchu). Fale te są tłumione w stadium przygotowania do wykonywania ruchu. Powszechnie uważa się, że odzwierciedlają one „synchronizację” tych neuronów kory ruchowej, które kontrolują stan części ciała (na przykład ręki), gdy nie są one w stanie ruchu.

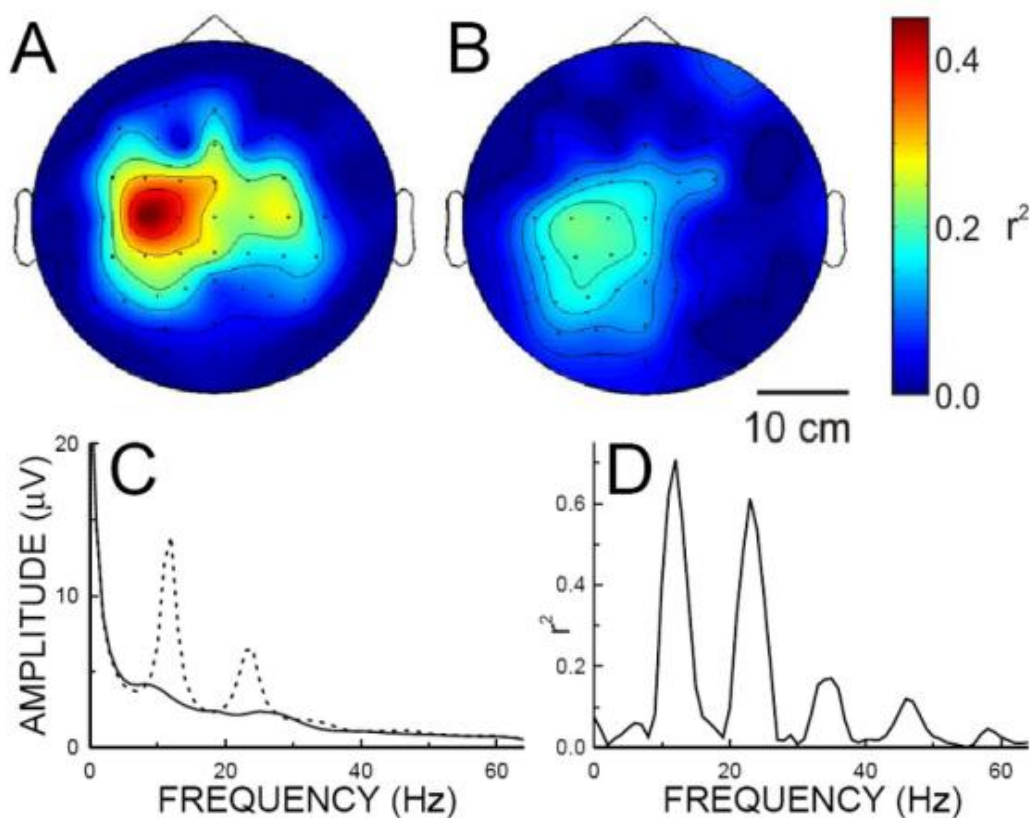
Jako ciekawostkę można podać, że w 1950 roku Gastaut i jego współpracownicy [15,29] zauważyli występowanie charakterystycznych potencjałów nie tylko podczas wykonywania ruchu przez osobę badaną, ale również podczas, gdy osoba ta obserwowała wykonywanie ruchu przez inną osobę. Badania te zostały potwierdzone przez kolejne zespoły [28,29,30]. Najnowsze badania wykonane przez Pindela i jego zespół pokazały, że osoba nie musi wykonywać ruchu, wystarczy samo jego wyobrażenie [13,14,15]. Efekty przytoczonych prac pozwoliły na postawienie następującej tezy: Potencjały mózgowie związane z ruchem można wykorzystać w interfejsach mózg-komputer, przeznaczonych dla osób niepełnosprawnych, ponieważ samo wyobrażenie ruchu przez użytkownika wywołuje podobne zmiany w sygnale EEG jakie występują podczas przygotowania i wykonania rzeczywistego ruchu.

Powyższe spostrzeżenia pozwoliły naukowcom na konstrukcję interfejsów mózg-komputer z wykorzystaniem potencjałów związanych z ruchem. To podczas tych badań zaobserwowano, że najsilniejsze zmiany sygnału EEG towarzyszące wykonywaniu lub przygotowaniu się do wykonania ruchu, pojawiają się w korze sensomotorycznej. Największy spadek aktywności odpowiednich rytmów pojawia na półkuli mózgu przeciwległej do części ciała związanej z wyobrażanym ruchem. Dla przykładu, ruch palcem prawej ręki powoduje spadek aktywności w lewej półkuli (w odpowiednim rejonie mózgu). Spadek aktywności nazywa się *event-related desynchronization* (ERD) natomiast wzrost (przy przejściu do stanu spoczynkowego) nazywany jest *event-related synchronization* (ERS). Wzrost aktywności ERS powstaje tuż po wykonaniu ruchu.

Na rysunkach 3.12 (A) oraz (B) pokazano różnicę, wyrażoną jako współczynnik determinacji  $r^2$ , dla wykonanego ruchu (A) oraz wyobrażonego ruchu (B), w odniesieniu do potencjałów występujących podczas spoczynku. Rozkład potencjału wyznaczono dla częstotliwości z zakresu 10,5Hz÷13,5Hz. Na rysunku (C) zamieszczono przykładowe widmo sygnału z elektrody C3, znajdującej się nad lewą połową kory sensomotorycznej, dla wyobrażania sobie ruchu (linia ciągła) i w stanie spoczynku (linia przerywana). Na rysunku



3.12 (D) przedstawiono współczynnik determinacji<sup>3</sup>  $r^2$  wyznaczony dla zmian pomiędzy wyobrażaniem sobie ruchu a odpoczynkiem. Można zauważyć dużą korelację dla fal alfa oraz beta, które są powiązane z rytмами *mu*.



Rys 3.12. Zmiana rytmów *mu* towarzyszących wykonywaniu oraz wyobrażeniu sobie ruchu (Rysunek zaczerpnięto z opisu badań [131] wykonanych przez G. Schalka i jego zespół)

W kontekście powyższego, powstaje zasadnicze pytanie, gdzie umieszczać elektrody, aby zarejestrować największe zmiany sygnału EEG podczas wyobrażania sobie ruchu wybraną częścią ciała. Odpowiedź na to pytanie nie jest prosta, gdyż „optymalna” lokalizacja elektrod może być inna dla każdego użytkownika. Niewątpliwie, lokalizacja elektrod powinna obejmować korę sensomotoryczną. Jednak w samej korze motorycznej trzeba wskazać miejsca „powiązane” z odpowiednimi częściami ciała.

W praktyce, najczęściej użytkownik wyobraża sobie ruch w określonej chwili czasu – jest to interfejs synchroniczny. Chodzi o ruch na przykład prawą ręką, lewą ręką, nogą czy językiem. Zadaniem systemu jest rozpoznanie zmian i odpowiednie zakwalifikowanie aktywności mózgu za pośrednictwem sygnału EEG. Ponieważ sygnały te są zwykle zbyt

<sup>3</sup> współczynnik determinacji  $r^2$  – miara stopnia przewidywalności zachowania obiektu na podstawie jego modelu

słabe, aby wykryć znaczące zmiany często wykorzystuje się wielokrotne powtórzenia w celu uśrednienia wyników i polepszenia klasyfikacji. Daje to możliwość np. wybierania ze zbioru liter czy cyfr lub sterowania prostymi urządzeniami.

Należy zaznaczyć, że aby „skutecznie” wyobrażać sobie ruch użytkownik często musi długo trenować. Z pomocą przychodzi tutaj *neurofeedback*, gdzie użytkownik na podstawie obserwacji przebiegu swoich potencjałów EEG próbuje optymalizować wyobrażanie sobie konkretnego ruchu. Taka nauka może trwać nawet kilka tygodni.

Jednakże, najtrudniejszym do realizacji jest interfejsy asynchroniczny, gdzie użytkownik może wyobrażać sobie ruch w dowolnej chwili czasu. Interfejsy takie pozwalają na sterowanie na przykład wózkiem inwalidzkim. Aby skutecznie posługiwać się takimi interfejsami potrzeba wielu ćwiczeń, ale i skutecznego systemu akwizycji, przetwarzania i analizy sygnału EEG. Jeśli chodzi o przetwarzanie i analizę sygnału to nieprzerwanie poszukuje się nowych, skutecznych metod poprawy stosunku sygnału do szumu oraz nowych metod ekstrakcji cech. Ponadto wielką niedogodnością stosowanych obecnie systemów BCI jest brak automatycznej selekcji cech. Takie podejście wymusza na osobie wspomagającej użytkownika znajomość organoleptycznych metod (obserwacja wyników podanych w postaci graficznej) optymalizacji doboru cech. Wybieranie cech może okazać się procesem zbyt trudnym dla tej osoby, a na pewno zajmuje jej sporo czasu i nie zawsze prowadzi do optymalnego rozwiązania.

### **3.5 Specyficzne aktywności myślowe**

Podobnie jak wyobrażenie sobie ruchu tak i inne rodzaje aktywności myślowych powodują zmiany w sygnale EEG. Dlatego podjęto próby wykorzystania tych zmian do budowy systemów BCI [1,2,27,28,91,92]. Użytkownik ma za zadanie np. wyobrażać sobie przestrzenny obiekt i obracać go w myślach, wyobrażać sobie wypowiedzianie słowa rozpoczynającego się na zadaną literę czy wykonywać obliczenia matematyczne. Takie interfejsy zrealizowało już kilka grup badawczych. Jednak nie wiąże się z nimi wielkich nadziei, ponieważ nie są „naturalne” i w łatwy sposób nie pozwalają kontrolować ruchu kursora czy też protezy. Należy podkreślić, że w niektórych zastosowaniach interfejsy te sprawdzają się jednak w praktyce i w zależności od użytkownika, pozwalają osiągnąć lepsze rezultaty niż w przypadku interfejsów związanych z wyobrażaniem ruchu.

### 3.6 Potencjały korowe wolnozmiennie (SCPSs)

Potencjały korowe wolnozmiennie <sup>4</sup> (*Slow Cortical Potentials Shifts*) to potencjały trwające od kilkuset milisekund do kilku sekund. Wyróżnić można pozytywne i negatywne zmiany potencjału SCP wywoływane poprzez aktywację i dezaktywację kory mózgowej. Niektóre osoby są w stanie nauczyć się kontroli nad tymi potencjałami i dzięki temu poruszać kursorem [4,107]. Ogólnie metoda wymaga długiego treningu, ponadto nie każda osoba potrafi wygenerować odpowiednie potencjały. Niektóre osoby potrafią w ten sposób pisać słowa, z szybkością jedno słowo na minutę. Aktualnie, nie obserwuje się znaczącego zainteresowania potencjałami SCP.

### 3.7 Miary oceny jakości systemów BCI


Bardzo ważną kwestią pozostaje szybkość działania interfejsów mózg-komputer. Należy zaznaczyć, że szybkości te nie są duże, ale dla osoby sparaliżowanej czas może nie być limitowany, zaś przekazanie intencji ma olbrzymie znaczenie. Na szybkość działania interfejsów mózg-komputer wpływa kilka czynników. Po pierwsze może ona ulegać zmianom, zależnie od stanu psychofizycznego użytkownika. Na chwilę obecną najszybsze wydają się interfejsy budowane z wykorzystaniem potencjałów wywołanych. Należy jednak zwrócić uwagę, że bardzo często wyniki podawane przez grupy badawcze obejmują tylko kilku, czasem wyselekcjonowanych użytkowników i nie muszą być obiektywne.

Szybkość interfejsów można porównywać w specyficznych, warunkach (zastosowaniach). Często jednak aplikacje systemów BCI są bardzo różne, dlatego porównuje się tak zwaną szybkość transferu informacji (*information transfer rate* - ITR). Definiuje się go jako ilość informacji przekazanej za pośrednictwem interfejsu w jednostce czasu. Ten parametr łączy w sobie szybkość i skuteczność działania w jedną całość. Transfer informacji (wyrażony w bitach na sekundę) [136,25,154] dla systemów BCI z  $N$  zadaniami myślowymi (możliwymi wyborami), dla średniej skuteczności wyrażonej jako  $p_a$  i czasu na dokonanie wyboru  $T_{act}$  (w sekundach) definiuje się jako [136]:

$$Bit\ rate = \frac{60}{T_{act}} \left( \log_2 N + p_a \log_2 p_a + (1 - p_a) \log_2 \frac{1-p_a}{N-1} \right) \quad (3.1)$$

---

<sup>4</sup> tłumaczenie autorskie




Rys 3.13. Zależność ITR od skuteczności klasyfikacji i liczby zadań myślowych.

Na rysunku 3.13 zobrazowano wykres przedstawiający liczbę bitów przypadających na czas dokonania pojedynczego wyboru dla kilku typowych wartości  $N$ . Wykres ma sens dla wartości  $p_a$  większych od  $\frac{1}{N}$ . W tabeli 3.1 zawarto krótkie podsumowanie osiągnięć w zakresie konstruowania interfejsów mózg-komputer. Wskazane zostały w niej wykorzystywane zadania myślowe (potencjały), zastosowane elektrody oraz osiągnięte wartości współczynnika ITR. Na rysunku 3.14 zobrazowano graficzne porównanie interfejsów w zależności od szybkości działania (ITR) oraz czasu przeznaczanego na naukę obsługi interfejsu.

Tabela 3.1 Podsumowanie wybranych systemów BCI

Grupa badawcza	Zadania myślowe/ Wykorzystane potencjały	Wybrane elektrody Zastosowane algorytmy	Zastosowanie	ITR (Średni) Czas treningu
Uniwersytet Rochester USA	Potencjał P300	Fz, Cz, Pz, P3, P4 Uśrednianie, Klasyfikator progu	Synchroniczna kontrola pięcioma elementami w wirtualnym budynku	12 bit/min Minuty
Uniwersytet Tübingen Niemcy	Potencjały CSP	Fz, Pz, Cz Filtr dolnoprzepustowy Klasyfikator progu	Synchroniczne włączanie i wyłączanie urządzenia	6 bit/min Miesiące
Wadsworth center USA	Rytmy mu i beta	64 elektrody Pasma rytmów mu i beta Klasyfikator liniowy	Poruszanie kursorem	22.5 bit/ min Tygodnie

Politechnika Graz Austria	Wyobrażenie sobie ruchu lewą prawą ręką i stopami	C3 i C4 Pasma alfa i beta LDA, HMM	Synchroniczny interfejs klawiatury, kontrola protezy i kursora	17 bit/min Dnie
Politechnika w Chinach	Potencjały SSVEP	O1 i O2 Porównywanie częstotliwości	Synchroniczna kontrola za pomocą panelu	27 bit/min Minuty
Uniwersytet Illinois USA	Potencjał P300	Fz, Cz, Pz, O1, O2 Uśrednianie, Klasyfikator progu	Wirtualna klawiatura 6x6	9 bit/min Minuty
ABI Projekt Unii Europejskiej JRC	Relaks, wyobrażenie ruchu prawa lewa ręką, obracanie sześcianem, obliczenia matematyczne	F3, F4, C3, Cz, C4, P3, Pz, P4 Częstotliwości od 8 do 30 Hz Sieci neuronowe	Asynchroniczne sterowanie robotem mobilnym	33 bit/min (maksymalna) Dni
EPFL Szwajcaria	Wyobrażenie ruchu prawym lewym palcem, liczenie w myślach, obracanie obiektów	Fp1, Fp2, F7, F3, F4, F8, T3, C3, C4, T4, T5, P3, P4, T6, O1, O2	Asynchroniczne sterowanie obiektem 2D	25 bit/sek Dni



Rys 3.14. Porównanie interfejsów BCI (szybkości działania versus czas potrzebny na naukę działania interfejsu)

Na chwilę obecną nie oczekuje się wielkiego przełomu w systemach mózg-komputer budowanych z wykorzystaniem sygnałów EEG. Dotyczy to zarówno nowych potencjałów mózgowych jak i modułów samego systemu BCI to jest akwizycji, przetwarzania i analizy sygnału. Jednak uważa się, że można polepszyć rezultaty działania, a przede wszystkim przyczynić się do upowszechnienia interfejsów. Najczęściej wymienia się tu z pozoru błahe czynniki, a jednak mające olbrzymie znaczenie praktyczne takie jak np. kolor i kształt obiektu świetlnego dla interfejsu synchronicznego. Zaobserwowano na przykład, że zmiana koloru tła

i liter z czarnego i białego na czarny i żółty lub użycie w postaci bodźca wizerunku twarzy powoduje mocniejsze odpowiedzi. Oprócz czynników mających wpływ na psychikę użytkownika wymienia się też te związane z czysto techniczną konstrukcją interfejsu.

Jeśli chodzi o akwizycję sygnału to istnieje wiele ograniczeń, które przyczyniają się, do tego, że interfejsy mózg-komputer mogą spotkać się z niechęcią zarówno ze strony konstruktorów jak i użytkowników. Jednym z nich jest brak wyspecjalizowanych urządzeń (masowej produkcji) na potrzeby systemów BCI. Urządzenia medyczne, często kilkudziesięciokanałowe są drogie i mają duże gabaryty. Dotyczy to też sposobu mocowania elektrod. Najczęściej wykorzystuje się do tego celu pastę przewodzącą (dla kilku, a czasem nawet kilkudziesięciu elektrod). Wydaje się, że opracowanie nowych elektrod, na przykład suchych, wykonanych z nanorurek, umożliwi wygodne ich mocowanie.

Oprócz tego bardzo ważnym elementem systemów BCI są moduły: przetwarzania, analizy i klasyfikacji sygnału. Tutaj również poszukuje się nowych metod: wydobywania użytecznego sygnału, minimalizacji liczby elektrod, miejsca przymocowania elektrod, nowych algorytmów ekstrakcji cech, wygodnych automatycznych i skutecznych metod selekcji cech. W konstrukcji takich elementów wykonawczych jak na przykład wózki inwalidzkie czy też inteligentne budynki, należy uwzględniać szybkość i omylność działania interfejsów.

---

## 4. AKWIZYCJA SYGNAŁU EEG

---

Jak już wspomniano istnieje wiele metod badania aktywności mózgu, jednak w niniejszej pracy autor skupia uwagę wyłącznie na interfejsach mózg-komputer działających z wykorzystaniem sygnałów elektroencefalograficznych. Ta bezinwazyjna akwizycja uwarunkowana jest wieloma czynnikami i ma swoje zalety oraz wady. Do najważniejszych zalet elektroencefalografii należy zaliczyć stosunkowo niski koszt samego wzmacniacza EEG jak i pozostałych akcesoriów potrzebnych do wykonania badania. Stosunkowo prosty jest sposób akwizycji sygnału. Osoba przeszkolona przez technika-medyka jest w stanie nakleić elektrody na powierzchni głowy i prawidłowo podłączyć je do wzmacniacza. Niekwestionowanym atutem badania EEG jest szybkość pomiaru aktywności mózgu, w porównaniu z metodami obrazowymi. Do wad elektroencefalografii natomiast zalicza się najczęściej niski poziom stosunku sygnału do szumu w porównaniu z metodami inwazyjnymi.

### 4.1 Procedura rejestracji sygnału EEG

Rejestracja sygnału EEG, zarówno na potrzeby medyczne jak i interfejsów mózg-komputer, przebiega podobnie. Osoba badana powinna usiąść komfortowo na krześle lub fotelu, najlepiej w słabo oświetlonym pokoju. Na głowie osoby badanej zostają umieszczone elektrody, w ściśle określonych miejscach, z uwzględnieniem elektrody odniesienia. Następuje kalibracja systemu. Wreszcie, sygnał EEG jest rejestrowany i zapisywany w pamięci komputera.

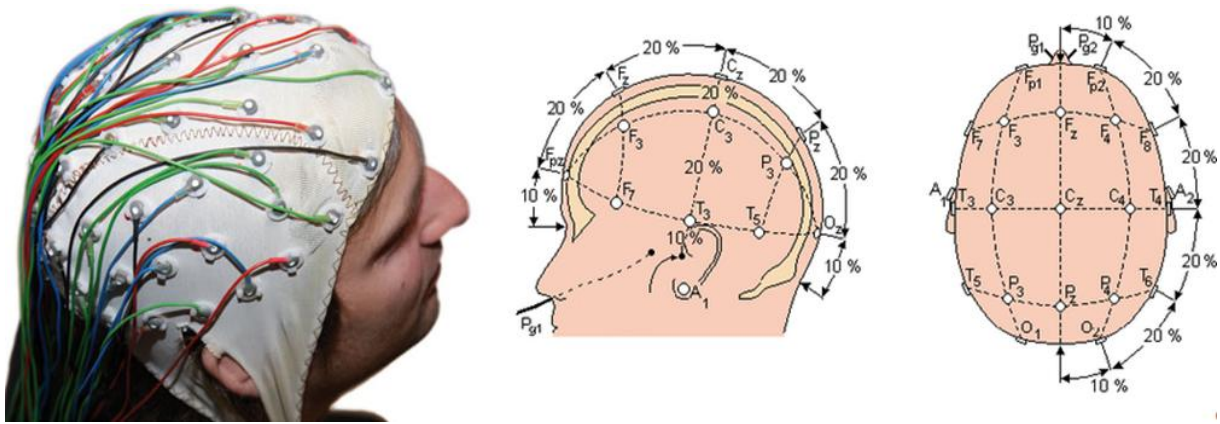
Osoba badana powinna wykonywać jak najmniej ruchów, aby zminimalizować wpływ aktywności mięśni (EMG) i innych sygnałów elektrofizjologicznych, na przykład elektrookulografii (EOG). Najczęściej elektrody wykonane są ze srebra i pokryte chlorkiem srebra (Ag-AgCl), a do ich naklejenia używa się specjalnego kleju (żelu). Tak wykonana konstrukcja ma za zadanie zminimalizować powstawanie potencjału na styku skóra-elektroda. Wartość tego potencjału, który nazywa się potencjałem standardowym lub potencjałem równowagowym, może wynosić nawet kilka woltów. W elektroencefalografii przyjęto standard, iż wartość tego potencjału nie powinna przekraczać 300 mV. Można również zastosować specjalne elektrody aktywne, ze wzmacniaczami jak również elektrody suche.

Elektrody suche nie wymagają stosowania żelów lub past. Trwają intensywne prace nad konstrukcją jak najlepszych elektrod suchych, wygodnych w użyciu.

Elektrody naklejane są na głowie w wyznaczonych miejscach. Najczęściej wybiera się miejsca określone przez międzynarodowy standard typu 10-20 (rys 4.1) - to jest 21 elektrod. Poszczególne elektrody są oznaczone symbolicznie literami i cyframi. Litery oznaczają płat kory, nad którym leży elektroda, cyfra parzysta prawą, nieparzysta lewą stronę. I tak litera F oznacza płat czołowy (łac. *frontalis*), T – płat skroniowy (*temporalis*), P - płat ciemieniowy (*parietalis*), O – potyliczny (*occipitalis*), C natomiast odnosi się do bruzdy środkowej mózgu. Elektrody umieszczone wzdłuż linii łączącej nasadę nosa z guzowatością potyliczną nie są oznaczone cyframi, lecz małą literą z. Aby technik mógł prawidłowo nakleić elektrody w odpowiednich miejscach, często używa się czepków o rozmiarach dopasowanych do rozmiaru głowy. Sygnał EEG jest zawsze przebiegiem różnicy potencjałów pomiędzy dwoma punktami. Tak więc, potencjały wytwarzane przez mózg muszą być mierzone względem jakiegoś potencjału odniesienia. Takimi miejscami są zwykle czubek nosa, połączone wyrostki sutkowate lub połączone płatki uszu. Możliwe jest również stosowanie, jako punktu odniesienia uśrednionego potencjału wszystkich elektrod. Istnieją systemy, w których używa się 32, 64 a nawet 128 elektrod. Naklejanie dużej liczby elektrod może być bardzo uciążliwe i czasochłonne, a wzmacniacz EEG bardzo kosztowny, dlatego zasadnym zadaniem jest minimalizacja liczby elektrod stosowanych w interfejsach mózg-komputer. Oczywiście można zgadywać, czy też domyślać się położenia obszarów do umiejscowienia elektrod na głowie na podstawie anatomii kory mózgowej. Czy jednak będzie to optymalne rozwiązanie, nie ma pewności. Jednym z zadań rozprawy jest próba opracowania sposobu automatyzacji wykonania tego etapu prac z wykorzystaniem komputera.

Na potrzeby diagnostyki medycznej, sygnały EEG są przekazywane do pamięci komputera i tam przechowywane. Możliwa jest ich analiza w trybie *off-line*. Warto jednak uświadomić sobie, jak wiele pamięci potrzeba na zapis sygnału EEG. Dla przykładu do przechowania godziny zapisu sygnału EEG, zebranego z 128 elektrod z częstotliwością próbkowania 500 Hz i rozdzielczością 16 bitów potrzeba ok. 0,45 GB. Tak duża ilość informacji wymaga szybkiej analizy prowadzonej często z użyciem skomplikowanych algorytmów. Systemy BCI muszą wykonywać operacje, akwizycji, przetwarzania wstępnego, ekstrakcji cech oraz klasyfikacji w trybie *on-line*! Dlatego bardzo ważnym zadaniem jest minimalizacja liczby elektrod oraz opracowanie efektywnych metod przetwarzania i analizy sygnału EEG.





Rys 4.1. Rozmieszczenie elektrod w Systemie 10-20: rzeczywiste oraz idealne

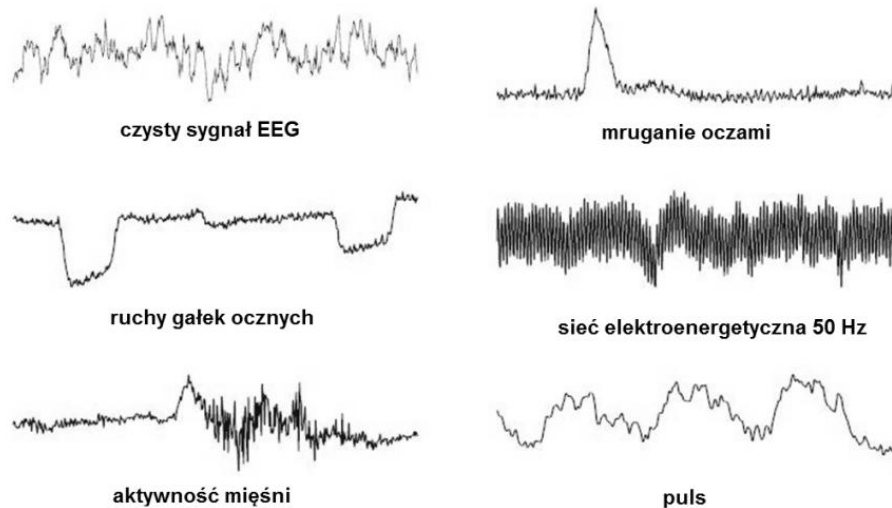
## 4.2 Artefakty w EEG

Idealem byłoby zarejestrowanie „czystych” sygnałów EEG będących wyłącznie efektem aktywności elektrycznej samego mózgu. Niestety, jak już wspomniano, rejestrowany w praktyce sygnał jest wypadkową wszystkich potencjałów pola elektrycznego (elektromagnetycznego) i zawiera sygnały niepożądane. Sygnały te powszechnie nazywa się artefaktami. Artefakty dzieli się na fizjologiczne i techniczne. Artefakty fizjologiczne to potencjały generowane w organizmie innego pochodzenia niż aktywność mózgu. Natomiast artefakty techniczne to potencjały (zakłócenia) pochodzące od wszelakich urządzeń technicznych. Dotyczy to najczęściej potencjałów indukowanych na powierzchni głowy, czy samych elektrodach, pochodzących od sieci elektroenergetycznej 50/60 Hz.

Do artefaktów fizjologicznych zaliczyć można:

- Artefakty powstałe wskutek napinania mięśni. Ruch powoduje powstanie potencjału elektrycznego (EMG) wielokrotnie przewyższającego poziom sygnału EEG. Najczęściej artefakty takie wywoływane są mimowolnymi ruchami kończyn, napięciem mięśni karku, połykaniem, poruszaniem języka, lub zaciskaniem szczęki.
- Artefakty powstałe na skutek poruszania gałkami ocznymi (EOG) lub podczas mrugania. Mrugnięcie osoby badanej wywołać może powstanie potencjału o amplitudzie nawet do 100uV.
- Artefakty powstałe na skutek działania układu krwionośnego. Wywołuje je aktywność mięśnia sercowego (EKG), puls, oddychanie.

Wyekstrahowane z EEG artefakty fizjologiczne zaprezentowane zostały na rysunku 4.2.



Rys 4.2. Typowe artefakty występujące podczas rejestracji EEG

Artefakty techniczne są skutkiem niedoskonałości przyrządów pomiarowych lub właściwości zastosowanej metody pomiarowej. Każdy z elementów aparatury pomiarowej, może wprowadzać różnego rodzaju zakłócenia lub zniekształcenia sygnału. Możemy wyróżnić następujące typy zakłóceń/zniekształceń:

- powstające przy przekazywaniu sygnału z elektrod do aparatury,
- związane ze wzmacnianiem sygnału,
- związane z przetwarzaniem sygnału analogowego na cyfrowy.


Powodem zakłóceń powstających, przy przekazywaniu sygnału z elektrod do aparatury pomiarowej są fale elektromagnetyczne, generowane w otoczeniu i odbierane przez pasożytnicze pojemności i indukcyjności kabli. Odprowadzenia elektrod są wrażliwe na pole elektromagnetyczne jak również wzajemne ruchy względem siebie. Szумы o wysokiej częstotliwości nie mają większego wpływu, gdyż są eliminowane przez dolnoprzepustowe filtry analogowe (we wzmacniaczu). Zmniejszając impedancje przewodów, chociażby poprzez skrócenie ich długości można znacznie osłabić zakłócenia. Można też przewody ułożyć w wiązki, ograniczając ich ruch względem siebie.

Sygnał zbierany przez elektrody zostaje wzmacniony za pomocą specjalistycznego wzmacniacza EEG. Wzmacniacz ten jest źródłem szumów. Bardzo ważnym parametrem wzmacniacza, jest wartość amplitudy szumów wyjściowych odniesiona do jego wejścia. Wartość ta dla dobrego wzmacniacza powinna wynosić około  $1\mu\text{V}$ . Istotnym parametrem jest też pasmo przenoszonych częstotliwości. Dla sygnału EEG, nie ma specjalnych wymagań, musi to być zakres od 0,5Hz do kilkudziesięciu Hz. Inny parametr wzmacniacza to

wzmocnienie napięciowe. W praktyce stosuje się wzmocnienia poniżej 30, gdyż stałe napięcie elektryczne pomiędzy skórą pacjenta a elektrodą może dochodzić do 200mV i może doprowadzić do przesterowania wzmacniacza [113].

Nowoczesne wzmacniacze EEG cechują się bardzo wysokim współczynnikiem tłumienia sygnałów wspólnych – *Common Mode Rejection Ratio* (CMRR). Dla dobrej klasy wzmacniaczy wynosi on przynajmniej 100dB.

Przed przystąpieniem do przetwarzania sygnału do postaci cyfrowej należy przeprowadzić antyaliasingową filtrację dolnoprzepustową (w celu usunięcia składowych powyżej częstotliwości Nyquista). Z działaniem przetwornika analogowo-cyfrowego wiąże się błąd kwantyzacji (źródło szumu kwantyzacji). Cały tor do rejestracji sygnału EEG wraz z elementami wzmacniacza został zaprezentowany na rysunku 4.3.



Rys 4.3. Schemat toru rejestracji sygnału EEG EEG. 1) Elektrody, 2) Wzmacniacz, 3) Filtr dolnoprzepustowy, 4) Przetwornik A/C, 5) mikroprocesor, 6) Wzmocnienie może być regulowane z poziomu procesora, 7) zarejestrowane dane przechowywane są w pamięci

Artefakty w sposób znaczący mogą zakłócać sygnał EEG. Stopień eliminacji artefaktów w dużej mierze zależy od jakości zastosowanego sprzętu oraz dokładności wykonania badania przez technika-medyka. Artefakty fizjologiczne można zwalczać na kilka sposobów. Pierwszym sposobem jest ograniczenie wszelkich ruchów i napinania mięśni przez osobę badaną. Osoba wykonująca badanie powinna, w sposób odpowiedni, poinstruować użytkownika interfejsu, co do zachowań (sposób siedzenia, rozluźnienie mięśni, relaks). Czasem wymagane jest zaciśnięcie języka pomiędzy zębami czy rozluźnienie mięśni karku. Nigdy jednak artefakty nie zostaną wyeliminowane zupełnie. W zastosowaniach klinicznych, doświadczony lekarz bez problemu rozpozna fragmenty sygnału EEG, w których występowały artefakty. Taki fragment sygnału nie jest brany pod uwagę podczas oceny zapisu EEG. Odrzucenie fragmentu sygnału EEG wykonywane jest najczęściej przez osobę

doświadczoną. W ostatnim czasie pojawiły się pewne narzędzia automatyczne, ułatwiające wskazanie miejsc zawierających artefakty fizjologiczne.

Aby wykryć automatycznie artefakty wykorzystuje się najczęściej metody częstotliwościowe. Główna idea rozpoznania artefaktu polega na sprawdzeniu, jakie częstotliwości dominują w zarejestrowanym sygnale. Jeśli częstotliwości sygnału odbiegają znacząco od częstotliwości sygnału EEG, wtedy klasyfikator zaznacza ten fragment, jako artefakt. Inną metodą eliminacji, a nawet usuwania artefaktów, są metody polegające na odejmowaniu sygnału zakłócającego od sygnału EEG. Najczęściej dotyczy to artefaktów elektrookulograficznych. Wtedy, oprócz samego sygnału EEG, rejestrowany jest sygnał okulograficzny (EOG). Istnieje możliwość odjęcia od zakłóconego sygnału EEG przebiegu EOG, co może w sposób znaczący zminimalizować wpływ artefaktu. Istnieją też bardziej wyrafinowane metody usuwania artefaktów jak np. technika ślepej separacji sygnału (BSS). Jedną z metod jest analiza składowych niezależnych (ICA).

Można zatem wyobrazić sobie system BCI, gdzie w pierwszym etapie następuje usunięcie artefaktów z sygnału EEG, a dopiero później klasyfikacja. Aktualnie w systemach BCI dokonuje się klasyfikacji sygnału EEG bez wstępnego usuwania artefaktów. Trzeba jednak pamiętać, że systemy BCI przeznaczone są dla osób niepełnosprawnych, które często nie mają możliwości poruszenia oczami czy kończynami (brak w sygnale tego typu artefaktów).

### **4.3 Charakterystyka danych eksperymentalnych**

Podczas eksperymentów wykonywanych na potrzeby rozprawy, autor wykorzystywał sygnały EEG z bazy danych oraz sygnały zarejestrowane z użyciem własnego systemu BCI. Sygnały z bazy danych miały tą przewagę, że pochodziły od wyselekcjonowanych użytkowników i umożliwiały skuteczną klasyfikację dla przypadku interfejsu asynchronicznego. Interfejsy asynchroniczne wymagają nauki „generowania” odpowiednich zadań myślowych. Zawartość bazy danych dawała pewność, że autor pracuje na właściwych sygnałach, umożliwiających prawidłową klasyfikację. Podczas badań autor wykonał kilkanaście samodzielnych eksperymentów z rejestracją sygnałów EEG, co upoważnia go do stwierdzenia, że rejestracja sygnału EEG jest dosyć trudnym zadaniem. Po pierwsze wynika to z przebiegu samej procedury pomiaru, a po drugie z próby wyeliminowania jak największej liczby czynników zakłócających wiarygodność rejestracji. Chodzi tu o niezamierzone rozpraszanie uwagi użytkownika podczas eksperymentu (brak koncentracji), czy minimalizację artefaktów fizjologicznych.

### 4.3.1 Opis danych z ogólnodostępnej bazy

Dane zostały zaczerpnięte z ogólnodostępnej bazy danych przygotowanej na potrzeby jednego z konkursów BCI [93]. Zawierają one sygnały EEG zarejestrowane dla trzech użytkowników. Sesje odbywały się bez *neurofeedbacku*. Podczas rejestracji osoby siedziały na fotelu zrelaksowane i z rozluźnionymi kończynami. Zadaniem użytkowników było wykonywanie pewnych zadań myślowych w zadanej chwili czasu. Zadaniem tymi były:

1. Wyobrażenie sobie ruchu lewą ręką (klasa K2),
2. Wyobrażenie sobie ruchu prawą ręką (klasa K3),
3. Wyobrażenie sobie wypowiedzianych słów rozpoczynających się na losowo wybraną literę (klasa K7).

Wszystkie sesje zostały wykonane tego samego dnia. Każda sesja trwała 5 minut z przerwami od 5 do 10 minut. Ochotnicy realizowali zadanie przez około 15 sekund, po czym następowała zmiana zadania na inne. Dane zarejestrowano z użyciem 32 elektrod usytuowanych zgodnie ze standardem 10-20 (Fp1, AF3, F7, F3, FC1, FC5, T7, C3, CP1, CP5, P7, P3, Pz, PO3, O1, Oz, O2, PO4, P4, P8, CP6, CP2, C4, T8, FC6, FC2, F4, F8, AF4, Fp2, Fz, Cz). Częstotliwość próbkowania sygnałów wynosiła 512 Hz. Nie usunięto składowej stałej. Nie zastosowano żadnej metody eliminacji artefaktów. Do plików dołączono 33 składową zawierającą informację z nazwą bieżącego zadania, w postaci przynależności do klasy.

### 4.3.2 Opis danych własnych

Podczas eksperymentów autor testował algorytmy na samodzielnie zebranych zbiorach danych EEG. Zaletą tych badań była dokładna wiedza, na temat tego jak przebiegał eksperyment oraz jaką „strategię mentalną” stosowała badana osoba. Dane zarejestrowane zostały dla dwóch użytkowników oznaczonych symbolami MK oraz AM. Sesje odbywały się bez *neurofeedbacku*. Podczas rejestracji osoba siedziała zrelaksowana na fotelu, miała rozluźnione kończyny i starała się nie wykonywać zbędnych ruchów - w celu minimalizacji artefaktów. Stwierdzono, że nie było to proste zadanie. Podczas eksperymentów nie zauważono znaczącego wpływu artefaktów poza kilkoma pochodzącym od mrugnięcia powiek dla użytkownika MK. Nie zaobserwowano znaczącego artefaktu EKG dla użytkownika MK, w odróżnieniu od AM. Zadaniem użytkowników było wykonywanie tych samych zadań, które obowiązywały w poprzednim przypadku tzn.:


1. Wyobrażenie sobie ruchu lewą ręką (klasa K2)
2. Wyobrażenie sobie ruchu prawą ręką (klasa K3)

3. Wyobrażanie sobie wypowiedziania słów na losowo wybrana literę (klasa K7).

Dla ułatwienia zadania, użytkownicy podczas wyobrażania sobie ruchu zastosowali strategię myślenia o ścisaniu gumowej piłeczki w tempie ok. jeden raz na sekundę.

Wykonano 2 sesje, z czego każda trwała około 4 minuty, z minutową przerwą pomiędzy nimi. Użytkownicy wyobrażali sobie zadanie przez około 15 sekund, po czym następowała sekundowa przerwa, a następnie losowa zmiana zadania na inne. Polecenia dla użytkownika pojawiały się w formie strzałek na ekranie monitora. Przy czym strzałka skierowana w prawą stronę oznaczała zadanie K3, lewą stronę K2, a strzałka skierowana do góry skojarzona była z zadaniem K7. Sekwencja poleceń wyświetlanych użytkownikowi została zobrazowana na rys. 4.4. Dane zarejestrowano z wykorzystaniem profesjonalnego wzmacniacza firmy g.Tec typ g.UsbAmp 3.0 seria UB [99]. Opis parametrów wzmacniacza zamieszczono w dodatku D1.

Użyto 8-miu elektrod aktywnych (F3, F4, T7, C3, CP1, C4, T8, Cz) z zastosowaniem kleju-żelu. Częstotliwość próbkowania sygnałów wynosiła  $F_s=256$  Hz. Zastosowano pasmowo-przepustowy filtr Butterworda  $0,5\text{Hz}\pm 30\text{Hz}$ . Nie zastosowano żadnej metody eliminacji artefaktów. Zarejestrowane dane zawierały 9 komponent wskazujący na numer wykonywanego zadania (klasa).



Rys 4.4. Schematyczne przedstawienie sposobu pozyskiwania danych do eksperymentów

---

## 5. PRZETWARZANIE WSTĘPNE SYGNAŁU

---


Jak już wspomniano, sygnały EEG są zwykle zakłócone przez artefakty fizjologiczne oraz techniczne. Istnieje wiele metod wydobywania „bardziej użytecznego” sygnału. Najbardziej rozpowszechniona jest filtracja. Często znane są parametry widmowe sygnałów zakłócających EEG. Możemy je częściowo wyeliminować zarówno z użyciem filtracji analogowej jak i cyfrowej.

Sygnały EEG rejestrowane przez pojedynczą elektrodę, są superpozycją sygnałów z wielu źródeł (np. przypisanych do innych elektrod), dlatego użyteczne stały się tak zwane filtry przestrzenne. W metodzie filtracji przestrzennej wykorzystuje się informację na temat wzajemnego położenia elektrod i eliminuje cząstkowe wartości sygnału pochodzącego z innych (otaczających) elektrod. Znane są również inne metody działające na zasadzie estymacji sygnału źródłowego. Przykładem takiej metody jest ślepa separacja sygnału (*Blind Signal Separation* - BSS), a w szczególności analiza składowych niezależnych (*Independent Component Analysis* - ICA). Wszystkie operacje przetwarzania wstępnego tworzą nowe sygnały w dziedzinie czasu. Liczba tych nowych sygnałów zwykle jest taka sama jak liczba elektrod. Niekiedy jednak liczba otrzymanych sygnałów może zostać ograniczona poprzez wydobywanie tylko sygnałów najbardziej znaczących. Do wyznaczenia nowych sygnałów wykorzystuje się oczywiście wszystkie zarejestrowane (pierwotne) sygnały EEG, a sygnały wynikowe tworzone są przez superpozycję sygnałów oryginalnych z pewnymi wagami. Wagi te wskazać mogą miejsce pochodzenia sygnału, jak to jest w przypadku BSS i ICA.

### 5.1 Filtracja częstotliwościowa


Jak już wspomniano, przyjmuje się, że sygnał EEG obejmuje zakres częstotliwościowy od 0,5Hz do 100Hz [134]. Część artefaktów, mieści się w użytecznym widmie sygnału EEG, dlatego nie jest możliwe wyeliminowanie wszystkich artefaktów, a jedynie ograniczenie ich wpływu. Najczęściej spotykane w praktyce obróbki cyfrowej sygnału EEG są filtry pasmowo-przepustowe 0,1Hz÷40Hz, filtry dolnopasmowe do 40Hz, filtry typu *notch* o blokowanej częstotliwości 50Hz (albo 60 Hz). Filtry cyfrowe wykorzystywane w EEG to zarówno filtry o skończonej odpowiedzi impulsowej (FIR) jak i filtry rekursywne o nieskończonej odpowiedzi

impulsowej (IIR). Na rysunku 5.1 zamieszczono 1-sekundowy zapis sygnału jednego kanału EEG. Widać na nim wyraźnie zakłócenie o częstotliwości sieci elektroenergetycznej 50Hz.



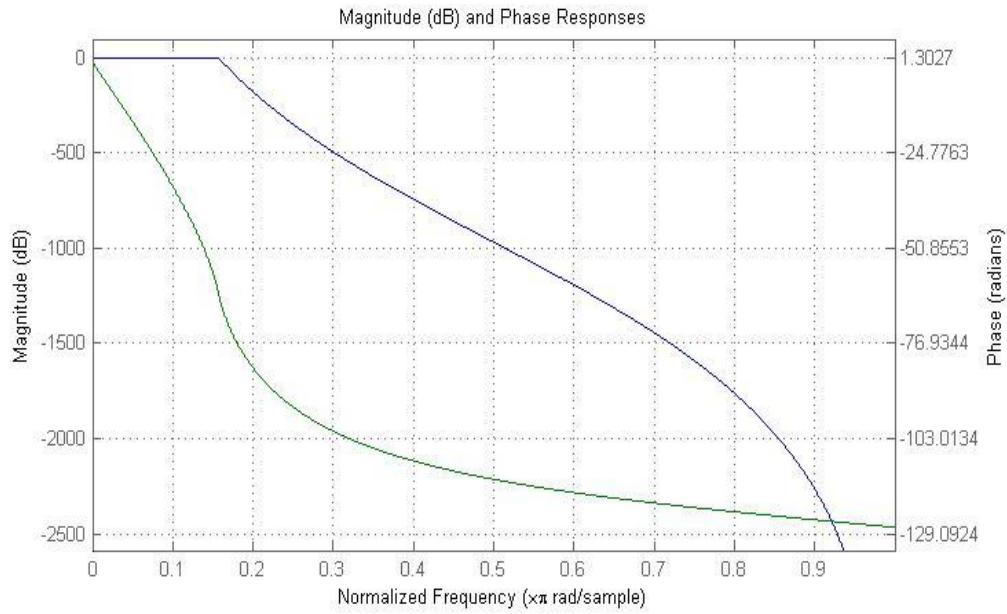
Rys 5.1. Typowy zapis 1-sekundowy sygnału EEG z bazy danych zakłócony przebiegiem sieci elektroenergetycznej

W tym konkretnym przypadku, aby w ogóle możliwe było zaobserwowanie sygnału EEG, konieczne jest zastosowanie filtra pasmowozaporowego (50Hz) lub filtra dolnoprzepustowego (40Hz). W tym celu autor wykorzystywał filtr cyfrowy typu IIR Butterwortha o parametrach projektowych zapisanych na rysunku 5.2. Charakterystyki częstotliwościowe tego filtra przedstawione są na rys. 5.3.




Rys 5.2. Szablon użyty do zaprojektowania filtra dolnoprzepustowego Butterwortha ( $f_s=512\text{Hz}$ ,  $F_{\text{pass}}=40\text{Hz}$ ,  $F_{\text{stop}}=45\text{Hz}$ ,  $A_{\text{pass}}=1\text{dB}$ ,  $A_{\text{stop}}=80\text{dB}$ , Rząd filtru=81)





Rys 5.3. Charakterystyka amplitudowa i fazowa filtru

Po zastosowaniu filtru, sygnał jest czytelny i odzwierciedla typowy przebieg EEG (rys 5.4). Tak przefiltrowany sygnał EEG, można poddawać dalszemu procesowi przetwarzania wstępnego sygnału na przykład ICA.



Rys 5.4. Typowy zapis jednej sekundy sygnału EEG po filtracji dolnoprzepustowej o paśmie 40Hz

## 5.2 Filtry przestrzenne

### 5.2.1 Filtry Laplace'a

Jak wynika z poprzednich opisów, potencjały zebrane z powierzchni głowy, za pomocą przyklejonych do niej elektrod, charakteryzują się słabą rozdzielczością przestrzenną. Badania symulacyjne wykazują [96], że zaledwie ok. połowa zebranego sygnału EEG pochodzi z fragmentu głowy pod elektrodą o promieniu 3 cm! Reszta pochodzić może z innych obszarów mózgu lub co gorsza z mięśni. Problem staje się bardziej znaczący, jeśli przeznaczone do analizy sygnały są bardzo słabe, na przykład rytmy sensomotoryczne. Inne obszary mózgu wykazujące aktywność i generujące sygnały (silniejsze) o tej samej częstotliwości, mogą w sposób znaczący zakłócać właściwy sygnał. W przypadku potencjałów wywołanych (P300 lub SSVEP) istnieje możliwość podania bodźca wielokrotnie i uśrednienia rezultatów odpowiedzi, co znacznie poprawia jakość sygnału i ułatwia późniejszą analizę. Ten problem staje się istotny w przypadku wydobywania informacji o wyobrażeniu sobie ruchu przez użytkownika, na podstawie tylko 1-sekundowego zapisu EEG. Sytuację częściowo poprawia zastosowanie *biofeedbacku* [151]. Użytkownik „uczy się generować” mocniejsze i bardziej „odpowiednie” sygnały EEG. Trening może trwać nawet kilka tygodni czy miesięcy. Dalszy etap to wstępne przetwarzanie sygnału, jak np. zastosowanie odpowiedniej kombinacji sygnałów pochodzących z sąsiednich elektrod (sumowanie lub odejmowanie z odpowiednimi wagami), co może doprowadzić do uzyskania zupełnie nowego sygnału, który zawiera znacznie więcej użytecznych informacji. Takie „tworzenie” nowego sygnału określane jest mianem filtracji przestrzennej (*spatial filters*) [54]. Przykładami metod operujących w tej dziedzinie są: filtr Laplace'a (*Laplace filter*), *Local Average Technique* (LAT), oraz *Common Average Reference* (CAR). Warto zauważyć, że zgodnie z przyjętą definicją, nawet zwykła rejestracja sygnału EEG zawiera filtrację przestrzenną, ponieważ pozyskuje się sygnał w sposób różnicowy, względem punktu referencyjnego (np. wyrostka sutkowatego). W przypadku filtrów typu LAT i Laplace'a, do wyznaczania nowych kombinacji sygnałów używa się składowych pochodzących tylko z elektrod sąsiednich. Przy filtracji CAR używa się wszystkich zarejestrowanych sygnałów.

Filtry przestrzenne Laplace'a wykorzystuje się do usunięcia wartości średniej potencjału. Taki potencjał występuje na każdej elektrodzie i nie wnosi użytecznej informacji. Tutaj należy podkreślić, że choć po zastosowaniu filtru przestrzennego, otrzymuje się nowy sygnał to wiadomo, że został on skonstruowany z użyciem kilkunastu lub wszystkich elektrod.

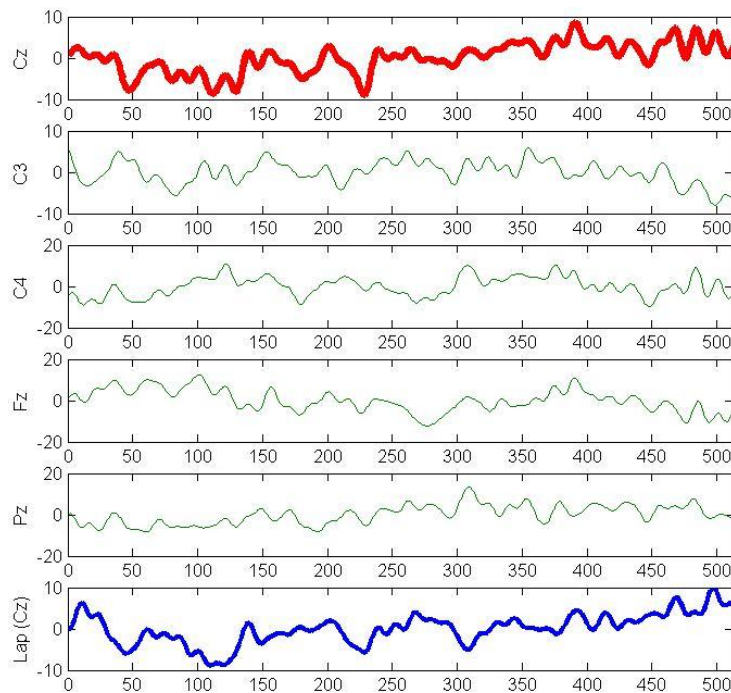
Zastosowanie filtrów przestrzennych nie pozwala na ograniczenie, w sposób bezpośredni, liczby elektrod stosowanych do rejestracji sygnału EEG, ale może poprawić jakość sygnału.

Metoda filtru przestrzennego Laplace'a została zaproponowana przez Hjorta w 1975 roku [56]. Przy założeniu symetrycznego rozmieszczenia elektrod, Laplasjan może być wyznaczony przez odjęcie ważonych średnich wartości potencjału elektrod sąsiednich, zgodnie z zależnością (5.1):

$$V_j^{Lap} = V_j - \frac{1}{4} \sum_{k \in S_j} V_k \quad (5.1)$$

gdzie  $V_j$  jest potencjałem  $j$ -tej elektrody, a  $S_j$  zbiorem indeksów czterech najbliższych kanałów (tzw. mały Laplace). Jeśli  $S_j$  jest zbiorem indeksów czterech dalszych kanałów, wtedy używa się określenia duży Laplace.

Dla przykładu, aby wyliczyć nową wartość sygnału  $V_{Cz}^{Lap} = V_{Cz} - \frac{1}{4} (V_{C3} + V_{C4} + V_{Pz} + V_{Fz})$  należy odjąć od wartości potencjału zarejestrowanego przez elektrodę Cz sąsiednie uśrednione potencjały z elektrod C3, C4, Pz i Fz z wagami 1/4 (patrz rys 5.5)



Rys 5.5. Tworzenie nowego sygnału  $Lap(Cz)$

Taka sytuacja ma miejsce przy wykorzystaniu potencjału P300, który zlokalizowany jest na „czubku” głowy, w okolicy elektrody Cz. Ponieważ jednak potencjał P300 „dociera” również do sąsiednich elektrod, często analizuje się sygnał będący sumą sygnału pochodzącego z elektrody Cz oraz elektrod sąsiednich. Suma ta powinna być liczona


z odpowiednimi wagami przypisanymi do poszczególnych elektrod. Często wagi te są dobrane intuicyjnie przez analityka. Autor podczas badań, prowadzonych na potrzeby rozprawy, przebadał możliwość polepszenia jakości sygnałów dzięki zastosowaniu filtrów przestrzennych dla ograniczonej liczby elektrod. W tym przypadku zbiór rejestrowanych sygnałów obejmował tylko korę sensomotoryczną.

### 5.2.2 Wspólny uśredniony potencjał odniesienia

Często stosowanym filtrem przestrzennym w elektroencefalografii, również w zastosowaniu do BCI, jest filtr określany mianem *Common Average Reference* (CAR). W tym przypadku wartość potencjału dla elektrody wyliczana jest poprzez odjęcie od potencjału tej elektrody uśrednionej sumy potencjałów wszystkich elektrod:

$$V_j^{CAR} = V_j^{ER} - \frac{1}{n} \sum_{i=1}^n V_i^{ER} \quad (5.2)$$

Gdzie  $V_i^{ER}$  jest potencjałem pomiędzy  $j$ -tą elektrodą a elektrodą odniesienia, a  $n$  jest liczbą elektrod zastosowanych w eksperymencie.



Rys 5.6. Stosowane metody filtracji przestrzennej

Przykład wykorzystania elektrod dla różnych metod filtracji przestrzennej zaprezentowano na rysunku 5.6. Należy pamiętać, że kombinacja sygnałów pochodzących z różnych elektrod daje w efekcie „nowy” sygnał. Ten etap przetwarzania sygnału ma bardzo duży wpływ na późniejsze etapy (ekstrakcji cech, selekcji cech oraz klasyfikacji), a co za tym idzie całego toru działania interfejsu mózg-komputer. Sprawne działanie późniejszych etapów analizy sygnału bardzo zależy od zastosowanych filtrów przestrzennych. Nie jest rzeczą oczywistą, w jakim stopniu zastosowanie filtrów przestrzennych poprawi jakość klasyfikacji i usprawni działanie całego interfejsu. W szczególności problem filtracji przestrzennej jest istotny

z punktu widzenia, postawionego przez autora problemu, minimalizacji elektrod. Autor podjął próbę poszukania odpowiedzi na to pytanie.

### 5.2.3 Wspólne wzorce przestrzenne

W uproszczeniu można przyjąć, że w przypadku filtrów przestrzennych, usunięcie uśrednionego potencjału z innych elektrod poprawi jakość analizowanego sygnału. Jednak nie ma pewności czy taka operacja przyniesie zamierzony skutek. Wiadomo, że przy filtracji Laplace'a, wykorzystywana jest tylko informacja o potencjale z najbliższego otoczenia centralnej elektrody. Takie podejście wcale nie oznacza rozwiązania „optymalnego”, zwłaszcza w kontekście doboru wag. Z pomocą przychodzi kolejna metoda przetwarzania wstępnego, zaproponowana właśnie na potrzeby interfejsu mózg-komputer (dedykowana), metoda „wspólnych wzorców przestrzennych”<sup>5</sup> (*Common Spatial Pattern* - CSP). Metodę tę przedstawił H. Romaser w swoim artykule pt. „*Optimal Spatial Filtering of Single Trial EEG During Imagined Hand Movement*” [120]. Zaproponowana przez niego metoda ma bardzo duże znaczenie z punktu widzenia poruszanego w rozprawie problemu. Po pierwsze, została specjalnie opracowana na potrzeby skutecznej klasyfikacji sygnału EEG z wykorzystaniem pojedynczej realizacji zarejestrowanej podczas wyobrażania sobie ruchu przez użytkownika. Po drugie w metodzie tej, poprzez filtrację przestrzenną (z doбором wag) tworzy się nowe sygnały, na zasadzie maksymalizacji wariancji, dla dwóch różnych klas (wyobrażeń ruchu). Na podstawie „dobrych” przez algorytm wag możliwe jest wykrycie, które elektrody wnoszą najwięcej do procesu dyskryminacji klas. Dodatkowo wagi (*filter*) i wzorce (*pattern*) „stworzone” przez algorytm są łatwo interpretowalne przez neuropsychologów. Dzięki temu możliwe jest trafne wskazanie miejsc, w których powinny znajdować się elektrody, aby najlepiej separować dwie klasy.

W praktyce, algorytm ten jest stosowany szeroko w zakresie dyskryminacji klas, dla systemów wielokanałowych (32 czy 64 kanały) [120,36,80]. W swoich badaniach, na użytek rozprawy, autor poszedł o krok dalej. Najpierw podjęta została próba selekcji elektrod, a następnie, na już ograniczonej liczbie elektrod zastosowana metoda CSP do wyznaczenia nowych wag filtru przestrzennego i wreszcie ekstrakcja cech i klasyfikacja sygnału. Autor nie spotkał się nigdy wcześniej z prezentacją takiego podejścia w dostępnych publikacjach naukowych. Choć algorytm CSP został stworzony do dyskryminacji dwóch klas, to jest możliwe rozszerzenie go na zadanie wieloklasowe. Można tego dokonać poprzez rozwiązanie „podzadań”: jedna klasa przeciwko każdej klasie lub jedna klasa przeciwko wszystkim

---

<sup>5</sup> tłumaczenie autorskie

klasom. Podobne podejście stosuje się podczas klasyfikacji sygnału metodą wektorów wspierających (SVM).

W przypadku dwu klas, metoda CSP bazuje na wykorzystaniu diagonalizacji dwóch macierzy kowariancji dla tych klas. Niech dana będzie macierz  $E$  o rozmiarach  $N \times T$  zawierająca przebiegi sygnałów EEG w czasie (zarejestrowane sygnały EEG dla dwóch różnych wyobrażeń ruchu). Niech  $N$  oznacza liczbę kanałów w zapisie sygnału EEG, a  $T$  kolejne próbki w zapisie sygnału EEG, dla każdego kanału. Znormalizowaną macierz kowariancji  $C$  można otrzymać z zależności [33]:

$$C = \frac{EE^T}{\text{tr}(EE^T)} \quad (5.3)$$

Gdzie  $E^T$  oznacza transpozycję macierzy, a operator  $\text{tr}(E)$  ślad macierzy (*trace*), czyli sumę diagonalnych elementów macierzy  $E$ . Dla każdej klasy zarejestrowanych sygnałów EEG, to jest dla wyobrażenia sobie ruchu prawą -  $\overline{C}_R$  lub lewą ręką -  $\overline{C}_L$  wyliczana jest przestrzenna macierz kowariancji  $C_C$ :

$$C_C = \overline{C}_R + \overline{C}_L \quad (5.4)$$

Macierz  $C_C$  można poddać faktoryzacji  $C_C = U_C \lambda_C U_C^T$ , gdzie  $U_C$  jest macierzą wektorów własnych, a  $\lambda_C$  oznacza macierz diagonalną wartości własnych. Należy zwrócić uwagę, że wartości własne po tej operacji powinny być posortowane od największej do najmniejszej. Następnym krokiem jest zdefiniowanie macierzy wybielającej (normalizującej wariancję):

$$P = \sqrt{\lambda_C^{-1}} U_C^T \quad (5.5)$$

i przetransformowanie macierzy  $\overline{C}_L$  oraz  $\overline{C}_R$  do postaci:

$$S_L = P \overline{C}_L P^T \text{ oraz } S_R = P \overline{C}_R P^T \quad (5.6)$$

Wreszcie rozkład macierzy  $S_L$  oraz  $S_R$  na wartości własne i wektory własne. Można wykazać, że po rozłożeniu obydwu macierzy otrzyma się takie same wektory własne zapisane w macierzy  $B$ :

$$S_L = B \overline{\lambda}_L B^T \text{ oraz } S_R = B \overline{\lambda}_R B^T \quad (5.7)$$

Wartości własne będą spełniały warunek:  $\lambda_L + \lambda_R = I$ , gdzie  $I$  to macierz jednostkowa. Oznacza to, że suma korespondujących ze sobą wartości własnych zawsze wynosi jeden. Wektor własny macierzy  $S_L$  dla największej wartości własnej odpowiada najmniejszej wartości własnej dla macierzy  $S_R$  i odwrotnie. Wynika stąd, że wektory własne zapisane w macierzy  $B$  są użyteczne do klasyfikacji dla dwu zarejestrowanych grup sygnałów EEG. Zrzutowanie wybielonego sygnału EEG na pierwszą i ostatnią wartość wektora własnego w macierzy  $B$  pozwoli otrzymać nowy przebieg sygnału, który umożliwi optymalne

rozdzielenie dwu omawianych klas (grup) sygnału EEG. Ostatecznie, macierz transformacji  $\mathbf{W}$  wyznacza się poprzez zależność:

$$\mathbf{W} = (\mathbf{B}^T \mathbf{P})^T \quad (5.8)$$

Aby wyliczyć nowe przebiegi sygnałów  $\mathbf{Z}$  po zastosowaniu nowego filtru przestrzennego  $\mathbf{W}$ , należy wymnożyć macierze  $\mathbf{W}$  oraz  $\mathbf{E}$ :

$$\mathbf{Z} = \mathbf{W}\mathbf{E} \quad (5.9)$$


Macierz  $\mathbf{W}$  można interpretować na dwa sposoby: z jednej strony wiersze macierzy  $\mathbf{W}$  mogą być interpretowane jako stacjonarny filtr przestrzenny, a z drugiej można spojrzeć na kolumny macierzy  $\mathbf{W}^{-1}$  jako wspólne wzorce przestrzenne w sygnale EEG.

Tytułem eksperymentu z zastosowaniem algorytmu CSP do dwukanałowego zapisu sygnału EEG, z bazy danych zawierającej 32 kanałowy zapis sygnału EEG zostały wybrane sygnały zarejestrowane za pomocą elektrod C3 oraz C4. Podczas rejestracji sygnału użytkownik miał za zadanie myśleć o ruchu prawą ręką, a następnie o ruchu lewą ręką. Każdy fragment sygnału można więc przypisać do konkretnego zadania myślowego. Na wstępie, dwukanałowy zapis sygnału EEG został przefiltrowany za pomocą pasmowo-przepustowego filtru Butterwortha 8Hz÷12Hz. Obserwacja sygnału EEG nie pozwalała wyróżnić w przebiegu sygnału dwóch różnych fragmentów (klas). Jednak po wymnożeniu tego sygnału przez otrzymaną za pomocą algorytmu CSP macierz  $\mathbf{W}$ , możliwe jest dostrzeżenie różnic między fragmentami przebiegu przypisanymi do różnych klas K1 oraz K2. Wariancje nowych sygnałów wynosiły:  $var_{K1}=5.0950$  oraz  $var_{K2}=3.3173$ , dla sygnału gdy użytkownik wyobrażał sobie ruch prawą ręką. Natomiast, gdy użytkownik wyobrażał sobie ruch lewą ręką wariancje wynosiły odpowiednio  $var_{K1}= 6.0141$  a  $var_{K2}=10.7969$ . Zmiana nastąpiła dla próbki numer  $2,9 \times 10^4$  (rys 5.7).

Łatwo zauważyć, że algorytm CSP spełnił w tym przypadku swoje zadanie, doprowadzając do zróżnicowania wariancji nowoutworzonych sygnałów. Dla pierwszego utworzonego sygnału wariancja jest większa przy wyobrażaniu sobie ruchu lewą ręką, natomiast dla drugiego przy wyobrażaniu ruchu prawą ręką. Dodać należy, że sam algorytm CSP tworzy nowe sygnały w dziedzinie czasu. Jednak aby wyznaczyć cechy, które posłużą do nauki klasyfikatorów trzeba wygenerować z tych  $n$  nowych sygnałów pewne cechy. Najczęściej metodę CSP łączy się z wyliczeniem logarytmu z wariancji fragmentu nowych sygnałów:

$$f_p = \log (var(\mathbf{Z}_n)) \quad (5.10)$$

gdzie,  $\mathbf{Z}_n$  to nowe sygnały, wybrane po zastosowaniu algorytmu CSP.



Rys 5.7. Nowe sygnały uzyskane za pomocą algorytmu CSP

Jak już wspomniano, wariancja sygnału wąskopasmowego, może być kojarzona z energią sygnału w tym paśmie. Zatem tak należy rozumieć generowane w ten sposób cechy. Dla naszego dwukanałowego przypadku, w jednym nowostworzonym sygnale, wariancja jest większa a potem mniejsza, co ułatwia proces klasyfikacji sygnału. Celem logarytmowania wariancji jest minimalizacja wpływu dużych (*outsiders*), a zwiększenie wpływu mniejszych wartości wariancji.

### 5.3 Ślepa separacja sygnału


Jak już wspomniano, rejestrowany sygnał EEG zawiera wiele składowych pochodzących z różnych obszarów mózgu (superpozycja), ale również wiele artefaktów fizjologicznych i technicznych. Problem wydobywania (estymacji) sygnałów źródłowych nosi nazwę ślepej separacji źródeł (*Blind Source Separation*<sup>6</sup> - BSS) [9,100]. Celem takiej estymacji jest odtworzenie ukrytych w zarejestrowanych złożonych przebiegach sygnałów źródłowych. Możliwa jest również ekstrakcja szumów i artefaktów w celu późniejszej ich eliminacji.

Przykład ogólnej idei BSS przedstawiony jest na rysunku 5.8. Rejestrowane za pomocą elektrod sygnały  $x_1 \dots x_5$  stanowią superpozycję, docierających do elektrod sygnałów

<sup>6</sup> Często używana jest również nazwa: *Blind Signal Separation*



źródłowych  $s_1...s_4$ . W tym przypadku celem ślepej separacji (blok BSS) jest próba odtworzenia sygnałów oryginalnych.



Rys 5.8. Zobrazowanie poglądowej ślepej separacji sygnałów

Problem ślepej separacji sygnału może być najprościej opisany za pomocą modelu statycznego ze zbiorem liniowych równań algebraicznych. Zbiór równań można przedstawić w postaci macierzowej [100]:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{v}(t) \quad (5.11)$$

gdzie  $\mathbf{x}(t)$  jest wektorem sygnałów rejestrowanych,  $\mathbf{s}(t)$  oznacza zbiór niezależnych sygnałów źródłowych,  $\mathbf{v}(t)$  jest wektorem szumów. W modelu tym sygnały, źródłowe mieszają się w sposób liniowy z użyciem wag macierzy  $\mathbf{A}$ . Dodatkowo występuje tu szum losowy, niezależny od sygnałów źródłowych. Podczas rozwiązywania problemu BSS przyjmuje się następujące uproszczenia:

- liczba sygnałów obserwowanych jest większa lub równa liczbie sygnałów źródłowych,
- kolumny macierzy  $\mathbf{A}$  są linowo niezależne,
- szum  $\mathbf{v}(t)$  jest niezależny od sygnałów  $\mathbf{s}(t)$ , lub jest pomijalnie mały.

W przypadku, gdy znana jest macierz mieszająca  $\mathbf{A}$ , a szum pomijalnie mały, wtedy problem ma proste rozwiązanie. Jednak w praktyce macierz  $\mathbf{A}$  nie jest znana, a poszukuje się tzw. macierzy separującej  $\mathbf{W}$ , która spełnia równanie:

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t) \quad (5.12)$$

Ideałem byłoby otrzymanie sygnałów  $\mathbf{y}$ , równoważnych sygnałom źródłowym  $\mathbf{s}$ . Jednak w praktyce rozwiązanie problemu ślepej separacji sygnału ma pewne ograniczenia. Po

zastosowaniu metod BSS najczęściej sygnały nie mają takiej amplitudy jak sygnały źródłowe, a jedynie podobny do oryginału kształt. Kolejnym ograniczeniem jest to, że sygnały po separacji są nieuporządkowane, mogą mieć dowolną kolejność. Warto podkreślić, że nazwa ślepa separacja sygnału sugeruje, że nie wiemy nic lub bardzo mało o sygnałach wejściowych. W rzeczywistości jednak w niektórych algorytmach zaliczanych do metod ślepej separacji sygnału wykorzystuje się posiadaną wiedzę o właściwościach sygnałów źródłowych.

### 5.3.1 Wybielanie sygnału

Najczęściej algorytmy ślepej separacji sygnału obejmują etap, który nazwać można wybielaniem sygnału. Poniżej zostanie przedstawiony problem wybielania sygnału symulowanego, a następnie rzeczywistego. Za pomocą procedury wybielania jest możliwe odseparowanie od siebie sygnałów. Autor rozprawy ma nadzieję, że takie wybielenie sygnału, stworzy nowe przebiegi, które okażą się łatwiejsze do klasyfikacji.

Wektor  $\mathbf{y}$  o zerowej wartości średniej jest nazywany białym, jeśli jego macierz kowariancji (korelacji) definiowana jako wartość oczekiwana  $\mathbf{R}_{yy} = E\{\mathbf{y}\mathbf{y}^T\}$  jest macierzą jednostkową. Dowolny ciąg wektorów  $\mathbf{x}(k)$  o zerowej wartości średniej można przekształcić do ciągu wektorów  $\mathbf{y}$  typu białego przez następującą transformację liniową:  $\mathbf{y} = \mathbf{W}\mathbf{x}$ . Macierz  $\mathbf{W}$  jest nazywana macierzą wybielającą. Jej wybór musi być tak przeprowadzony, aby macierz korelacji  $\mathbf{R}_{xx}$  została przetransformowana w macierz jednostkową  $\mathbf{R}_{yy}$ . Oznacza to spełnienie warunków:  $\mathbf{R}_{yy} = E\{\mathbf{y}\mathbf{y}^T\} = E\{\mathbf{W}\mathbf{x}\mathbf{x}^T\mathbf{W}^T\} = E\{\mathbf{W}\mathbf{R}_{xx}\mathbf{W}^T\} = \mathbf{I}$ . Macierz kowariancji jest macierzą symetryczną i nieujemnie określoną to znaczy, że jej wszystkie wartości własne są rzeczywiste i nieujemne. Niech  $\mathbf{L}_x$  oznacza macierz diagonalną złożoną z uporządkowanych wartości własnych macierzy  $\mathbf{R}_{xx}$  tzn.  $\mathbf{L}_x = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_N]$ . Symetryczną macierz  $\mathbf{R}_{xx}$  można przedstawić wtedy jako iloczyn macierzy wektorów własnych  $\mathbf{V}_x$  oraz wartości własnych  $\mathbf{L}_x$  [33]:

$$\mathbf{R}_{xx} = \mathbf{V}_x \mathbf{L}_x \mathbf{V}_x^T \quad (5.13)$$


Można wykazać, że macierz wybielająca w postaci:  $\mathbf{W} = \mathbf{L}_x^{-1/2} \mathbf{V}_x^T$  pozwala przetransformować zbiór wektorów  $\mathbf{x}$ , w wybielone przebiegi zapisane w wektorze  $\mathbf{y}$  [33]. W wyniku wybielania sygnały stają się ortogonalne, ale jeszcze nie odseparowane od siebie. Z kolei separację można przeprowadzić za pomocą prostego przekształcenia liniowego:

$$\mathbf{X}_{sep} = \mathbf{V}_x \mathbf{y} \quad (5.14)$$


Poniżej przedstawiono przykład separacji dwu sygnałów sinusoidalnych  $s_1$  i  $s_2$  o częstotliwościach odpowiednio 1 Hz i 3 Hz, zmieszanych ze sobą. Niech nowe sygnały  $\mathbf{x}_1$  oraz  $\mathbf{x}_2$  powstałe po zmieszaniu mają postać:

$$\begin{aligned}x_1 &= 0.5s_1 + 0.7s_2 \\x_2 &= 0.7s_1 + 0.6s_2\end{aligned}\quad (5.15)$$

Przebiegi sygnałów źródłowych zamieszczono na rys. 5.9, a nowych sygnałów zmieszanych na rys. 5.10.




Rys 5.9. Sygnały źródłowe  $s_1$  oraz  $s_2$  o częstotliwościach 1Hz oraz 3Hz



Rys 5.10. Sygnały  $x_1$  oraz  $x_2$  - zsumowane z odpowiednimi wagami sygnały źródłowe  $s_1$  i  $s_2$


Na rysunku 5.10 można zaobserwować, że obydwa sygnały otrzymane po zsumowaniu, są kształtem zbliżone do siebie. Podobną sytuację można zaobserwować w rzeczywistym sygnale EEG, gdy występują podobieństwa między poszczególnymi kanałami.

Jak wspomniano, po wyznaczeniu macierzy wybielającej  $\mathbf{W}$  można otrzymać wybielone, ale jeszcze nie odseparowane sygnały. Takie sygnały, można zobaczyć na rysunku 5.11.



Rys 5.11. Sygnały wybielone -  $x_1$  oraz  $x_2$  wymnożone przez macierz wybielającą  $\mathbf{W}$

Ostatecznym krokiem, jest próba separacji poprzez rzutowanie sygnałów wybielonych, znajdujących się w wektorze  $\mathbf{y}$ , na wektory własne  $\mathbf{V}_x$ . Wynik rzutowania można obejrzeć na rysunku 5.12.




Rys 5.12. Sygnały rozseparowane


Trzeba zwrócić uwagę, że rozseparowane sygnały nie mają właściwej amplitudy ani nie są uszeregowane. Jednak mają identyczny kształt jak sygnały oryginalne. Można zatem

powiedzieć, że sygnały zostały prawidłowo rozseparowane. Jest nadzieja, że opisany sposób wystarczy do separacji sygnałów EEG i ułatwi ich klasyfikację.

Stąd kolejny przykład: próba separacji rzeczywistego sygnału EEG za pomocą wybielania. Wybrano dwa przefiltrowane (8Hz÷30Hz) kanały EEG (elektrody C3 oraz C4). Następnie zastosowano opisany powyżej algorytm wybielania i separacji sygnału. Sygnały oryginalne i rozseparowane można zobaczyć na rysunkach 5.13 oraz 5.14.



Rys 5.13. Oryginalne sygnały EEG zarejestrowane z elektrod C3 i C4



Rys 5.14. Rozseparowane sygnały EEG

### 5.3.2 Analiza składowych niezależnych

Dużą popularnością w zagadnieniu ślepej separacji sygnału cieszy się metoda analizy składowych niezależnych (*Independent Component Analysis* - ICA). Warto od razu zaznaczyć, że niezależność sygnałów jest bardziej ostrym pojęciem niż brak korelacji pomiędzy sygnałami. Dlatego podczas implementacji algorytmów ICA, oprócz wstępnego procesu wybielania sygnałów, stosuje się jeszcze rzutowanie na nowe składowe, które dają nadzieję na „większą” niezależność sygnałów. Metod wyznaczania nowych składowych niezależnych jest wiele, dlatego też istnieje szereg algorytmów ICA, które nie zostaną tu omówione szczegółowo. Podobnie jak podczas wybielania, nie ma gwarancji na to, że sygnały rozseparowane będą idealnie odzwierciedlały sygnały źródłowe. Wiele zależy od właściwości statystycznych sygnałów, które chcemy rozseparować, dlatego niektóre algorytmy ICA spisują się lepiej, a inne gorzej w pewnych konkretnych przypadkach. Znane są algorytmy ICA dedykowane konkretnym sygnałom. Autor pracy podjął się badań polegających na zastosowaniu najpopularniejszych algorytmów ICA do separacji wielokanałowych (32 kanały) sygnałów EEG. Dodatkowo autor przebadął zastosowanie algorytmów ICA do sygnałów EEG zarejestrowanych z użyciem ograniczonej do kilku liczby elektrod z nadzieją, że takie podejście da zupełnie inne jakościowo wyniki niż separacja sygnału z wykorzystaniem dużej liczby elektrod.

Metody ICA bazują na próbie znalezienia takich kierunków rzutowania, które umożliwią stworzenie nowych, niezależnych sygnałów. W ogólnym przypadku dwie zmienne losowe  $y_i$  oraz  $y_j$  są statystycznie niezależne, jeśli informacja o jednej zmiennej nie wnosi nic o drugiej. Niezależność statystyczna oznacza, że dwuwymiarowy rozkład gęstości prawdopodobieństwa  $p(y_i, y_j)$  jest równoważny iloczynowi jednowymiarowych rozkładów gęstości [100]:

$$p(y_i, y_j) = p(y_i)p(y_j) \quad (5.16)$$

Konsekwencje tego równania doprowadzają do stwierdzenia, że jeśli ciągle zmienne losowe  $y_i$  oraz  $y_j$  są niezależne, to dla dowolnych funkcji  $f_1$  oraz  $f_2$  zachodzi równość:

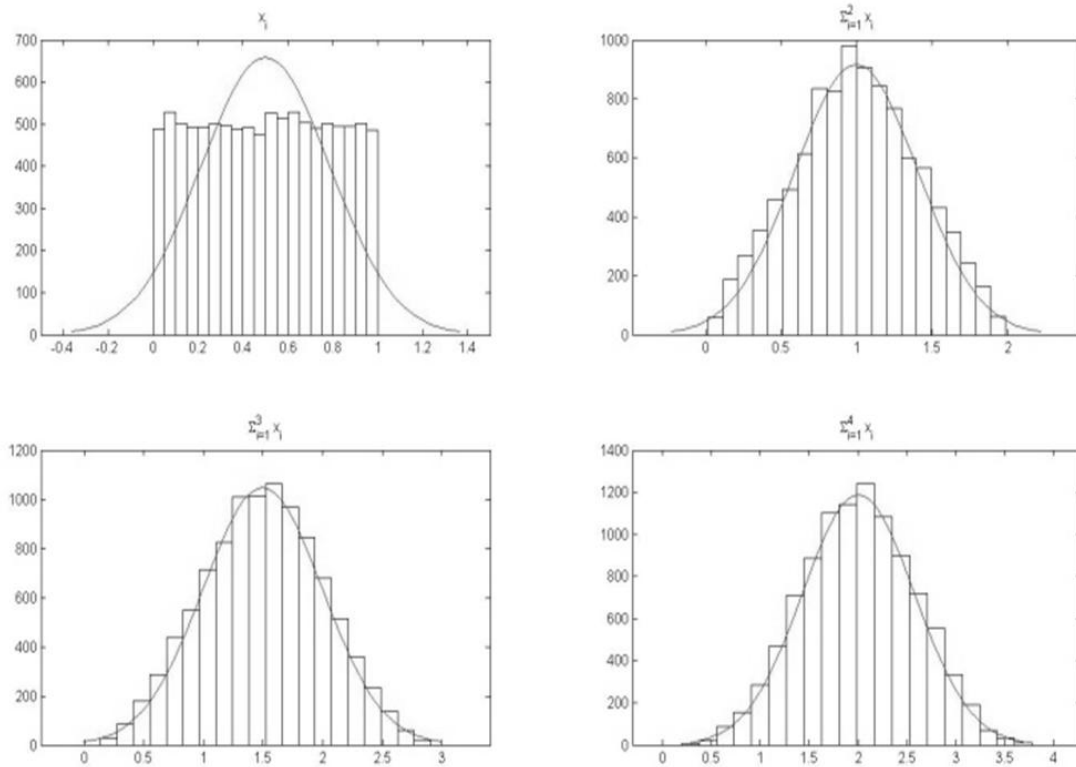
$$E[f_1(y_i)f_2(y_j)] = E[f_1(y_i)]E[f_2(y_j)] \quad (5.17)$$

gdzie  $E[\ ]$  oznacza wartość oczekiwaną. Bardzo ważnym elementem, który wykorzystuje się w analizie składowych niezależnych jest centralne twierdzenie graniczne. Mówi ono, że jeżeli  $n$  niezależnych zmiennych losowych  $y_1..y_n$  ma ten sam rozkład o skończonej wartości oczekiwanej  $\mu$  oraz wariancji  $\sigma^2 > 0$  to zachodzi związek:

$$Z_n = \frac{S_n - n\mu}{\sigma\sqrt{n}} \quad (5.18)$$

$$\lim_{n \rightarrow \infty} P[Z_n \leq z] = \varphi(z)$$

Gdzie  $\varphi$  oznacza dystrybuantę rozkładu normalnego  $N(0,1)$  a  $S_n = y_1 + \dots + y_n$ .



Rys 5.15. Centralne twierdzenie graniczne: im z większej liczby zmiennych losowych składa się nowa zmienna tym jej rozkład jest bardziej zbliżony do rozkładu normalnego

Rysunek 5.15 obrazuje centralne twierdzenie graniczne. Model ICA zakłada, że jeśli zmienna losowa ma rozkład normalny, to zgodnie z centralnym twierdzeniem granicznym jest „mieszaniną” niezależnych zmiennych losowych. Podejście to opiera się na wyznaczeniu z „mieszaniny” kolejnych składowych o rozkładzie jak najbardziej odległym od normalnego. Poszukiwane są zatem takie rzutowania, które dają nowe sygnały o rozkładzie jak najbardziej różniącym się od gaussowskiego.

Klasyczną miarą „normalności” rozkładu jest kurtoza (moment czwartego rzędu). Kurtoza sygnału  $y$  jest definiowana jako [41]:

$$Kurt(\mathbf{y}) = E[\mathbf{y}^4] - 3(E[\mathbf{y}^2])^2 \quad (5.19)$$

Kurtoza jest miarą „spłaszczenia” rozkładu. Kurtoza dla zmiennej o rozkładzie Gaussa przyjmuje wartość zero. Dla rozkładu niegaussowskiego kurtoza jest różna od zera, ale może

przyjmować wartości ujemne i dodatnie. W związku z tym, wyróżnić można różne typy rozkładów:

- mezkurtyczne, wartość kurtozy wynosi 0, spłaszczenie rozkładu jest podobne do spłaszczenia rozkładu normalnego,
- leptokurtyczne, kurtoza jest dodatnia, wartości bardziej skoncentrowane niż przy rozkładzie normalnym,
- platokurtyczne, kurtoza jest ujemna, wartości mniej skoncentrowane niż przy rozkładzie normalnym.

Poszukiwanie składowej niezależnej o rozkładzie maksymalnie niegaussowskim polega na maksymalizacji lub minimalizacji wartości kurtozy. Zazwyczaj optymalizuje się wartość bezwzględną kurtozy lub jej kwadrat. Zastosowanie w praktyce kurtozy ma pewne ograniczenia. Jest czuła na „outsiderów”. Wartość kurtozy może się zmieniać pod wpływem zaledwie kilku próbek. Dlatego kurtoza nie jest najlepszą miarą do wykorzystania w zadaniu ICA.

Drugą bardzo ważną miarą tego na ile rozkład odbiega od rozkładu gaussowskiego jest negentropia. Negentropia bazuje na teorii informacji i jest przeciwieństwem entropii. Entropia – w ramach teorii informacji jest definiowana jako średnia ilość informacji, przypadająca na znak symbolizujący zajście zdarzenia z pewnego zbioru. Im bardziej „losowa” i nieprzewidywalna jest zmienna tym ma większą entropię. Formalnie entropię można wyznaczyć z zależności [41]:

$$H(i) = - \sum_{i=1}^n p(i) \log_r p(i) \quad (5.20)$$

gdzie  $p(i)$  to prawdopodobieństwo zajścia zdarzenia  $a$ , a  $n$  to liczba wszystkich zdarzeń w danej przestrzeni. W teorii informacji najczęściej stosuje się logarytm o podstawie  $r=2$  (wtedy jednostką entropii jest *bit*). Dla  $r=e$  jednostka entropii jest *nat (nit)*. Powyższa definicja entropii może być rozszerzona na zmienne ciągłe i wtedy entropia  $H$  na wektorze  $i$  o gęstości prawdopodobieństwa  $f(i)$  może być zdefiniowana jako:

$$H(i) = - \int f(i) \log f(i) di \quad (5.21)$$

Okazuje się, że największą entropię spośród zmiennych losowych o jednakowej wariancji ma rozkład normalny i wynosi ona  $\ln(\sigma\sqrt{2\pi e})$ , gdzie  $\sigma$  to odchylenie standardowe rozkładu. Podstawowe właściwości entropii to:

- jest nieujemna,



- jest maksymalna, gdy prawdopodobieństwa zajść zdarzeń są takie same,
- jest równa 0, gdy stany systemu przyjmują wartości tylko 0 albo tylko 1,
- ma właściwość superpozycji – gdy dwa systemy są niezależne, to entropia sumy systemów równa się sumie entropii.

Aby otrzymać miarę „niegaussowości”, która jest równa zero dla rozkładu normalnego i zawsze nieujemna, zdefiniowano negentropię. Negentropia  $J$  jest zdefiniowana jako:

$$J(\mathbf{y}) = H(\mathbf{y}_{gauss}) - H(\mathbf{y}) \quad (5.22)$$

gdzie  $\mathbf{y}_{gauss}$  to zmienna losowa o rozkładzie normalnym i wariancji takiej jak wariancja wektora  $\mathbf{y}$ . Użycie negentropii jest kłopotliwe z punktu widzenia obliczeń, dlatego stosuje się różne przybliżenia negentropii. Jedną z metod takiego przybliżenia jest zastosowanie momentów wyższych rzędów (Jones i Sibson, 1987) [42]:

$$J(\mathbf{y}) \approx \frac{1}{12} E\{\mathbf{y}^3\}^2 + \frac{1}{48} kurt(\mathbf{y})^2 \quad (5.23)$$

gdzie  $\mathbf{y}$  jest zmienną losową o wartości średniej równej 0 i wariancji równej 1.

Inna funkcja przybliżająca negentropię, która ma praktyczne zastosowanie w metodzie ICA (Hyvarinen 1998), to [64]:

$$J(\mathbf{y}) \approx \sum_{i=1}^p k_i [E\{G_i(\mathbf{y})\} - E\{G_i(\mathbf{v})\}]^2 \quad (5.24)$$

Gdzie  $k_i$  jest dodatnia stałą,  $\mathbf{v}$  zmienną o rozkładzie gaussowskim, średniej zero i wariancji równej jeden, natomiast  $G_i$  są funkcjami niekwadratowymi. Najczęściej jako funkcje  $G$  wybiera się:

$$G_1(\mathbf{v}) = \frac{1}{a_1} \log \cosh a_1 \mathbf{v} \quad (5.25)$$

$$G_2(\mathbf{v}) = -\exp(-\mathbf{v}^2/2) \quad (5.26)$$

gdzie  $1 \leq a_1 \leq 2$  jest dowolnie wybraną stałą. Tak otrzymane przybliżenie negentropii daje dobry kompromis pomiędzy właściwościami dwóch klasycznych miar niegaussowości: to jest kurtozą i negentropią liczoną z definicji. Dodatkowo takie przybliżenie jest proste i szybkie w obliczeniach. Warto zaznaczyć, że istnieją jeszcze inne miary, na których opiera się estymowanie nowych składowych niezależnych, jednak nie zostaną tu opisane szczegółowo. Zainteresowany czytelnik może skorzystać z pozycji literatury [9,100,41].

Do wyznaczenia składowych niezależnych można też wykorzystać algorytm FastICA zaproponowany przez Aapo Hyvärinena [42]. Dla jednej składowej, nowy kierunek rzutowania danych  $\mathbf{w}$  znajduje się poprzez maksymalizację niegaussowości (negentropii)

zrutowanych danych  $\mathbf{w}^T \mathbf{x}$ . Negentropia aproksymowana jest za pomocą funkcji  $G_I(\mathbf{v})$  (5.25). Dla wyznaczenia odpowiedniego kierunku rzutowania, który maksymalizuje negentropię, wykorzystuje się iteracyjną metodę przybliżeń Newtona. Algorytm poszukiwania jednego komponentu (kierunku) można przedstawić w następujących krokach:

- 1. Wybierz dowolny wektor losowy  $\mathbf{w}$ ,
- 2. Oblicz wektor  $\mathbf{w}^+ = E\{\mathbf{x}G_I(\mathbf{w}^T \mathbf{x})\} - E\{G_I'(\mathbf{w}^T \mathbf{x})\}\mathbf{w}$ ,
- 3. Oblicz nowy wektor  $\mathbf{w} = \frac{\mathbf{w}^+}{\|\mathbf{w}^+\|}$ ,
- 4. Jeśli rozwiązanie nie jest zbieżne wróć do punktu 2.

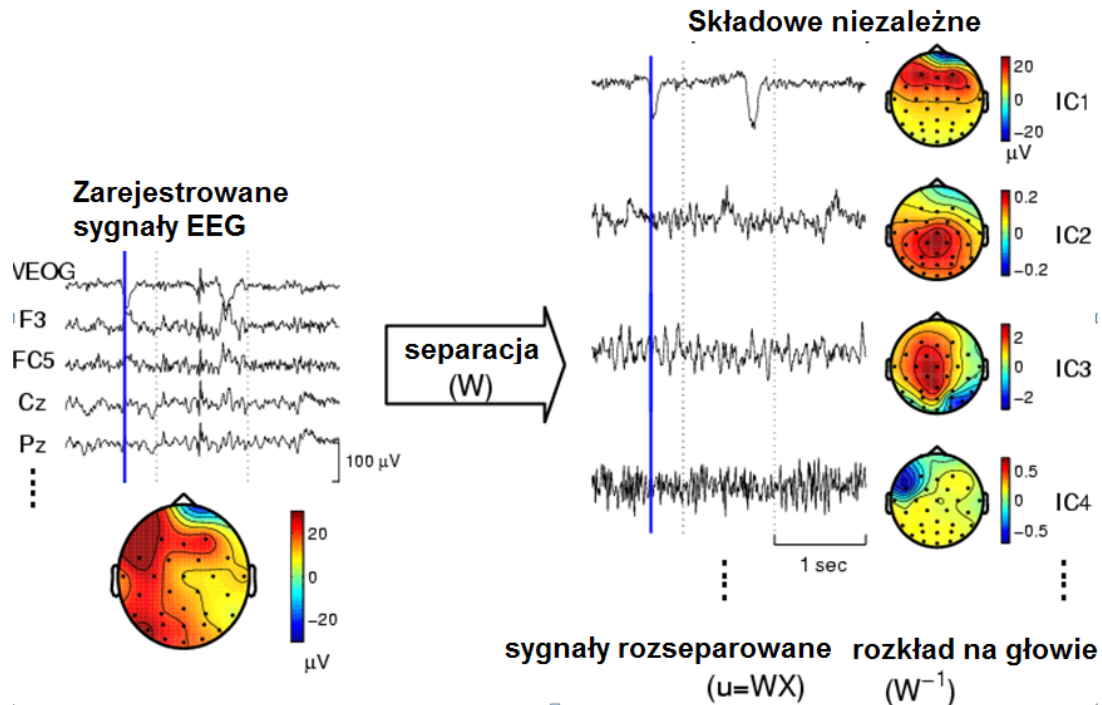
W zastosowaniu do EEG, celem ICA jest próba wyznaczenia nie jednego lecz kilku kierunków (składowych niezależnych). Tak estymowane składowe będą reprezentowały przybliżone źródła sygnału EEG. Aby zapobiec temu, że wszystkie składowe będą zbiegały podczas iteracji do tego samego maksimum trzeba przeprowadzać ortogonalizację wektorów po każdej iteracji. Jedną z najprostszych metod jest ortogonalizacja Grama-Schmidta. Metoda ta pozwala przekształcić zbiór liniowo niezależnych wektorów przestrzeni unitarnej w zbiór wektorów ortogonalnych. Twórcy algorytmu FastICA proponują natomiast użycie metody zaproponowanej przez Karhunenena, to jest de Korelacji wektorów [51]. Aby zdekorować wektory zawarte w macierzy  $\mathbf{W} = (w_1, \dots, w_n)^T$  należy wykonać operację:

$$\mathbf{W} = (\mathbf{W}\mathbf{W}^T)^{-1/2}\mathbf{W} \quad (5.27)$$

W ten sposób otrzymane wektory pozwalają wyznaczyć nowe przebiegi sygnałów. Autor przebadiał kilka najpopularniejszych algorytmów ICA do separacji sygnału EEG. Warto zauważyć, że trudna jest ocena przydatności algorytmu separacji ICA bez uruchomienia kolejnych etapów to jest ekstrakcji cech oraz klasyfikacji. Algorytmy ICA mogą mieć największe znaczenie w separacji i usuwaniu artefaktów, które są rejestrowane jako pewne składowe sygnału EEG.

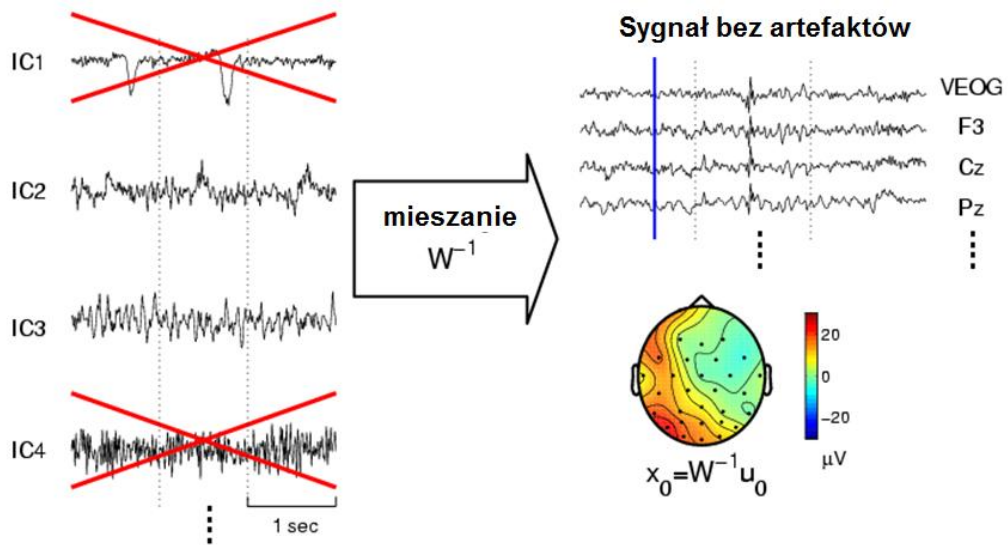
Warto pamiętać, że sama dekompozycja sygnałów na nowe składowe nie mówi jeszcze nic o pochodzeniu sygnałów. Do tego celu może posłużyć macierz wag skojarzonych z konkretnymi elektrodami. Na rysunku 5.16 można zobaczyć w jaki sposób dzięki macierzy  $\mathbf{W}$  otrzymuje się nowe składowe niezależne. Nowe składowe niezależne powstają dzięki wymnożeniu każdego zarejestrowanego sygnału przez pewną wagę, dla danego kanału, z macierzy  $\mathbf{W}$ . Na rysunku 5.16 można zaobserwować, że składowa pierwsza  $IC1$  odpowiada za artefakt pochodzący od ruchu oczami. I rzeczywiście składowa ta zakłóca najbardziej sygnał w okolicach przedniej części głowy. Jednak biorąc pod uwagę jego pokaźną amplitudę, może on mieć niekorzystny wpływ na wszystkie rejestrowane potencjały. Rozkład na głowie

poszczególnych składowych możliwy jest do uzyskania dzięki zobrazowaniu rozkładu wag macierzy  $W^{-1}$ .



Rys 5.16. Schemat działania ICA

Istnieje możliwość usunięcia niepożądanych składowych z zarejestrowanego sygnału EEG. W wyniku separacji, pojawić się mogą sygnały, których pochodzenie utożsamiane jest z aktywnością mięśni lub szumów. Jeśli odpowiednie składowe zostaną usunięte możliwe jest stworzenie sygnałów EEG bez zakłóceń i artefaktów. Na rysunku 5.17 można zobaczyć, że usunięcie składowych  $IC1$  oraz  $IC4$ , które są artefaktami mięśni i ponowne stworzenie sygnałów za pomocą macierzy  $W^{-1}$ , pozwala usunąć z przebiegu EEG wspomniane artefakty. Przedstawione w tym rozdziale metody wstępnego przetwarzania sygnału EEG mają duże znaczenie dla kolejnych etapów działania systemu BCI, to jest ekstrakcji cech i klasyfikacji. Od metod przetwarzania wstępnego oczekuje się stworzenia nowych „lepszych” sygnałów, mniej zaszumionych i mniej zaburzonych artefaktami. Choć przedstawione przez autora algorytmy przetwarzania wstępnego są znane to zostały opisane z zamieszczeniem cząstkowych wyników autorskich implementacji. Istotnym novum jest przebadanie ich zastosowania w interfejsach mózg-komputer dla ograniczonego, w sposób znaczący, zbioru elektrod.



Rys 5.17. Schemat postępowania przy usuwaniu artefaktów z sygnału EEG za pomocą metody ICA

---

## 6. EKSTRAKCJA CECH Z SYGNAŁU EEG


---

Zasadniczym celem etapu ekstrakcji cech jest próba jak najlepszego ilościowego opisanie właściwości sygnału EEG, podlegającego klasyfikacji. W wyniku tego procesu powstają wektory zawierające cechy, które umożliwiają trenowanie klasyfikatora. Zakłada się, że sygnały EEG zostały już przetworzone wstępnie, co zostało opisane dokładnie w rozdziale 5. Proces ekstrakcji cech z sygnału EEG, na użytek interfejsu mózg-komputer, był już przedmiotem wielu intensywnych badań. Powstały więc, swego rodzaju recepty na pozyskiwanie najlepszych cech, jednak wiadomo też, że cechy te mogą być różne dla różnych użytkowników, a nawet zmieniać się z czasem dla tego samego użytkownika. Takimi cechami, w przypadku wyobrażanie sobie ruchu (ERD/ERS), są najczęściej parametry częstotliwościowe sygnału. W tym etapie dokonane zostanie jedynie porównanie metod ekstrakcji cech z sygnału EEG na użytek interfejsu mózg-komputer. Tak szerokie porównanie, na tym samym zbiorze sygnałów EEG, nie jest znane autorowi.

Ogólnie, metody ekstrakcji cech charakteryzuje duża różnorodność. I choć niektóre spośród pozyskiwanych cech mają jasną interpretację fizyczną, to zwykle trudno jest przewidzieć wyższość jednych nad drugimi. Z drugiej strony, dobrane w odpowiedni sposób cechy mają olbrzymi wpływ na jakość klasyfikacji. Należy podkreślić, że we wszystkich przypadkach cechy trzeba generować w czasie rzeczywistym, bowiem na ich podstawie klasyfikator ma działać w trybie ciągłym (*on-line*) bez opóźnień. Na rys. 6.1 zaprezentowano sposób generowania cech z  $N$  kanałowego sygnału EEG, wykorzystując przesuwne okno czasowe.

Trzeba zwrócić uwagę, że każde pojedyncze okno czasowe sygnału EEG zawiera kilka (np.  $N$ ) kanałów, zatem jeśli liczba cech dla pojedynczego kanału wynosi  $K$ , to dla  $N$  kanałów (elektrod) liczba tych cech wyniesie  $K \times N$ . Efektem niektórych metod ekstrakcji jest olbrzymia liczba cech, co zwiększa problem klasyfikacji i przedłuża czas obliczeń.

Celem cząstkowych badań przeprowadzonych w ramach niniejszej pracy, było wskazanie najlepszych metod ekstrakcji cech spośród już znanych oraz zaproponowanie nowych, dedykowanych - na użytek interfejsu mózg-komputer. Należy podkreślić, że zaprezentowane nowe metody mogą zostać użyte wszędzie tam, gdzie istnieje problem klasyfikacji sygnału EEG, a nie tylko w interfejsach mózg-komputer.



Rys. 6.1. Sposób generowania cech z wielokanałowego zapisu EEG

W przypadku interfejsów synchronicznych jednoznacznie wiadomo kiedy rozpoczynać analizę sygnału EEG oraz etap ekstrakcji cech. W przypadku systemu asynchronicznego zadanie jest znacznie trudniejsze. Należy analizować równie wnikliwie każde położenie okna czasowego na sygnale EEG (przesuwane z dużą precyzją), aby jak najszybciej podjąć decyzję - po wykryciu zamiaru użytkownika. Opisywane w pracy metody ekstrakcji cech dotyczą, dla uproszczenia, jednosekundowego okna z pojedynczego kanału.

Nie należy mylić etapu ekstrakcji cech z ich późniejszą selekcją. Selekcja cech zawiera zupełnie inne podejście i operuje na uprzednio wygenerowanym zbiorze cech. Niektórzy badacze, również metody rzutowania wielowymiarowego, np. PCA, LDA, zaliczają do etapu ekstrakcji. Faktycznie techniki te dają nowe cechy, jednakże są one pewną kombinacją liniową cech wejściowych, uprzednio pozyskanych. Reasumując, istnieją techniki umożliwiające poprawienie efektywności oraz ograniczenie liczby już wyekstrahowanych cech, które adekwatnie do działania, można określać mianem selekcji. Selekcja cech stanowi przedmiot następnego rozdziału rozprawy.

## 6.1 Wariancja

Teoria dotycząca interfejsów mózg-komputer, mówi o zmianie aktywności (energii) odpowiednich części mózgu podczas wykonywania pewnych zadań myślowych. Stąd wydaje się, że najprostszą cechą, do wykorzystania w tym przypadku, jest energia sygnału EEG mierzona w określonym paśmie częstotliwości. Najczęściej analizowanym i najbardziej odpowiednim, jest pasmo:  $8\text{Hz} \div 30\text{Hz}$ . Dlatego sygnał na etapie przetwarzania wstępnego

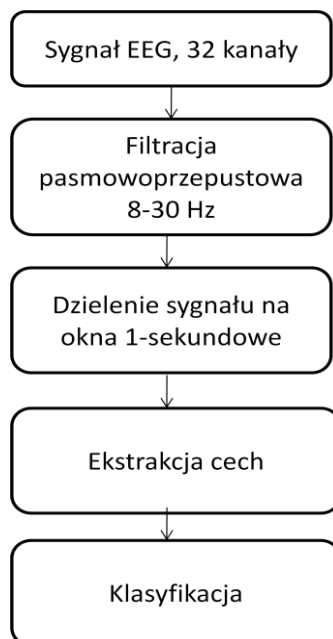
musi być poddany filtracji pasmowo-przepustowej. Najprostszą miarą, skojarzoną z energią sygnału jest wariancja. Wariancja to pewna miara rozrzutu od wartości średniej. Wariancję obliczyć można na kilka sposobów, jednym z nich jest:

$$Var(\mathbf{X}) = E[(\mathbf{X} - \mu)^2] \quad (6.1)$$

gdzie  $\mu$  to średnia sygnału, a operator  $E[x]$  oznacza wartość oczekiwaną  $x$ . Zdarza się, że energia sygnału EEG przyjmuje wartości znacznie większe od średniej (*outsiderzy*), co może zaburzyć rozkład cech. Wtedy warto zastosować operację logarytmowania. Cechą jest logarytm z wariancji sygnału:

$$C = \log(Var(\mathbf{X})) \quad (6.2)$$

Tak wygenerowane cechy są domyślnie stosowane w metodzie CSP omówionej dokładnie w rozdziale dotyczącym przetwarzania wstępnego. Na rys. 6.2 przedstawiono schemat przetwarzania sygnału EEG dla zaproponowanego interfejsu BCI. Ekstrakcja cech w tym wypadku oznacza obliczenie wariancji.




Rys. 6.2. Schemat przetwarzania sygnału EEG w zaproponowanym systemie BCI

Podczas eksperymentów autor zauważył, że inne operacje matematyczne zastosowane na wariancji dają jeszcze lepsze wyniki klasyfikacji. Do takich operacji należy pierwiastkowanie, które również zmniejsza wartości liczbowe „*outsiderów*” i jednocześnie powoduje, że są to wartości zawsze dodatnie (6.3):

$$C = \sqrt{Var(\mathbf{X})} \quad (6.3)$$

W przypadku wariancji, dla wybranego okna sygnału EEG, z wielu próbek sygnału, otrzymuje się tylko jedną wartość  $C$ . Dla większej liczby (na przykład 32) elektrod możliwa jest wizualizacja średnich rozkładów cech dla poszczególnych zadań myślowych. Takie przykładowe rozkłady, dla trzech typowych klas K2, K3, K7 przedstawiono na rys. 6.3.



Rys. 6.3. Rozrysowane na głowie średnie cechy  $\sqrt{\text{var}(X)}$  dla trzech typowych zadań myślowych

Można zaobserwować, że rozkłady cech są różne dla różnych zadań. Dokładna analiza takich rozkładów oraz ocena, które elektrody najlepiej różnicują dwie klasy zostanie przedstawiona w dalszej części pracy.


## 6.2 Widmo sygnału

Z badań dotyczących interfejsu mózg-komputer, raportowanych w pracach [146,114,39] wynika, że rozróżnienie zadań myślowych może odbywać się w sposób selektywny, w wybranych pasmach częstotliwości. W celu wykrycia, które częstotliwości mają największe znaczenie autor użył dyskretnej transformacji Fouriera (DFT) do ekstrakcji cech. DFT przekształca skończony zbiór próbek sygnału ( $x_0, x_1, x_2, x_{N-1}$ ) w ciąg prążków widma ( $X_0, X_1, X_2, X_{N-1}$ ) [30]:

$$X_k = \sum_{n=0}^{N-1} x_n w_N^{-kn} \quad (6.4)$$

Gdzie:  $0 \leq k \leq N-1$ ,  $w_n = e^{j\frac{2\pi}{N}}$ ,  $j$  jednostka urojona,  $k$ - numer prążka widma,  $n$  - numer próbki sygnału,  $x_n$  - wartość amplitudy próbki sygnału,  $N$  - liczba próbek. Dla sygnałów rzeczywistych, ze względu na symetrię widma, wystarczy uwzględnić tylko połowę prążków  $N/2$ . Wiadomo, że użyteczne pasmo sygnału EEG, zawiera się w granicach od 0,5Hz do 40Hz. Można zatem jako cechy wybrać wartości bezwzględne (moduł) prążków widma z tego zakresu. W ten sposób z każdego okna sygnału EEG otrzymać można  $N/2$  cech (rys. 6.4).






Rys. 6.4. Generowanie cech dla pojedynczego kanału z zastosowaniem FFT

Zakładając, że częstotliwość próbkowania wynosi  $f_s=512$  Hz (przyjęty standard), przeprowadzając analizę z zastosowaniem 512-punktowej transformacji Fouriera otrzymać można 256 prążków widma (z rozdzielczością 1Hz). Z tych 256 prążków wystarczy wybrać tylko te, które przypisane są do częstotliwości od 1Hz do 40Hz. Tym sposobem, dla pojedynczego okna czasowego (każdego kanału) otrzymuje się 40 cech. Dla 32-elektrodowego systemu daje to: 40 prążków  $\times$  32 elektrod=1280 cech. Zwykle w przypadku analizy widmowej stosuje się okna czasowe o wymyślnych kształtach, aby zminimalizować skutki analizy asynchronicznej. Jednak podczas przeprowadzonych eksperymentów okazało się, że stosowanie okien czasowych (*Blackmana*, *Hamminga*, *Hanna*, *Kaisera*), związane z modyfikacją amplitud sygnału, pogarsza jakość klasyfikacji. Na rys. 6.5 zobrazowano, uśrednione dla wielu okien, widma sygnału EEG, dla klas K2 K3 i K7.

Wygenerowane w ten sposób cechy dobrze opisują sygnał w dziedzinie częstotliwości, ale jest ich bardzo dużo. Natomiast, podejście zaproponowane przez autora pozwala na znalezienie dokładnych częstotliwości (cech), które najbardziej różnicują poszczególne klasy. Do tej pory stosowano częstotliwości w pewnych szerokich pasmach.



Rys. 6.5. Uśrednione dla wielu okien, widma sygnału EEG dla klas K2 K3 i K7 pochodzące od dwu wybranych elektrod (prążki od 1Hz do 40Hz)

Cechy otrzymane za pomocą dyskretnej transformacji Fouriera obrazują wartość amplitudy sygnału dla poszczególnych składowych częstotliwościowych. Jednak okazuje się, że właściwości sygnału EEG wygodniej opisać jest w poszczególnych podpasmach użytecznego pasma tego sygnału [32,16]. Jedną z metod pozwalającą na obliczenie energii sygnału w pewnym paśmie częstotliwości jest widmowa gęstość mocy.

Definicję widma gęstości mocy sygnału można przedstawić wzorem [16]:

$$S_{xx}(f) = \sum_{m=-\infty}^{\infty} R_{xx}(\tau) e^{-j2\pi f \tau / f_s} \quad (6.5)$$

gdzie  $R_{xx}(\tau)$  - funkcja autokorelacji,  $f_s$  - częstotliwość próbkowania. Widmową gęstość mocy można policzyć na wiele sposobów. Jednym z najbardziej praktycznych jest wykorzystanie do tego celu transformacji Fouriera. Zgodnie z tym podejściem estymacja widma gęstości mocy odbywa się na podstawie wzoru:

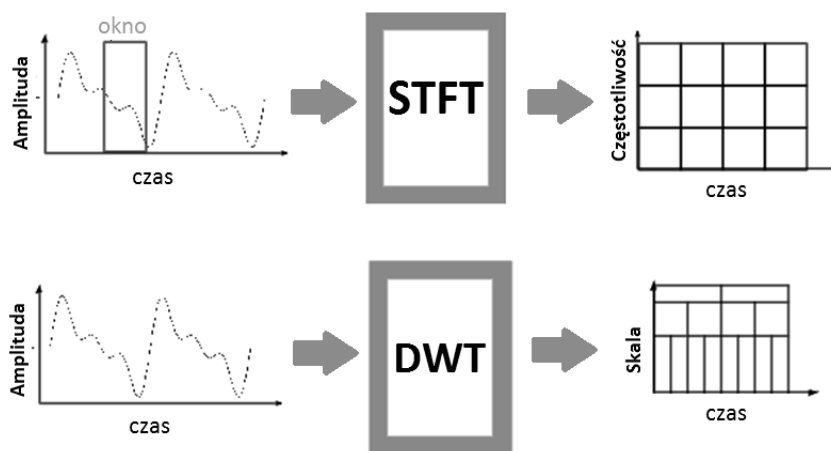
$$S_{xx}(f) = \frac{|X(f)|^2}{N} \quad (6.6)$$

gdzie  $X(f)$  jest transformacją Fouriera, a  $N$  oznacza rozmiar transformaty. Aby obliczyć energię sygnału w wybranym paśmie należy zsumować wartości amplitud odpowiednich, interesujących nas prążków widma podniesionych do kwadratu. Dzięki takiemu podejściu możliwe jest wyselekcjonowanie pewnych, znaczących z punktu widzenia efektywności

klasyfikacji, prążków, a tym samym ograniczenie liczby cech drogą ich selekcji. Podczas swoich badań autor, bazując na teorii, w sposób selektywny dobierał różne podpasma częstotliwościowe jako źródła cech:  $8\text{Hz} \div 12\text{Hz}$  i  $8\text{Hz} \div 30\text{Hz}$ , oraz  $8\text{Hz} \div 12\text{Hz}$  i  $18\text{Hz} \div 25\text{Hz}$ . Dobór podpasm odbywał się w obszarze sygnału EEG przepuszczonego przez filtr pasmowo-przepustowy:  $8\text{Hz} \div 30\text{Hz}$ . W charakterze cech wykorzystywano energię sygnału EEG zawartą w poszczególnych podpasmach częstotliwości.

### 6.3 Statystyki wyższych rzędów detali transformacji falkowej

Tradycyjna transformacja Fouriera podczas przejścia z dziedzin czasu do dziedzin częstotliwości powoduje utratę informacji o czasie (nie można powiedzieć, w których chwilach czasu występowały poszczególne składowe częstotliwościowe). Transformacja falkowa pozwala na przeniesienie sygnału z dziedziny czasu do dziedziny czas-skala. Przy czym skala ma swoje odniesienie do częstotliwości. Dzięki temu możliwa jest analiza sygnału jednocześnie w dziedzinie czasu i częstotliwości (ściśle skali). Dlatego falki nadają się doskonale do analizy sygnałów niestacjonarnych. Ponadto transformacja falkowa ma nieograniczony zbiór funkcji bazowych, zwanych falkami, za pomocą których w sposób bardziej skuteczny można aproksymować sygnały o różnych kształtach. Dużą zaletą transformacji falkowej, w porównaniu z krótkoczasową transformacją Fouriera (STFT), jest podział płaszczyzny czas/częstotliwość na fragmenty z użyciem okien czasowo-częstotliwościowych. Chodzi o modyfikację rozdzielczości analizy w zależności od zakresu częstotliwościowego. Różnice można zaobserwować na rysunku 6.6.



Rys. 6.6. Porównanie krótkoczasowej transformacji Fouriera (STFT) z transformacją falkową (DWT)

Sygnał  $x(t)$  może zostać przybliżony za pomocą superpozycji składowych, tak zwanych falek. Reprezentacja falkowa jest funkcją dwóch zmiennych: skali  $m$  oraz przesunięcia  $n$  funkcji  $\psi(t)$  zwanej falką matką [134,3]:

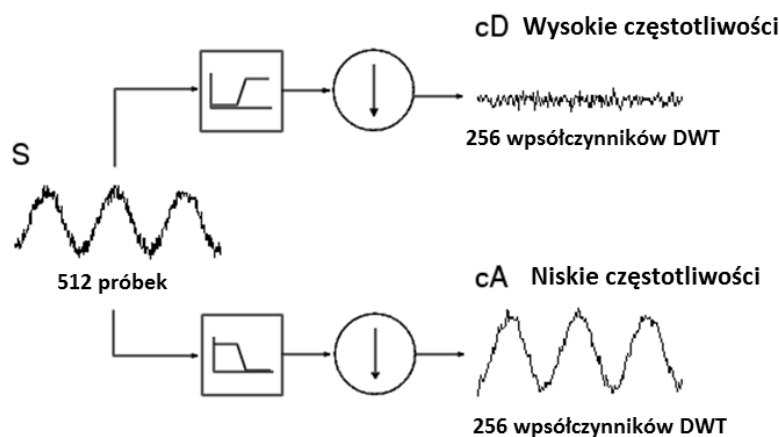
$$f(t) = \sum_m \sum_n d_{m,n} \psi(2^{-m}t - n) \quad (6.7)$$

Współczynniki  $d_{m,n}$  oblicza się podobnie jak w przypadku transformacji Fouriera:

$$d_{m,n} = 2^n \int f(t) \psi(2^{-m}t - n) dt \quad (6.8)$$


Z falki matki  $\psi$ , za pomocą skalowania, tworzone są nowe (najczęściej ortogonalne) funkcje bazowe. Funkcje te charakteryzują się dobrą lokalizacją w czasie oraz ograniczonym pasmem w dziedzinie częstotliwości. Istotną cechą reprezentacji falkowej jest to, że zawiera w sobie informacje o sygnale na różnych poziomach szczegółowości. Odpowiedni dobór falki-matki umożliwia precyzyjne wydobycie właściwego sygnału spośród wielu składowych, na odpowiednim poziomie dekompozycji.

Praktyczną implementację dyskretnej transformacji Falkowej (*Discrete Wavelet Transform* - DWT) zaproponował Mallat [81] w 1988 roku. Algorytm ten polega na dekompozycji sygnału na składowe przy użyciu par filtrów cyfrowych. Sygnal za pomocą odpowiednich filtrów może zostać rozłożony na detale (szczegóły) oraz aproksymacje (przybliżenia). Detale otrzymuje się dzięki zastosowaniu filtru górnoprzepustowego, zaś aproksymacje po zastosowaniu filtru dolnoprzepustowego (rys 6.7). Zarówno filtr górnoprzepustowy jak i filtr dolnoprzepustowy są powiązane z kształtem falki. Na wyjściu filtrów przeprowadzana jest decymacja sygnału. W ten sposób otrzymuje się redukcję próbek o połowę.




Rys. 6.7. Pierwszy stopień dekompozycji Mallata

Stosując wielokrotnie proces dekompozycji do kolejnych aproksymacji można otrzymać tak zwaną piramidę Mallata (rys. 6.8).



Rys. 6.8. Piramida Mallata

W wyniku zastosowania algorytmu wielorozdzielczej dekompozycji Mallata dla każdego okna czasowego (fragmentu) sygnału EEG, otrzymuje się zbiór detali (jeden na każdym poziomie dekompozycji) oraz jedną, ostatnią aproksymację. Przykład rozkładu 1-sekundowego przebiegu sygnału EEG (okno czasowe) na składowe falkowe, z wykorzystaniem 7 poziomów dekompozycji, zamieszczono na rys. 6.9.



Rys. 6.9. Przykład wielorozdzielczej analizy sygnału EEG (detale  $d_1 \div d_7$  i aproksymacja  $a_7$ )

Każdy detal dekompozycji Mallata może być interpretowany jako sygnał przefiltrowany odpowiednim filtrem pasmowo-przepustowym. W odniesieniu do sygnału EEG autor zaproponował użycie siedmiu detali dekompozycji. Przy czym, liczba detali jest uwarunkowana liczbą próbek w sygnale wejściowym (decymacja).

Następnym etapem zaproponowanej metody ekstrakcji cech, było wyznaczenie statystyk wyższych rzędów (*Higher Order Statistics* - HOS) dla każdego z wyznaczonych detali. Oprócz wariancji do statystyk tych zaliczyć można skośność i kurtozę. Wariancję interpretuje się najczęściej jako miarę rozrzutu od średniej. Współczynnik skośności to pewna miara asymetrii rozkładu gęstości prawdopodobieństwa. Skośność dla wektora  $\mathbf{x}$  wyznaczyć można według wzoru:

$$Sk = \frac{E(\mathbf{x} - \mu)^2}{\sigma^3} \quad (6.9)$$

gdzie  $E(\mathbf{x})$  oznacza wartość oczekiwaną  $\mathbf{x}$ , a  $\sigma$  oznacza odchylenie standardowe wektora  $\mathbf{x}$ . Współczynnik skośności przyjmuje wartość zero dla rozkładu symetrycznego. Wartości ujemne skośność przyjmuje dla rozkładów o lewostronnej asymetrii (wydłużone lewe ramię rozkładu), a wartości dodatnie dla rozkładów o prawostronnej asymetrii (wydłużone prawe ramię rozkładu).

Inną statystyką pomocną również w ekstrakcji cech jest kurtoza, opisana już w rozdziale dotyczącym przetwarzania wstępnego sygnałów EEG (wzór 5.17). Jest to pewna miara oddalenia kształtu rozkładu gęstości prawdopodobieństwa od gaussowskiego.

W kontekście przyjętych założeń, dla jednosekundowego okna sygnału EEG, z pojedynczej elektrody, otrzymać można 7 detali. Dla każdego z detali wyliczane są 3 statystyki wariancja, skośność i kurtoza. W ten sposób otrzymać można  $3 \text{ HOS} \times 7 \text{ detali} = 21$  cech. W przypadku użycia 32 elektrod otrzymuje się  $32 \text{ elektrody} \times 21 \text{ cech} = 672$  cechy.

Jak już wspomniano, ważnym elementem, przy analizie sygnału metodą falkową jest dobór odpowiedniego kształtu falki matki. Podczas eksperymentów autor przebadał wpływ różnego rodzaju falek na proces klasyfikacji.

#### 6.4 Współczynniki modelu autoregresyjnego (AR)

Model autoregresyjny, w zastosowaniu do interfejsów mózg-komputer, został przedstawiony w pracach [1,106,155]. Opisuje on procesy dyskretne, w których wartość sygnału w danej chwili jest kombinacją liniową  $p$  wartości próbek poprzednich:

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t \quad (6.10)$$

gdzie  $\varphi_1, \dots, \varphi_p$ , to współczynniki (parametry) modelu,  $c$  jest stałą, zaś  $\varepsilon_t$  oznacza szum biały. Przed przystąpieniem do tworzenia modelu należy wybrać odpowiedni rząd. Dobór rzędu modelu nie jest sprawą prostą [88]. Zaproponowano również wiele metod estymacji współczynników modelu [90,53]. Idea modelowania parametrów AR przedstawiona jest na rysunku 6.10.



Rys. 6.10. Idea modelowania parametrów AR

W modelu AR przyjmuje się, że na wejście podawany jest szum, natomiast na wyjściu otrzymywany jest estymowany sygnał EEG. Współczynniki modelu AR mogą być skojarzone ze współczynnikami odpowiedniego filtra FIR. Celem badań, w kontekście rozprawy, było użycie współczynników modelu AR w charakterze cech. Autor przebadiał kilka modeli różnych rzędów i określił wpływ rzędu modelu na proces klasyfikacji. W przypadku, gdy rząd modelu wynosił  $p$ , z każdego pojedynczego kanału otrzymano  $p$  cech. Typowo  $p=10$ , a zatem dla jednosekundowego okna globalna liczba cech wynosi: 32 kanały  $\times$  10 cech=320 cech.

## 6.5 Oprogramowanie autorskie "Feature\_Toolbox"

Prowadzenie badań w ramach rozprawy wymagało żmudnego i pracochłonnego, powtarzanego wielokrotnie, wydobywania różnego typu cech z sygnału EEG. Celem uproszczenia działań w tym zakresie, autor stworzył program, dzięki któremu proces generowania cech stał się prosty i intuicyjny [66]. Program umożliwia generowanie cech z użyciem takich metod jak: FFT, DWT/HOS, AR. Parametry algorytmów mogą być dowolnie modyfikowane. Dodatkową jego zaletą jest możliwość wykorzystania do ekstrakcji cech z innego typu sygnałów (wielokanałowych), nie tylko z sygnału EEG. Obraz panelu czołowego do obsługi programu zamieszczono na rys. 6.11.



Rys. 6.11. Panel czołowy programu FE\_Toolbox zaimplementowanego przez autora

Podstawowymi parametrami, które należy zdefiniować w celu wygenerowania cech są:

- nazwa macierzy sygnału EEG, z której mają zostać wygenerowane cechy,
- szerokość okna czasowego, z którego ma nastąpić generowanie cech,
- wartość częstotliwości próbkowania sygnału,
- stopień nakładania okien czasowych,
- nazwa wektora wyjściowego, który ma zawierać cechy sygnału EEG.

W metodzie HOS na współczynnikach DWT użytkownik może dodatkowo zdefiniować:

- typ użytej falki,
- liczbę poziomów dekompozycji (detali),
- rodzaj parametru: skośność, wariancja czy kurtoza.

Model AR wymaga zdefiniowaniu rzędu. Dla cech typu FFT użytkownik definiuje typ wykorzystanego okna czasowego.

Niejednokrotnie, liczba wygenerowanych przez program cech jest bardzo duża, stąd aby ułatwić pracę użytkownikowi, generowana jest dodatkowa macierz, zawierająca dokładny opis wygenerowanego wektora cech. Macierz ta okazała się bardzo przydatna w kolejnych etapach pracy. W znaczący sposób ułatwiła określenie, które cechy najlepiej nadają się do dyskryminacji klas.



Należy zwrócić uwagę, że proces ekstrakcji cech nierzadko powoduje wygenerowanie dużej liczby cech, co może pociągać za sobą pewne utrudnienia w realizacji systemu. Z drugiej strony, większa liczba cech lepiej opisuje właściwości sygnału EEG. Z tym problemem wiążą się również parametry okna czasowego. Autor przebadiał wpływ szerokości okna czasowego i sposób nakładania okien na przebieg procesu generowania cech oraz późniejszej klasyfikacji.

Ważnym elementem praktycznego zastosowania proponowanych metod ekstrakcji cech jest możliwość ich implementacji w czasie rzeczywistym. Należy pamiętać, że etap analizy sygnału EEG, w sesji kalibracyjnej może odbywać się w trybie *off-line*, natomiast jego działanie praktyczne wymaga prowadzenia ekstrakcji cech w czasie rzeczywistym.

W tabeli 6.1 znajduje się podsumowanie dotyczące liczby cech dla różnych metod ekstrakcji.

Tabela 6.1 Rozmiary wektorów cech dla różnych metod ekstrakcji z 1-sek., 32 kanałowego zapisu EEG

Sposób generowania cech	Liczba cech z 32 kanałów
Wariancja (Energia)	32
FFT	1280
PSD	96
HOS/DWT	672
AR	512

---

## 7. SELEKCJA CECH

---


Etap ekstrakcji cech miał na celu wydobycie pewnych charakterystycznych cech z sygnału EEG. Wynikiem tego procesu były wektory cech. Liczba cech w zależności od użytej metody wynosiła od 32 do 1280. Zbyt duża liczba cech nie pozwalała na poprawne uczenie i sprawne działanie klasyfikatora. Dlatego istotnym problemem okazał się etap selekcji, a ściślej ograniczenia liczby cech. Istotą selekcji cech jest pozostawienie efektywnych cech, które wnoszą najwięcej informacji do procesu klasyfikacji. Oprócz tego autor podjął się zadania wskazania stowarzyszonych z nimi elektrod. Takie działania mają olbrzymią wartość praktyczną, umożliwiając bowiem ograniczenie liczby elektrod, a co za tym idzie redukcję czasu naklejenia elektrod i w ogóle ułatwiają późniejszą obsługę interfejsu. Innym ważnym efektem ograniczenia liczby elektrod jest zmniejszenie czasu przetwarzania, analizy i klasyfikacji sygnału. Z drugiej strony, taka redukcja liczby kanałów EEG powinna odbywać się jak najmniejszym kosztem jakości i efektywności klasyfikacji. Bardzo ważnym elementem, proponowanych przez autora, automatycznych metod selekcji cech, jest możliwość ich działania bez angażowania użytkownika. Zwykle, po wykonaniu sesji kalibracyjnej, wybór cech dokonywany jest przez użytkownika (system BCI2000<sup>7</sup>). Rozwiązanie problemu automatycznej selekcji cech znacznie uprości sposób obsługi interfejsu. Należy jeszcze raz zaznaczyć, że choć teoretycznie znane jest optymalne rozmieszczenie elektrod czy też usytuowanie najlepszych cech, to nie jest możliwe stworzenie uniwersalnego zestawu cech! Przykładowo, jak to już zaznaczono w poprzednich częściach rozprawy, zestawy „najlepszych” cech w dziedzinie widma mogą zmieniać się z dnia na dzień, a nawet z godziny na godzinę - dla tego samego użytkownika!

Istnieje wiele metod selekcji cech [133]. W najbardziej zaawansowanych rozwiązaniach, selekcja cech może być powiązana z elementami „wydobycia wiedzy” (*data-mining*), które umożliwiają wskazanie najlepszych cech, czy wręcz odkrycie nowych, które wniosą najwięcej do procesu klasyfikacji [156]. Możliwe jest również wskazanie najlepszych cech z użyciem złożonych algorytmów ewolucyjnych, np. wykorzystując algorytmy genetyczne, poprzez wielokrotne uruchomienie i zliczenie najczęściej wypadających cech przy każdym kolejnym uruchomieniu. Najprostsze w zastosowaniach są metody rankingowe lub tak zwane


---

<sup>7</sup> Uniwersalny system przeznaczony do badania interfejsów mózg-komputer

filtry [37,145,89]. W metodach tych nie uwzględnia się wyników klasyfikacji, a jedynie wykorzystuje wiedzę o przynależności do klasy. Zwykle metody te wypadają gorzej, niż metody selekcji oparte na wiedzy o trafności klasyfikacji (*wrapper* lub *embedded*). Jednakże bardzo ważną zaletą metod rankingowych jest możliwość uszeregowania cech od „najlepszych” do „najgorszych”. Ta możliwość istnieje również w przypadku metod działających z wykorzystaniem klasyfikacji. Do metod takich zaliczyć należy sekwencyjne przeszukiwanie w przód (*sequential forward selection* - *SFS*). Porównanie metod rankingowych i metod typu *wrapper* zawietrajają rysunki 7.1,7.2.



Rys. 7.1. Model selekcji cech za pomocą filtrów (ranking) - bez wiedzy o klasyfikacji



Rys. 7.2. Model selekcji cech typu *wrapper* - z wykorzystaniem wiedzy o jakości klasyfikacji

Zupełnie innym sposobem redukcji cech jest zastosowanie rzutowania zmiennych na nowe współrzędne. Najczęściej proces ten kojarzony jest z analizą składowych głównych (*Principal Component Analysis* - *PCA*) oraz liniową analizą dyskryminacyjną (*Linear Discriminant Analysis* - *LDA*) [37]. Nowe cechy są, w tych przypadkach, liniową kombinacją cech wydobytych w procesie ekstrakcji. Choć takie podejście może polepszyć jakość nowych cech, to niesie ono pewne ograniczenie. Nie podaje w sposób bezpośredni, tak jak bywa w przypadku metod rankingowych wiedzy o tym, które cechy lepiej dyskryminują dane. Nie jest możliwe bezpośrednie uszeregowanie cech, stwierdzenie które cechy są najlepsze.

Poniżej zostaną opisane metody selekcji cech oraz elektrod, wykorzystywane przez autora podczas eksperymentów. Metody te są uniwersalne i mogłyby być stosowane praktycznie dla każdego rodzaju cech wydobytych na etapie ekstrakcji. Dodatkowo, w przypadku interfejsu mózg-komputer, należy uwzględnić większą liczbę klas, co komplikuje znacznie problem selekcji cech. Nie wystarczy wskazać te cechy, które różnicują dwie klasy, ale te które pozwolą na rozróżnienie większej ich liczby.


## 7.1 Metoda wizualnego wyboru elektrod

Jednym ze sposobów umożliwiających określenie, które elektrody (oraz stowarzyszone z nimi cechy) wnoszą do procesu klasyfikacji najwięcej informacji jest wyznaczenie różnic uśrednionych cech i ich wizualizacja na głowie pacjenta. Wizualny wybór położenia elektrod ma wiele zalet. Po pierwsze jest bardzo intuicyjny, a po drugie selekcja cech/elektrod może być szybko zweryfikowana przez specjalistę neurologa, znającego podstawy funkcjonowania mózgu.

Założmy, że do rozróżnienia są trzy klasy nazwane odpowiednio K2, K3 i K7, a cechy stanowi energia sygnału EEG (opisana w poprzednich rozdziałach). Do wyznaczenia różnic uśrednionych cech służą równania (7.1):

$$\mathbf{R}_{23} = |\boldsymbol{\mu}_2 - \boldsymbol{\mu}_3|, \mathbf{R}_{27} = |\boldsymbol{\mu}_2 - \boldsymbol{\mu}_7|, \mathbf{R}_{37} = |\boldsymbol{\mu}_3 - \boldsymbol{\mu}_7| \quad (7.1)$$

W wyrażeniu (7.1) symbole  $\boldsymbol{\mu}_2$ ,  $\boldsymbol{\mu}_3$ ,  $\boldsymbol{\mu}_7$  oznaczają wartości średnie cech wszystkich elektrod odpowiednio dla klas: K2, K3 i K7. Wynik rozrysowania rozkładu wartości jednego ze współczynników ( $\mathbf{R}_{27}$ ) zobaczyć można na rysunku 7.3.




Rys. 7.3. Rozkład różnic średnich wartości cech dla klas K2 i K7

Do realizacji tego samego celu, w następnym etapie, można wykorzystać współczynnik K-Fishera [91,92]. Współczynnik ten oprócz różnicy w średnich uwzględnia też odchylenia standardowe. W ten sposób wyznaczono współczynniki (7.2):

$$\mathbf{F}_{23} = \frac{\mathbf{R}_{23}}{\sigma_2 + \sigma_3}, \mathbf{F}_{27} = \frac{\mathbf{R}_{27}}{\sigma_2 + \sigma_7}, \mathbf{F}_{37} = \frac{\mathbf{R}_{37}}{\sigma_3 + \sigma_7} \quad (7.2)$$

gdzie  $\sigma_2$ ,  $\sigma_3$ ,  $\sigma_7$  oznaczają odchylenia standardowe, liczone odpowiednio dla zbiorów cech klas: K2, K3, K7. W ten sposób zobrazowano współczynniki przyporządkowane do każdej z elektrod (rys. 7.4).




Rys. 7.4. Rozkład wartości współczynnika Fishera dla cech z klas K3 i K7

Inną miarą wskazującą na ile cechy różnią się od siebie może być stosunek ich wartości średnich. Stąd w trzecim podejściu wyznaczono współczynniki:

$$S_{23} = \frac{\mu_2}{\mu_3}, S_{27} = \frac{\mu_2}{\mu_7}, S_{37} = \frac{\mu_3}{\mu_7} \quad (7.3)$$

Po ich wizualizacji otrzymano obraz zamieszczony na rysunku 7.5.



Rys. 7.5. Rozkład stosunku średnich wartości cech klas K2 i K7

Otrzymane wyniki umożliwiają wskazanie właściwych miejsc do umieszczenia elektrod na głowie pacjenta poprzez wizualną ocenę rozkładów. Choć w przykładzie wykorzystano dane dla cechy jaką była energia sygnału, to sposób ten jest bardzo uniwersalny i pozwala na wykreślenie zależności dla dowolnych cech. Należy zaznaczyć, że aby skutecznie zobrazować rozkład potencjału na głowie wskazane jest użycie większej liczby elektrod (z nadmiarem). Dla skutecznego rozróżnienia trzech klas trzeba porównać obrazy rozkładów różnic pewnych współczynników pomiędzy parami klas: K2-K3, K2-K7, K3-K7.

Zobrazowanie rozkładów potencjałów pokazuje, że możliwe jest ograniczenie liczby elektrod, co pozostaje w zgodzie z wiedzą neuropsychologiczną. Zgodnie z nią największe potencjały *mu* i *beta* pojawiają się na elektrodach C3 oraz C4. Opracowane w wyniku badań algorytmy do wizualizacji przydatności cech, w przypadku wyobrażania sobie ruchu, są uniwersalne i mogą posłużyć do wyznaczenia miejsc na głowie podczas realizacji innych, dowolnych zadań myślowych.

## 7.2 Metody rankingowe

### 7.2.1 T-statystyki

Podstawą omawianej metody jest uszeregowanie wybranych cech zgodnie z t-statystyką Welcha. Najlepsze cechy to takie, które uzyskują największą wartość *t* - testu Welcha [45]:

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{\sigma_1^2}{N_1} + \frac{\sigma_2^2}{N_2}}} \quad (7.4)$$

gdzie  $\bar{x}_1$  to średnia w 1-szej próbie,  $\sigma_1^2$  wariancja w 1-szej próbie a  $N_1$  to licznosc 1-szej próby. Podobnie dla drugiej.

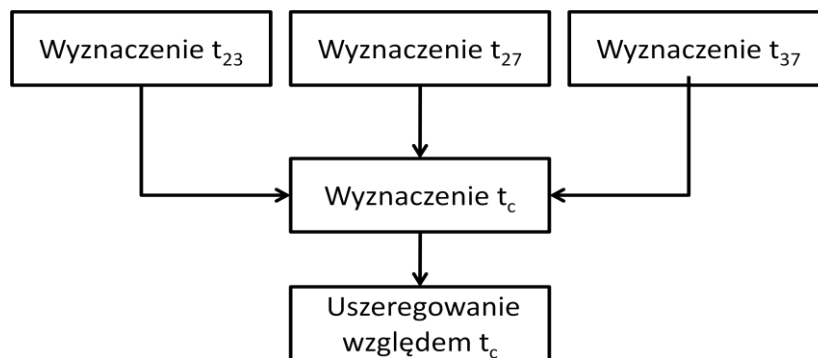
Współczynnik *t* można interpretować jako pewną wartość, która mówi o stopniu zróżnicowania pomiędzy cechami dla dwóch rozpatrywanych klas. Autor używał wartości bezwzględnej parametru *t*. Im większa różnica wartości średnich w liczniku wyrażenia (7.4) i mniejsze wariancje zmiennych w mianowniku, tym większy współczynnik *t*, a zatem większa szansa na zróżnicowanie klas za pomocą tych zmiennych. Zmienne można uszeregować zgodnie ze wzrostem parametru *t* i wybrać te z największymi wartościami. Osobnym problemem wciąż pozostaje liczba cech, dająca najlepszy rezultat klasyfikacji.

Jako przykład niech posłuży eksperyment z wykorzystaniem cech w postaci 40 prążków widma (FFT) sygnału EEG z zakresu: 1Hz÷40Hz. Zbiór cech poddany został procesowi selekcji z użyciem t-statystyk. Miarą jakości doboru cech był błąd nauki klasyfikatora. Dodatkowo autor przeprowadził badanie wpływu liczby cech na jakość klasyfikacji.

W wyniku procesu ekstrakcji cech otrzymano zbiory danych reprezentujące trzy klasy K2, K3 oraz K7. Problem klasyfikacji dotyczy więc przyporządkowania 1-sekundowego zapisu sygnału EEG do jednej z trzech klas. Dzięki t-statystykom (7.4) możliwe jest wyznaczenie rankingu cech pomiędzy parami klas: K2-K3, K2-K7, oraz K2-K3. Autor zaproponował jeden wspólny współczynnik  $t_c$  opisujący t-statystyki pomiędzy wszystkimi możliwymi parami klas (7.5):

$$t_c = |t_{23}| + |t_{27}| + |t_{37}| \quad (7.5)$$


Współczynnik ten może być interpretowany jako łączna miara zróżnicowania pomiędzy klasami. Im większa wartość współczynnika  $t_c$  tym cechy powinny bardziej różnicować populację. W celu wyznaczenia współczynnika  $t_c$  dla każdej z 1280 cech wyznaczono współczynniki cząstkowe:  $t_{23}$ ,  $t_{27}$  oraz  $t_{37}$ , a następnie zsumowano ich wartości bezwzględne zgodnie ze wzorem (7.5). Następnym etapem było uszeregowanie cech pod względem wartości  $t_c$  - od największej do najmniejszej. Procedurę tworzenia globalnego parametru  $t_c$  zaprezentowano na rys. 7.6.




Rys. 7.6. Proces tworzenia współczynnika  $t_c$  oraz sposób wyboru najlepszych cech

Na kolejnym etapie selekcji wybierana była pewna liczba  $N$  najlepszych cech (z największą wartością  $t_c$ ). Ważnym elementem sprawdzenia efektywności metody selekcji cech jest określenie błędu klasyfikacji. Do wyznaczenia wartości tego błędu użyto 10-krotnego testu krzyżowego (*10-cross validation test*). Cały zbiór danych został podzielony na 10 podzbiorów. Klasyfikator trenowany był na pierwszych 9-ciu zbiorach, a testowany na ostatnim. Następnie proces trenowania obejmował podzbiory od 1-8 oraz 10, a test przeprowadzany był na 9. Cykl ten był powtarzany dla każdego spośród 10 podzbiorów. Test był przeprowadzony dla dwóch różnych klasyfikatorów: liniowa analiza dyskryminacyjna (LDA) i kwadraturowa analiza dyskryminacyjna (QDA). W przekonaniu autora, bardziej miarodajnym klasyfikatorem jest LDA separująca klasy liniowo. Taki klasyfikator cechuje się lepszymi właściwościami generalizacyjnymi (danych z nowej sesji).

Na efektywność trenowania klasyfikatora ma wpływ nie tylko jakość cech, ale również ich liczba. Dlatego autor zmieniał liczbę użytych cech, uprzednio uszeregowanych. Wyniki eksperymentu zaprezentowane zostały na dwu kolejnych rysunkach 7.7 i 7.8.



Rys. 7.7. Błąd klasyfikacji dla klasyfikatora LDA (t-statystyki i losowy wybór cech)



Rys. 7.8. Błąd klasyfikacji dla klasyfikatora QDA (t-statystyki i losowy wybór cech)




Zaletą zaproponowanej, rankingowej metody selekcji cech, w porównaniu z innymi metodami jak np. algorytmy genetyczne, w zastosowaniu do interfejsów mózg-komputer, jest niewątpliwie szybkość szeregowania cech. Metoda pozwala na wyznaczenie najlepszych cech dzięki rankingowi otrzymanemu poprzez zsumowanie parametrów  $t$  pomiędzy poszczególnymi cechami. Autor zaproponował takie podejście, ponieważ podczas badań okazało się wielokrotnie, że cechy uszeregowane względem  $t_{12}$ ,  $t_{13}$  oraz  $t_{23}$  są takie same. Na jakość klasyfikacji ma niewątpliwie wpływ liczba cech. Im większa liczba cech tym lepsze objaśnienie modelu (zjawiska). Większa liczba cech daje mniejszy błąd klasyfikacji szczególnie w przypadku testu krzyżowego. Autor przebadał wpływ liczby cech dla losowo wybranych cech oraz dla cech po selekcji t-statystykami, na trafność klasyfikacji. Badania wykonano dla klasyfikatorów LDA oraz QDA. Rysunki 7.7 oraz 7.8 obrazują błąd klasyfikacji cech dla redukcji z zastosowaniem t-statystyk oraz dla losowo wybranej liczby cech. Dla klasyfikatora LDA selekcja zaproponowaną metodą pozwoliła na ograniczenie błędu klasyfikacji (dla 50 cech uzyskano błędy odpowiednio: 31% oraz 45% patrz rys. 7.7). Zatem poprawa wynosi około 14%. Dla klasyfikatora QDA selekcja zaproponowaną metodą pozwoliła na ograniczenie błędu klasyfikacji (dla 150 cech uzyskano błędy odpowiednio: 18% oraz 33% patrz rys. 7.8). Zatem poprawa wynosi około 15%. Zauważyć można, że wraz ze wzrostem liczby wybranych cech, maleje znaczenie zaproponowanej metody selekcji cech.

### 7.2.2 Współczynnik K-Fischera


Ważną miarą szeregowania wielkości w metodach rankingowych jest wspomniany już współczynnik K-Fishera [126,139]. Im większa wartość współczynnika, tym klasy są łatwiej separowalne. Wpływ na wartość współczynnika K-Fischera ma różnica wartości średnich cech (proporcjonalność) oraz suma odchyłeń standardowych danej cechy dla poszczególnych klas (odwrotna proporcjonalność). Analogicznie jak w przypadku t-statystyk wyznaczono wartość współczynnika:

$$K_c = K_{23} + K_{27} + K_{37} \quad (7.6)$$

Podczas testów okazało się, że uszeregowanie cech z pomocą t-statystyk oraz za pomocą współczynnika K-Fishera daje bardzo zbliżone rezultaty. Wyniki testu dla K-Fishera zaprezentowano na rysunkach 7.9 oraz 7.10.




Rys. 7.9. Błąd klasyfikacji dla klasyfikatora LDA (wsp. K-Fishera oraz losowo wybrane cechy)




Rys. 7.10. Błąd klasyfikacji dla klasyfikatora QDA (wsp. K-Fishera oraz losowo wybrane cechy)

Ważnym etapem przeprowadzonych badań, była próba wskazania które (konkretnie) cechy niosą najwięcej informacji dla procesu klasyfikacji. W tym celu wyznaczono sumę współczynników  $K_c$  dla każdej cechy (prążka widma) (rys 7.11).




Rys. 7.11. Suma współczynników K dla poszczególnych cech (prążków widma).

Otrzymane rezultaty jednoznacznie pokazują, że najlepiej do rozróżnienia klas nadają się cechy (składowe widma) z zakresu 9Hz÷11Hz oraz 20Hz÷23Hz co jest zgodne z dotychczasową teorią. Możliwe jest zatem wykreślenie rozkładu wartości współczynników K-Fishera dla prążka o częstotliwości 10 Hz i każdej pary klas (rys 7.12).



Rys. 7.12. Rozkład wartości współczynnika K-Fishera dla 10 Hz

Aby uogólnić wiedzę na temat tego, które elektrody wnoszą najwięcej do procesu klasyfikacji autor zaproponował wykreślenie rozkładu sumy współczynników K-Fishera ( $K_c$ ) dla prążka 10Hz. Zestaw 32 elektrod rozmieszczono zgodnie ze standardem 10-20. Największe wartości współczynnika  $K_c$  występują dla elektrod C3, C4 oraz Cz (rys. 7.13).

Rys. 7.13. Rozkład wartości współczynnika  $K_c$  dla 10 Hz

Okazuje się, że współczynniki K-Fishera oraz t-statystyki dają bardzo podobne rezultaty. Bardzo często (ale nie zawsze), wyniki określenia najlepszych cech dla t-statystyk oraz wsp. K-fishera były takie same. Choć w tych metodach selekcji nie wykorzystuje się wiedzy na temat jakości klasyfikacji (w sposób zwrotny), możliwe jest ograniczenie wartości błędu klasyfikacji i wyselekcjonowanie najlepszych cech (w tym wypadku podpasm częstotliwości) oraz położenia elektrod.

### 7.2.3 Korelacja wzajemna

Zaproponowana metoda bazuje na uszeregowaniu cech zgodnie z pewną miarą mówiącą o tym w jakim stopniu dana cecha jest liniowo skorelowana z inną. Metoda ta jest efektem przyjęcia założenia, że im mniej skorelowane są cechy tym więcej wnoszą do opisu modelu.

Wygodną miarą korelacji liniowej dwóch cech jest estymator zwany współczynnikiem Pearsona (7.7):

$$r_{XY} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} \quad (7.7)$$

gdzie  $\text{cov}(X, Y)$  oznacza kowariancję zmiennych  $X$  i  $Y$ , a  $\sigma_X$  oraz  $\sigma_Y$  ich odchylenia standardowe. Wartość współczynnika korelacji  $r_{XY}$  mieści się w przedziale  $[-1, 1]$ . Im większa wartość bezwzględna współczynnika korelacji tym silniejsza zależność liniowa pomiędzy

zmiennymi. Wartość współczynnika  $r_{XY}=1$  oznacza dokładnie dodatnią liniową zależność pomiędzy cechami,  $r_{XY}=0$  - brak liniowej zależności, zaś  $r_{XY}=-1$  dokładnie ujemną liniową zależność między cechami (jeśli wartość jednej zmiennej rośnie to drugiej maleje).

Wartości współczynników korelacji między cechami zebrane zostały, w sposób uporządkowany, w macierzy korelacji. Jest to macierz kwadratowa symetryczna z "1" na diagonalnej (rys. 7.14).

	$X_1$	$X_2$	...	$X_n$
$X_1$	1	$r_{12}$	...	$r_{n1}$
$X_2$	$r_{21}$	1	...	$r_{n2}$
...	...	...	...	...
$X_n$	$r_{n1}$	$r_{n2}$	...	1


Rys. 7.14. Przykład macierzy korelacji dla zmiennych  $X_1 \dots X_n$

Zsumowanie odpowiednich wierszy (lub kolumn) macierzy korelacji daje miarę globalną  $S$  mówiącą o tym w jakim stopniu dana cecha skorelowana jest z innymi (7.8):


$$S_i = r_{i1} + r_{i2} + \dots + r_{iK} \quad (7.8)$$

gdzie  $K$  oznacza liczbę cech, a  $i$  numer cechy, dla której wyznaczany jest współczynnik  $S$ . Im mniejsza wartość  $S$  tym cecha mniej skorelowana z innymi. Dzięki temu możliwe jest uszeregowanie cech od najmniej skorelowanych do najbardziej skorelowanych. Autor wykonał badania i ocenił jak metoda sprawdza się w zastosowaniu do selekcji cech. Dodatkowo porównano, jak liczba cech wpływa na błąd klasyfikacji dla losowo wybieranych cech. Standardowo w charakterze cech użyto prążków widma FFT 1Hz÷40Hz, dla 32 kanałów. W eksperymencie zastosowano dziesięciokrotny test krzyżowy. Wyniki klasyfikacji (LDA, QDA) zaprezentowano na rysunkach 7.15-7.16.

Otrzymane wyniki dowodzą, że nastąpiła redukcja błędu klasyfikacji, jednak są to wyniki gorsze niż w przypadku t-statystyki i współczynnika K-Fishera. Podczas badań autor dodatkowo sprawdził połączenie metody selekcji „ranking współczynnika korelacji” z metodą „t-statystyki”, ale nie dało to poprawy otrzymanych wyników.



Rys. 7.15. Błąd klasyfikacji dla klasyfikatora LDA dla zastosowanej metody S-korelacji oraz losowo wybranego zbioru cech



Rys. 7.16. Błąd klasyfikacji dla klasyfikatora QDA dla zastosowanej metody S-korelacji oraz losowo wybranego zbioru cech

### 7.3 Sekwencyjne przeszukiwanie w przód<sup>8</sup> (SFS)

Kolejną wykorzystaną do selekcji cech metodą było sekwencyjne przeszukiwanie w przód (*sequential forward selection* - SFS) [44,45,132]. W metodzie tej, przy doborze najlepszych cech wykorzystuje się wiedzę o ich przydatności w procesie klasyfikacji. Można ją zaliczyć do metod siłowych, sprawdzających, na bieżąco, jakość wybranych cech. Pierwszym krokiem zastosowanej metody jest wybór jednej cechy. Cechę wybiera się sprawdzając błąd klasyfikacji dla każdej z osobna. Cechę, która minimalizuje błąd klasyfikacji włącza się do poszukiwanego zbioru cech. W kolejnych etapach dodawane są kolejne cechy do uprzednio stworzonego zbioru.


Algorytm SFS można opisać w następujący sposób:

- Zaczynij od pustego zbioru cech  $Y$ ,
- Sprawdź wszystkie cechy po kolei i sprawdź ich błąd klasyfikacji,
- Wybierz cechę, która daje najmniejszy błąd klasyfikacji i dołącz do zbioru  $Y$ ,
- Wróć do punktu 2 dopóki zbiór  $Y$  nie zawiera  $N$  cech.

Wybór najlepszych cech może być kontynuowany, aż do uzyskania satysfakcjonujących wyników klasyfikacji lub do chwili skompletowania  $N$  cech. Dużą wadą zastosowanego algorytmu jest długi czas jego wykonywania oraz duża złożoność obliczeniowa (wybór cech, trenowanie i testowanie klasyfikatora). Celem wybrania 50 najlepszych cech, spośród wszystkich 1280, należy wykonać:  $1280+1279+1278+\dots+1230=64005$  operacji (trenowania i testowania klasyfikatora). Czas wykonywania takiego algorytmu wynosił kilka godzin na komputerze klasy Core 2 Duo. W takich przypadkach, długi czas selekcji cech znacząco ogranicza możliwość zastosowania SFS w systemach BCI. Dużą zaletą metody jest natomiast znacząca poprawa skuteczności klasyfikacji. Jednak należy pamiętać, że wybór cech odbywa się z uwzględnieniem wiedzy o skuteczności klasyfikacji dla konkretnego zbioru danych. Ostateczna weryfikacja może być wykonana na nowym zbiorze danych testujących.


Poniżej (rys 7.17) przedstawiono wyniki uzyskane w przypadku wykorzystania algorytmu SFS do selekcji cech w postaci 40 prążków widma (FFT) 1Hz÷40Hz, z zastosowaniem klasyfikatora w postaci LDA dla trzech, tradycyjnych zadań myślowych. Kryterium „stopu” ustawione było na dobór 50 cech.

<sup>8</sup> tłumaczenie autorskie




Rys. 7.17. Zależność błędu klasyfikacji od liczby cech, dla z metody SFS (klasyfikator LDA)

Określenie przydatności poszczególnych elektrod oraz prążków widma w charakterze cech zobrazowano na rysunkach 7.18 i 7.19.



Rys. 7.18. Częstość występowania cech na poszczególnych elektrodach dla metody SFS (klasyfikator LDA)

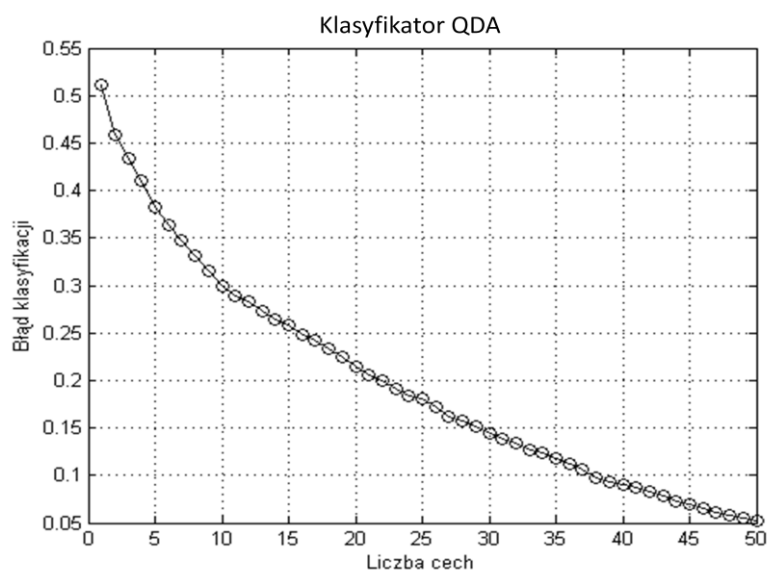





Rys. 7.19. Częstość występowania prążka widma, jako cechy dla metody SFS (klasyfikator LDA)

Dla opisanego wyżej przykładu, błąd klasyfikacji dla 50 cech wynosił 23.7%. Jest to lepszy wynik niż w przypadku opisanych wcześniej metod rankingowych. Metoda ta również pozwala na wyznaczenie najlepszych z punktu widzenia klasyfikacji prążków widma częstotliwości jak i położenia elektrod. Należy jednak z pewną rezerwą podchodzić do wysuniętych wniosków, bowiem cechy dobierane są dla konkretnego zbioru danych.


Oprócz klasyfikatora LDA autor przeprowadził badania na klasyfikatorze QDA. W wyniku uzyskano bardzo małą wartość błędu klasyfikacji (rzędu 5%), ale bez możliwości uogólnienia wyników na inne sesje użytkownika (rys 7.20÷7.22).



Rys. 7.20. Zależność wartości błędu klasyfikacji od liczby wybranych cech dla metody SFS (klasyfikator QDA)



Rys. 7.21. Częstość występowania cech na poszczególnych elektrodach, dla metody SFS (klasyfikator QDA)



Rys. 7.22. Częstość występowania prążka widma, jako cechy, dla metody SFS (klasyfikator QDA)

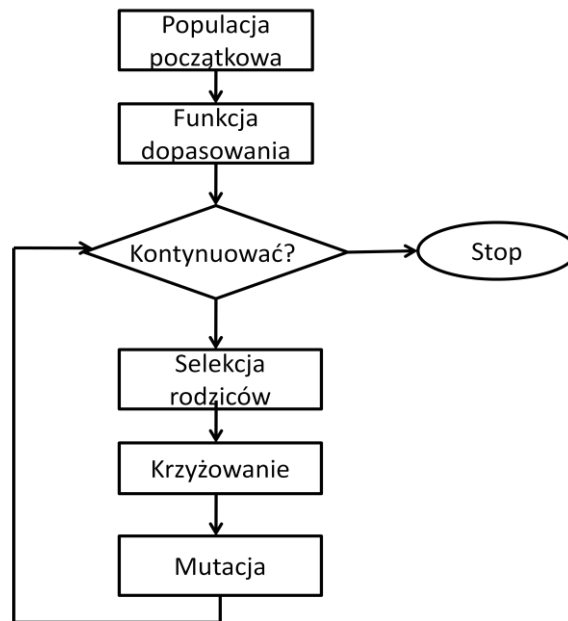
W metodzie SFS uzyskuje się wyraźne wskazanie znaczących cech z zakresów 8Hz÷12Hz oraz 18Hz÷26 Hz oraz możliwość wyselekcjonowania znaczących elektrod. Jednak metoda SFS testowana na klasyfikatorze liniowym LDA i nieliniowym QDA daje różne rezultaty.

## 7.4 Algorytmy genetyczne

W metodzie SFS, do selekcji cech, wykorzystano mało eleganckie rozwiązanie, jakim jest „siłowe” testowanie cech. Bardziej wyrafinowanym rozwiązaniem jest wykorzystanie algorytmów genetycznych (*Genetic Algorithms* - GA) [38,147,50,79,40]. Algorytmy genetyczne „naśladują” ewolucję biologiczną w celu jak najlepszego doboru cech osobników. Miarą oceny przydatności tych cech jest tak zwana funkcja przystosowania [147,148].

Podstawowa jednostką w GA jest osobnik, który składa się z chromosomów reprezentujących pewne geny-cechy. Tylko pewna część osobników o najlepszych genach-cechach jest w stanie przetrwać i przejść do następnego pokolenia. Możliwe jest tworzenie nowych osobników – dzieci, poprzez operację mutacji lub krzyżowania. Taka wymiana genów jest podstawą tworzenia cech. Operacja krzyżowania polega na losowym przecięciu chromosomu w pewnym punkcie i wymianie fragmentu chromosomu z innym. Operacja mutacji polega na zamianie dowolnego genu na inny.


Przykład wykorzystania algorytmów genetycznych do selekcji cech zostanie przedstawiony na cechach wygenerowanych za pomocą metody DWT/HOS. W wyniku ekstrakcji cech z 32 kanałowego zapisu EEG, otrzymano 672 cechy, dla 3 klas. Tak duża liczba cech uniemożliwia skuteczne trenowanie klasyfikatora. Autor uznał, że wystarczy uwzględnić jedynie 30 spośród nich. Liczba 30 została ustalona na podstawie wyników przeprowadzonych eksperymentów, które nie zostały opisane w pracy. Odbyło się to drogą kompromisu między czasem wykonywania algorytmu (rozmiar wektora cech), a wartością błędu klasyfikacji. Pierwszym etapem było losowe wygenerowanie 500 osobników (chromosomów) składających się z 30 genów. Odpowiada to wygenerowaniu 500 wektorów, każdy z 30 różnymi cechami. Dobór licznosci populacji wejściowej był dokonany w sposób eksperymentalny. Aby ocenić miarę przystosowania osobników i możliwość ich przejścia do kolejnego pokolenia zastosowano funkcję dopasowania. Podstawą funkcji dopasowania był efekt klasyfikacji. W roli klasyfikatora zastosowano kwadraturową analizę dyskryminacyjną (QDA). Do oceny błędu klasyfikacji (funkcja przystosowania) zastosowano 10-krotny test krzyżowy. Mniejszy błąd oznaczał lepszy dobór osobników (chromosomów), a co za tym idzie dobór lepszych cech. Schemat działania algorytmu genetycznego zaprezentowany został na rysunku 7.23.



Rys. 7.23. Etapy zastosowanego algorytmu genetycznego do selekcji cech

Selekcja „rodziców” polegała na dopuszczeniu do następnego pokolenia tylko osobników najlepiej przystosowanych (o najmniejszym błędzie klasyfikacji). Proces selekcji osobników przeprowadzany był za pomocą koła ruletki [90]. Krzyżowaniu podlegało 80% osobników. Punkt krzyżowania był ustawiany w sposób losowy. Ponieważ w populacji osobników mogły nie pojawić się odpowiednie cechy, wartościowe z punktu widzenia klasyfikacji, zastosowano również mutację. Mutacja pozwalała na wymianę genu na dowolny spośród 672 (cech). Prawdopodobieństwo zajścia mutacji wynosiło 5%. Kryterium stopu było przejście algorytmu ewolucyjnego przez 100 pokoleń. Działanie tego algorytmu zajmowało około 30 minut na komputerze klasy QuadCore.

Algorytm genetyczny został uruchomiony 10-krotnie, w celu wykrycia najczęściej wybieranych cech. Wyniki tego etapu zamieszczono na rys.7.24 (im ciemniejsze pole tym częściej wybierana cecha). Wykaz uzyskanych błędów klasyfikacji, dla poszczególnych cykli, zamieszczono w tabeli 7.1. Tabela zawiera wartości błędów klasyfikacji dla najlepszych osobników (najlepszych cech) oraz średnią wartość błędu dla całej populacji osobników w ostatnim cyklu działania algorytmu.




Rys. 7.24. Najczęściej wybierane cechy dla 10 cykli algorytmu genetycznego. Im ciemniejsze pole tym częściej wybierana cecha

Tabela 7.1 Wyniki dopasowania najlepszego osobnika i całej populacji osobników dla 10-krotnego uruchomienia algorytmu genetycznego

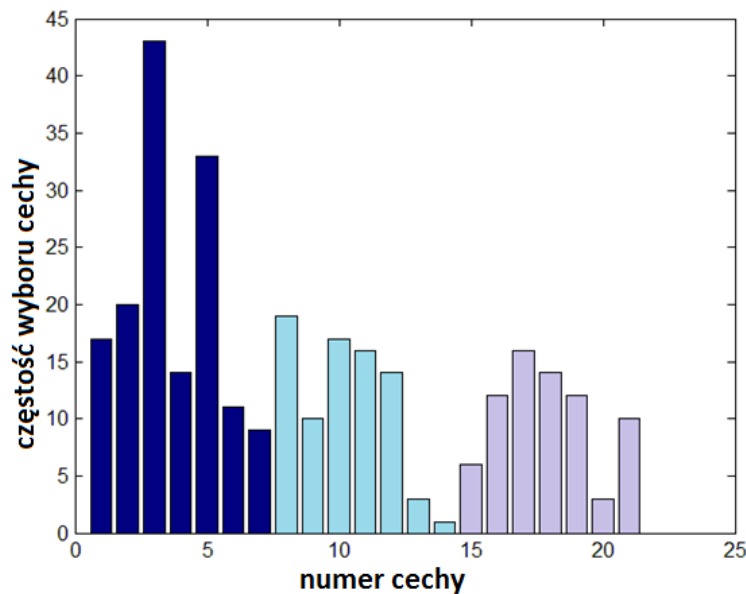
Nr cyklu	Najlepszy osobnik	Średnia dla najlepszych
1	11.6%	13.1%
2	9.50%	11.2%
3	10.1%	11.5%
4	8.10%	9.41%
5	10.3%	11.9%
6	9.10%	10.5%
7	9.70%	11.4%
8	9.90%	11.6%
9	8.60%	9.90%
10	11.8%	13.7%

Wyniki uzyskane z tego eksperymentu umożliwiły wyciągnięcie wniosków na temat najczęściej wybieranych cech (HOS), skojarzonych z poszczególnymi elektrodami. Wyniki obrazujące liczbę cech przypadających na poszczególne elektrody oraz częstość wybieranych cech są przedstawione na rysunkach 7.25 i 7.26. Pierwsze 7 cech przypada na wariancję, kolejne cechy to odpowiednio skośność i kurtoza dla detali  $d_1... d_7$ .

Z rysunku 7.26 wynika, że najczęściej wyselekcjonowaną podczas 10 cykli algorytmu genetycznego była cecha o numerze 3. Jest to wariancja detalu  $d_3$  czyli energia sygnału w pewnym specyficznym podpaśmie.



Rys. 7.25. Częstość wybierania cech, przypisanych do elektrod, dla 10 cykli algorytmu genetycznego




Rys. 7.26. Częstość wybierania cech dla 10 cykli algorytmu genetycznego

Błąd klasyfikacji dla pojedynczego cyklu algorytmu wynosił od 8.6% do 11.6%. Najczęściej wyselekcjonowanymi były cechy przypisane do elektrod 8, 9, 23 oraz 32 (C3, CP1, C4, Cz). Dokonany w ten sposób wybór elektrod zgodny jest z dotychczasową wiedzą neuropsychologiczną, jak również potwierdzony wynikami otrzymanymi za pomocą innych metod opisanych w pracy, na przykład rankingowych.

Kolejny eksperyment polegał na wyselekcjonowaniu tylko 4, najlepszych elektrod i ponownym uruchomieniu 10 cykli algorytmu genetycznego. Chodziło o sprawdzenie czy 4

wyselekcjonowane elektrody pozwolą na skuteczną klasyfikację. Skuteczność działania algorytmu zobrazowano na rys. 7.27.




Rys. 7.27. Błąd dopasowania osobników algorytmu genetycznego, kolor czarny - najlepszy osobnik w populacji, kolor niebieski - średnia populacji w kolejnych generacjach


Średnia wartość błędu dla 10 cykli algorytmu genetycznego wynosiła 10.5%. Jest to wynik bardzo zadawalający. Możliwa jest zatem skuteczna klasyfikacja w przypadku ograniczonej liczby elektrod.

W trakcie kolejnych eksperymentów autor wykorzystywał inne zbiory cech wejściowych i dokonywał ich selekcji za pomocą metody GA. Dla porównania zobrazowano wyniki otrzymane dla metody ekstrakcji: FFT, 1Hz÷40Hz (rys. 7.28, 7.29). Uzyskany błąd klasyfikacji, dla 10 cykli algorytmu genetycznego mieścił się w granicach od 22% do 26%.

Podobnie jak w poprzednim eksperymencie, wybrano najlepsze 4 elektrody: 9, 10, 22 i 23, które odpowiadają odpowiednio pozycjom: CP1, CP5, CP2 i C4 i ponownie uruchomiono algorytm. Otrzymano błąd klasyfikacji rzędu 23%. Warto zauważyć, że wyselekcjonowane 4 najlepsze elektrody dla metody FFT, były inne niż dla cech wyliczanych na podstawie DWT/HOS. To pozwala wysnuć wniosek, że sposób ekstrakcji cech wpływa na wyselekcjonowanie „najlepszych” elektrod. Cechy DWT/HOS dają znacząco lepsze wyniki klasyfikacji. Trzeba podkreślić, że wadą zastosowanego algorytmu genetycznego, jako metody selekcji cech, jest stosunkowo długi czas jego wykonywania. Algorytmy genetyczne bardzo dobrze sprawdzają w trybie *off-line*.



Rys. 7.28. Częstość wybierania poszczególnych cech (FFT: 1Hz÷40Hz), przypisanych do elektrod, dla 10 cykli algorytmu genetycznego (Im ciemniejsze pola tym częściej wybierane cechy)



Rys. 7.29. Częstość wybierania poszczególnych cech (FFT: 1Hz÷40Hz), dla 10 cykli algorytmu genetycznego

## 7.5 Metody transformacyjne


Opisane dotychczas metody selekcji nie powodowały modyfikacji (transformacji) cech, poddawanych klasyfikacji. Zarówno w metodzie „siłowej” (SFS) jak i t-statystykach celem było wyselekcjonowanie najlepszych cech spośród wielkiej ich liczby. Zaletą opisanych metod jest duża szybkość działania, jak również zachowanie niezmodyfikowanych cech.



Poniżej zostaną opisane metody, których zadaniem było stworzenie nowych, lepszych cech. Tworzenie nowych cech wykonuje się poprzez liniowe transformacje, rzutowanie cech oryginalnych na nowe współrzędne. Wynikowe cechy stanowią liniową kombinację cech pierwotnych. Uniemożliwia to praktyczne stwierdzenie, które cechy pierwotne, a co za tym idzie, które elektrody wnoszą najwięcej do procesu klasyfikacji. Warto zaznaczyć, że skutkiem tego, wspomniane metody często zaliczane są do metod ekstrakcji cech (a nie selekcji). W przypadku zastosowania metod transformacyjnych takich jak LDA czy PCA wykorzystuje się ograniczoną liczbę nowych składowych (cech), a zatem metody te można zaliczyć również do selekcji cech.

### 7.5.1 Analiza składowych głównych (PCA)

Analizę składowych głównych (*Principal Component Analysis* - PCA) można zaliczyć do nienadzorowanych metod selekcji cech, ponieważ nie uwzględnia się w niej przynależności cech pierwotnych do konkretnej klasy [139]. Jest to podstawowa niedogodność tej metody w zastosowaniu do ekstrakcji/selekcji (nowych) cech na użytek klasyfikacji. Istotą metody PCA jest konstrukcja (nowych) ortogonalnych przestrzeni cech. Nowe współrzędne przestrzeni dobierane są tak, aby zmaksymalizować rozrzut nowych cech. Takie postępowanie można uzasadnić tym, że większe zróżnicowanie położenia próbek wzdłuż kierunku (współrzędnej) przestrzeni cech, oznacza łatwiejszą kategoryzację [140]. (rys 7.30).



Rys. 7.30. Ideą PCA jest wyszukanie nowych współrzędnych, które maksymalizują wariancję zrzutowanych danych

Miarą rozrzutu próbek wzdłuż określonego kierunku, może być wariancja lub odchylenie standardowe. Aby obliczyć wartości danych (próbek  $y$ ) w nowym układzie współrzędnych  $v$ , możemy posłużyć się równaniem  $y = v^T x$ , gdzie  $x$  oznacza wartości oryginalnych

danych [101]. Zasadniczym celem PCA jest znalezienie takich kierunków  $\mathbf{v}$ , które zapewnią maksymalizację wariacji w nowej przestrzeni. Znalezienia wektorów PCA dokonuje się najczęściej za pomocą macierzy kowariancji danych, a następnie oblicza się wartości i wektory własne [115]. Wektory własne reprezentują składowe PCA. Załóżmy, że dane oryginalne  $\mathbf{x}$  mają wartość średnią równą zero, wtedy macierz kowariancji/korelacji może być obliczona ze wzoru:


$$\mathbf{C} = E[\mathbf{x}\mathbf{x}^T] \quad (7.9)$$

Następnym etapem jest rozkład macierzy  $\mathbf{C}$  na wartości i wektory własne:

$$\mathbf{C} = \mathbf{U}\mathbf{L}\mathbf{U}^T \quad (7.10)$$


gdzie  $\mathbf{U}=[\mathbf{u}_1, \dots, \mathbf{u}_N]$  to macierz zawierająca wektory własne, a  $\mathbf{L}=\text{diag}\{l_1, l_2, \dots, l_N\}$  to stowarzyszone z nimi wartości własne. Każdy z wektorów własnych jest nową składową PCA. Wartość własna skojarzona z wektorem własnym wskazuje na wariację danych zrzutowanych na ten wektor. Im większa wartość własna tym większa wariacja danej składowej. Wartość własna więc, może być interpretowana jako miara mówiąca o tym ile wnosi dana składowa do procesu kategoryzacji danych [139].

Poniżej przedstawiono przykład wykorzystania PCA, jako metody selekcji cech. Jako cechy pierwotne zostały użyte prążki widma od 1Hz÷40Hz sygnału EEG. Dla 32 kanałów liczba cech wynosiła 1280. Zadaniem było przypisanie danych do 3 klas. Pierwszym etapem było sprawdzenie jak rozkłada się wariacja danych po zrzutowaniu na nowe współrzędne. Zgodnie z ideą PCA, rozrzut próbek na pierwszej składowej jest największy, a na każdej kolejnej coraz to mniejszy (rys. 7.31).



Rys. 7.31. Wariancja 40 pierwszych składowych PCA (FFT 1Hz÷40 Hz)

Zasadniczym celem przeprowadzanych eksperymentów było sprawdzenie czy zastosowanie PCA poprawi trafność klasyfikacji. Dodatkowo przebadano wpływ liczby uwzględnionych składowych PCA na jakość klasyfikacji (rys. 7.32).




Rys. 7.32. Błąd klasyfikatorów dla kolejnych składowych PCA

Zwiększając liczbę składowych PCA, sprawdzano trafność klasyfikacji LDA oraz QDA przy użyciu 10-krotnego testu krzyżowego. Nie zaobserwowano znaczącej poprawy trafności klasyfikacji dla nowej przestrzeni cech. Taki stan rzeczy wynika ze wspomnianego już ograniczenia PCA, to jest braku uwzględniania przynależności danych do klas. Dodatkową wadą algorytmu PCA jest to, że nowe składowe są liniową kombinacją cech wejściowych (wszystkich danych). Takie rozwiązanie nie przybliży nas do wskazania optymalnych cech.

### 7.5.2 Analiza Dyskryminacyjna (LDA, QDA)

Analiza dyskryminacyjna jest znaną techniką wykorzystywaną do redukcji liczby cech [139,150]. Podobnie jak PCA w liniowej analizie dyskryminacyjnej poszukuje się nowych współrzędnych, które posłużą do zrzutowania danych. Jednak w przeciwieństwie do PCA, w metodzie LDA nie maksymalizuje się wariancji danych, ale rozróżnia przynależność do klas. Nowe współrzędne znajdują się w sposób taki, aby zmaksymalizować rozrzut międzyklasowy, a zminimalizować rozrzut wewnątrzklasowy (rys 7.33 i rys 7.34) Przy czym w metodzie LDA nowe składowe nie muszą być ortogonalne. Od razu warto zaznaczyć, że z uwagi na powyższe właściwości, metoda LDA lepiej nadaje się do selekcji cech na użytek klasyfikacji niż PCA.



Rys. 7.33. Zobrazowanie idei LDA - znajdowane są składowe, które najlepiej rozseparują dane

Za kryterium liniowej separowalności klas można uznać wyrażenie [139]:

$$F = \frac{\text{tr}(\mathbf{S}_m)}{\text{tr}(\mathbf{S}_w)} \quad (7.11)$$

gdzie  $\mathbf{S}_m$  oznacza macierz rozrzutu międzyklasowego (*between-class scatter*), a macierz  $\mathbf{S}_w$  jest macierzą rozrzutu wewnątrzklasowego (*within-class scatter*). Im większa wartość współczynnika  $F$  tym większe prawdopodobieństwo liniowej separowalności klas. Załóżmy, że mamy  $C$  klas, a każda zawiera  $N$  obserwacji  $\mathbf{x}_i$ . Macierz rozrzutu wewnątrzklasowego  $\mathbf{S}^c$  dla klasy  $c$  można obliczyć za pomocą równania:

$$\mathbf{S}^c = \sum_{i=1}^N (\mathbf{x}_i^c - \boldsymbol{\mu}^c) (\mathbf{x}_i^c - \boldsymbol{\mu}^c)^T \quad (7.12)$$

gdzie  $\boldsymbol{\mu}^c$  oznacza średnią wszystkich obserwacji  $\mathbf{x}_i$  dla  $c$ -tej klasy. Całkowitą macierz rozrzutu wewnątrzklasowego  $\mathbf{S}_w$  dla wszystkich  $C$  klas można obliczyć jako:

$$\mathbf{S}_w = \sum_{i=1}^c \frac{n_i}{N} \mathbf{S}^i \quad (7.13)$$

gdzie  $n_i$  jest liczbą obserwacji  $\mathbf{x}_i$  dla każdej klasy, a  $N$  oznacza całkowitą liczbę obserwacji.


Macierz rozrzutu międzyklasowego  $\mathbf{S}_B^c$  dla klasy  $c$  można obliczyć za pomocą wyrażenia:

$$\mathbf{S}_B^c = \sum_{i=1}^c (\boldsymbol{\mu}^i - \boldsymbol{\mu})(\boldsymbol{\mu}^i - \boldsymbol{\mu})^T \quad (7.14)$$

gdzie  $\boldsymbol{\mu}^i$  oznacza średnią dla obserwacji  $\mathbf{x}_i$  dla  $i$ -tej klasy, a  $\boldsymbol{\mu}$  oznacza średnią dla wszystkich obserwacji  $\mathbf{x}_i$  dla wszystkich klas. Całkowitą macierz rozrzutu międzyklasowego  $\mathbf{S}_m$  dla wszystkich  $C$  klas można obliczyć z zależności:

$$S_m = \sum_{i=1}^c \frac{n_i}{N} S_B^i \quad (7.15)$$

gdzie  $n_i$  jest liczbą obserwacji  $x_i$  dla każdej klasy, a  $N$  oznacza całkowitą liczbę obserwacji.



Rys. 7.34. Prezentacja rozrzutu wewnątrzklasowego i międzyklasowego


W praktyce, aby wyznaczyć kierunki określające najlepszą miarę separowalności  $F$ , wyznacza się macierz  $S = S_w^{-1} S_m$ . (iloraz macierzy rozrzutu międzyklasowego i rozrzutu wewnątrzklasowego).

Następnym etapem jest wyznaczenie wartości własnych i wektorów własnych tej macierzy:


$$S = ULU^T \quad (7.16)$$

gdzie  $U=[u_1, \dots, u_N]$  to macierz zawierająca wektory własne a  $L=diag\{l_1, l_2, \dots, l_N\}$  to stowarzyszone z nimi wartości własne. Wektory własne, o największych wartościach własnych, wytyczają współrzędne, które maksymalizują współczynnik separacji  $F$ . Warto zauważyć, że w praktyce macierz  $S$  nie jest macierzą symetryczną i znalezienie wektorów własnych nie jest sprawą prostą, tak jak w przypadku metody PCA. W tym przypadku stosuje się rozwiązanie uogólnionego problemu własnego.

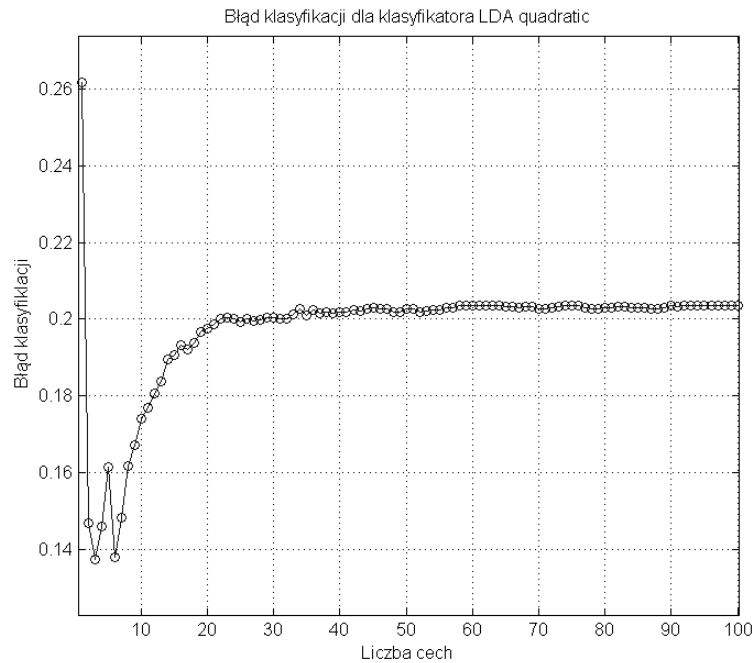
Poniżej, jak poprzednio, przedstawiono przykład zastosowania selekcji cech FFT: 1Hz÷40Hz, dla 32 kanałów, czyli 1280 cech wejściowych. W wyniku zastosowania LDA otrzymano nowe składowe, na które rzutowano dane. Autor zbadał wpływ liczby nowych składowych (liczby nowych cech) na trafność klasyfikacji. Zastosowano 10-krotny test krzyżowy dla klasyfikatora LDA - liniowego, QDA - nieliniowego oraz dodatkowo dla klasyfikatora K-NN (rys. 7.35÷7.37).



Rys. 7.35. Błąd klasyfikacji (K-NN) dla selekcji cech metodą LDA (liczba cech jest równoznaczna z liczbą składowych LDA)



Rys. 7.36. Błąd klasyfikacji (Klasyfikator LDA) dla selekcji cech metodą LDA (liczba cech jest równoznaczna z liczbą składowych LDA)



Rys. 7.37. Błąd klasyfikacji (klasyfikator QDA) dla selekcji cech metodą LDA (liczba cech jest równoznaczna z liczbą składowych LDA)

Wyniki wskazują, że jakość klasyfikacji poprawia się wraz ze wzrostem liczby wybranych cech. Największa poprawa następuje dla kilku pierwszych składowych. Dla QDA zaobserwować można, że powyżej 10 cech błąd klasyfikacji wzrasta do wartości 20%. Ponadto klasyfikator QDA daje większe wartości błędów w porównaniu z klasyfikatorami K-NN czy LDA.

Celem omówionych wyżej, rankingowych metod selekcji cech było wybranie najbardziej cennych z punktu widzenia skuteczności klasyfikacji. W metodach: t-statystyk, K-Fishera i korelacyjnej wykorzystywane są statystyczne parametry do określenia przydatności cech i ich użyteczności. W innych, takich jak: sekwencyjne przeszukiwanie w przód (SFS) i algorytmy genetyczne (GA), do stwierdzenia użyteczności cech wykorzystywano wiedzę o efekcie trenowania klasyfikatora. Wszystkie wymienione metody pozwalały na uszeregowanie cech w pewnym rankingu od najważniejszych do najmniej ważnych. Takie uszeregowanie pozwala wyciągnąć wnioski, z którymi elektrodami związane są najbardziej istotne cechy.

Ogromną zaletą opracowanych metod jest ich uniwersalność. Pozwalają one na wskazanie położenia najlepszych elektrod, dla dowolnych zadań myślowych (interfejsów asynchronicznych). Pewną nadzieją na lepsze wyniki klasyfikacji, nawet dla ograniczonej liczby elektrod, jest metoda LDA, która tworzy nowe bardziej separowalne cechy.

---

## 8. KLASYFIKATORY EEG

---

W poprzednich rozdziałach opisano sposoby przetwarzania sygnału, ekstrakcji oraz selekcji cech. Wszystkie te operacje mają na celu przygotowanie jak najlepszych danych (cech) na użytek klasyfikatora. Na tym etapie założymy, że znana jest pewna liczba cech, które dają nadzieję na przeprowadzenie efektywnej klasyfikacji. Jak już wspomniano wcześniej, interfejsy mózg-komputer działają w dwóch trybach: kalibracji oraz eksploatacji. W trybie kalibracji następuje trenowanie klasyfikatora, na podstawie informacji o przynależności cech i stowarzyszonych z nimi wybranych fragmentów sygnału do poszczególnych klas. W trybie eksploatacji, cechy wyekstrahowane z nowych fragmentów sygnału, zostają przypisane do odpowiednich klas (w tym przypadku zadań myślowych). Istnieje wiele algorytmów klasyfikacji, które zalicza się najczęściej do metod sztucznej inteligencji (rozpoznawanie wzorców). W tym celu najczęściej wykorzystuje się: sieci neuronowe MLP (*Multilayer Perceptron*), maszyny wektorów wspierających SVM (*Support Vector Machine*), Analizę Dyskryminacyjną LDA (*Linear Discriminant Analysis*), analizę QDA (*Quadratic Discriminant Analysis*), naiwny klasyfikator Bayesa NBC (*Naive Bayes Classifier*), klasyfikator najbliższego sąsiedztwa K-NN (*K-Nearest Neighbor*), a nawet drzewa decyzyjne DT (*Decision Tree*) [92]. Istnieją również metody klasyfikacji, w których nie wykorzystuje się wiedzy o przynależności do klas (klasyfikacja bez nadzoru). Zwykle jednak metody te dają gorsze rezultaty. Przeprowadzone przez autora eksperymenty, miały na celu dokonanie wyboru klasyfikatorów, które dobrze sprawdzają się w zastosowaniu do asynchronicznego interfejsu mózg-komputer, z klasyfikacją zadań myślowych.

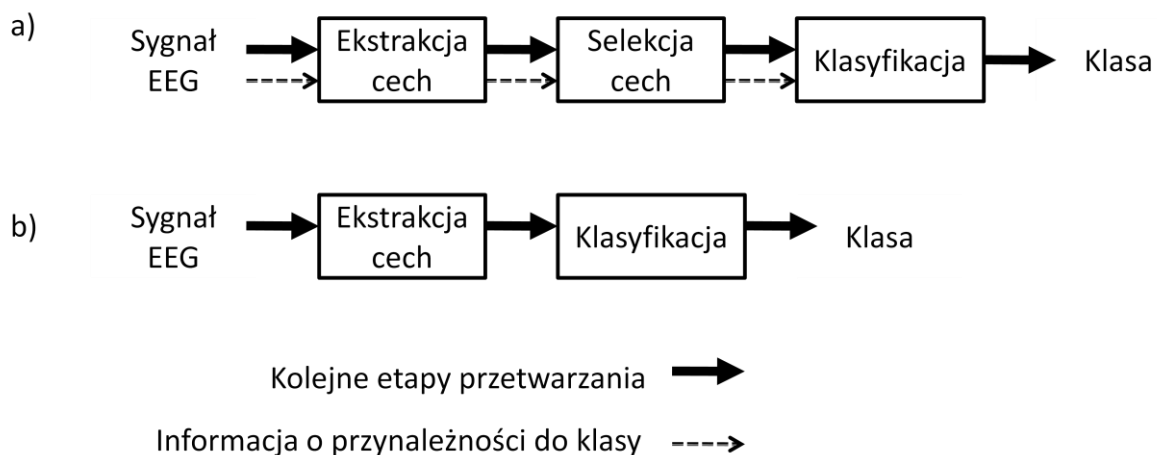
Klasyfikator to rodzaj algorytmu, który „przydziela” obserwacje do zdefiniowanych klas, bazując na atrybutach (cechach) tych obserwacji. Dla danej sekwencji treningowej (zbioru danych treningowych)  $\{(\mathbf{x}_1, y), \dots, (\mathbf{x}_n, y)\}$  należy znaleźć klasyfikator  $k: \mathbf{X} \rightarrow \mathbf{Y}$ , który „przydzieli” obiekt  $x \in \mathbf{X}$  do klasy  $y \in \mathbf{Y}$ . W przypadku interfejsu mózg-komputer  $\mathbf{x}_i$  reprezentuje pewien zbiór cech a  $y_i$ , to przypisane pewnemu fragmentowi sygnału EEG „zadania myślowe”. W trybie eksploatacji klasyfikator przypisuje do klas nowe dane nie wchodzące w zbiór danych uczących.

W asynchronicznym interfejsie mózg-komputer klasyfikator przypisuje zarejestrowane cechy do klas - to jest „zadań myślowych”. Jak wiadomo, ważnym zadaniem jest



odpowiednie wygenerowanie zbioru cech, które najlepiej odzwierciedlą dane zjawisko - co nierzadko jest zadaniem trudnym. Celem oceny trafności klasyfikacji wykonuje się testowanie klasyfikatora dla nowych danych (cech) i sprawdza trafność klasyfikacji.

Na wstępie, dane do trenowania, a także wstępnego testowania klasyfikatora, rejestrowane są podczas sesji kalibracyjnej, gdzie zadaniem użytkownika jest realizacja zdefiniowanych „zadań myślowych”. W tym przypadku, z góry znana jest przynależność obserwacji (cech) do poszczególnych klas. W sesji kalibracyjnej, na etapie testowania wstępnego, możliwa jest ocena trafności działania klasyfikatora (rys. 8.1).



Rys. 8.1. Schemat działania systemu BCI podczas sesji a) kalibracyjnej i b) eksploatacji

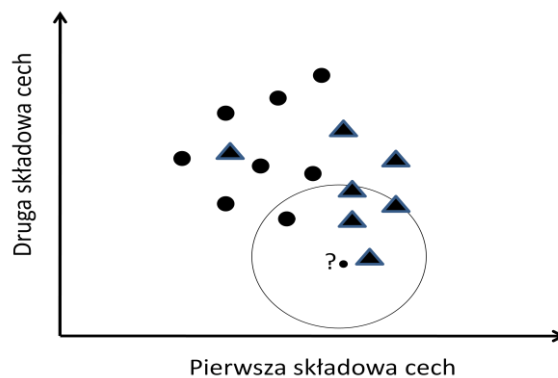
Istnieje wiele miar oraz sposobów oceny trafności klasyfikacji. W najprostszym przypadku, przy braku odpowiednich zestawów danych, testowanie algorytmów BCI odbywa się na tych samych danych, których użyto do trenowania klasyfikatora. Bardziej miarodajnym sposobem testowania algorytmów jest podział zarejestrowanych (dostępnych) danych na uczące (70%) i testujące (30%). Innym, często stosowanym sposobem jest użycie tzw. testu krzyżowego (*cross-validation test*), np. 10-krotnego. W tym przypadku, cały zbiór danych zostaje podzielony na 10 podzbiorów. Do trenowania używa się pierwszych 9-ciu podzbiorów, 10-ty zarezerwowany jest do testowania. Następnie proces trenowania obejmuje podziory od 1-8 oraz 10, a test przeprowadza się na podzbiore 9. Proces ten jest powtarzany dla każdego z 10 podzbiorów. W ten sposób każdy zbiór zostaje użyty do nauki oraz testowania klasyfikatora, a dane wykorzystane są wielokrotnie (rys 8.2). Pozornie, ma się do dyspozycji znacznie większy zbiór danych. Błąd całkowity testu jest sumą błędów otrzymanych dla każdego podzbioru testowego.



Rys. 8.2. Etapy 10-krotnego testu krzyżowego

### 8.1 Klasyfikator K- najbliższych sąsiadów (K-NN)

W klasyfikatorze K-najbliższych sąsiadów (K- Nearest Neighbours: K-NN) do klasyfikacji wykorzystuje się wiedzę o przynależności do klas „najbliżej położonych” danych [139]. Sprawdzana jest przynależność do klas  $K$  najbliższych sąsiadów bieżącego obiektu. Obiekt zostaje zaklasyfikowany do tej klasy, do której przynależała największa liczba sąsiadów z tej grupy. Parametr  $K$  przyjmuje wartości od 1 (1-NN) do kilkunastu. Zasadniczym problemem jest znalezienie w wielowymiarowej przestrzeni odpowiedniej liczby sąsiadów. Jest to problem czasochłonny szczególnie dla dużej liczby danych, bowiem zadanie rozwiązuje się sprawdzając odległość bieżącego obiektu od wszystkich obiektów sekwencji treningowej. Przykład działania klasyfikatora 5-NN zobrazowano na rysunku 8.3.



Rys. 8.3. Działanie klasyfikatora 5-NN

Klasyfikator ten „odnajduje” 5-ciu najbliższych sąsiadów próbki (bieżącej), która ma zostać sklasyfikowana (mała kropka) i zlicza próbki przypisane do poszczególnych klas (koła, trójkąty). W tym przypadku, bieżąca próbka zostaje zaklasyfikowana do klasy oznaczonej trójkątem. Na jakość klasyfikacji może mieć wpływ liczba  $K$  uwzględnianych sąsiadów oraz rozkład w przestrzeni wielowymiarowej zarejestrowanych uprzednio próbek (cech w naszym przypadku). Metoda  $K$ -NN jest prosta i intuicyjna, a przy odpowiednim doborze parametru  $K$  bardzo skuteczna. Wybór odpowiedniej liczby sąsiadów  $K$  jest podstawowym zadaniem przy projektowaniu klasyfikatora. Zbyt duża wartość parametru  $K$  uniemożliwia odzwierciedlenie skomplikowanej struktury przestrzeni cech. Autor przeprowadził analizę wpływu liczby sąsiadów  $K$  na jakość klasyfikacji. Poniżej zaprezentowano wyniki klasyfikacji dla różnych wartości parametru  $K$  (tabele 8.1 ÷ 8.4). Oprócz błędu globalnego zostały zaprezentowane macierze pomyłek (*confusion matrix*), objaśniające jak przebiegał rozkład klasyfikacji zmiennych dla konkretnych klas. Cechami wejściowymi była wariancja sygnału EEG w paśmie 8Hz÷30Hz dla 32 elektrod. Błędy zostały obliczone z zastosowaniem 10-krotnego testu krzyżowego.

Tabela 8.1. Macierz pomyłek dla klasyfikatora 1-NN. Błąd całkowity 0,4%

1-NN	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	503	3	1
K3	1	612	3
K7	0	1	788

Tabela 8.2. Macierz pomyłek dla klasyfikatora 5-NN. Błąd całkowity 2,2%

5-NN	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	494	12	10
K3	8	601	7
K7	2	3	775

Tabela 8.3. Macierz pomyłek dla klasyfikatora 5-NN. Błąd całkowity 5,3%

10-NN	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	482	22	31
K3	13	587	21
K7	9	7	740

Tabela 8.4. Macierz pomyłek dla klasyfikatora 5-NN. Błąd całkowity 12,87%

20-NN	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	424	43	51
K3	29	556	55
K7	51	17	686


Przedstawione wyniki wskazują, że wartość parametru  $K$  ma duży wpływ na trafność klasyfikacji. Wraz z wzrostem parametru  $K$ , w analizowanym przypadku, najlepiej wypada klasyfikator 1-NN. Błąd wynosi zaledwie 0.47%.

## 8.2 Analiza dyskryminacyjna (LDA, QDA)

Liniowa analiza dyskryminacyjna (LDA) oraz kwadraturowa analiza dyskryminacyjna (QDA), omówione są w rozdziale dotyczącym selekcji cech. Stanowią one również najpopularniejsze techniki klasyfikacji, z wykorzystaniem tzw. podziału przestrzeni cech. Dokładne rozważania na ten temat można znaleźć w bogatej literaturze np. [72,75].

W klasyfikacji minimalno-odległościowej, związanej z podziałem przestrzeni cech, zakłada się, że każda z kategorii jest reprezentowana w przestrzeni cech za pomocą pewnego, ograniczonego zbioru próbek wzorcowych (cech). Inna strategią klasyfikacji jest określenie tzw. powierzchni separujących. Najczęściej powierzchniami tymi są hiperpłaszczyzny w przestrzeni  $N$  wymiarowej, gdzie  $N$  oznacza liczbę wykorzystanych cech. Wiedza o parametrach powierzchni separujących estymowana jest poprzez analizę danych sekwencji treningowej. Sprawdza się położenie próbki względem powierzchni separującej.

Na użytek klasyfikacji (rys. 8.4), oprócz wyznaczenia najlepszego kierunku rzutowania  $\mathbf{a}$  maksymalizującego odległość między rzutowanymi wartościami średnimi klas, (przy uwzględnieniu wariancji składników) należy wskazać hiperpłaszczyzny, które rozseparują wszystkie klasy. Aby zbudować regułę dyskryminacyjną, rzutuje się składniki  $\mathbf{x}$  na kierunek  $\mathbf{a}$ , a następnie przypisuje się je do jednej z klas - w zależności od tego czy rzut ten był bliższy rzutowi środka grupy pierwszej czy drugiej.



Rys. 8.4. Przykład tworzenia reguły dyskryminacyjnej

Problem klasyfikacji za pomocą LDA można uogólnić na przypadek większej liczby klas,  $K > 2$ . Takie uogólnienie zaproponowali C. R. Rao i J.G Bryan [72]. Najczęściej nie jest możliwe określenie jednego kierunku rozdzielającego klasy. Wtedy szuka się kilku kierunków kanonicznych. W tym przypadku rozwiązuje się  $\binom{K}{2}$  zadań dyskryminacyjnych między parami klas. Po to, aby proste dyskryminacyjne dla  $K$  klas przecinały się w tym samym punkcie, należy dla wszystkich klas przyjąć wspólną macierz kowariancji wewnątrzgrupowej. Można wykazać, że dla niektórych zbiorów danych łatwiejsza jest separacja klas za pomocą funkcji kwadratowych (kwadraturowych) [75]. Mówimy wtedy o tak zwanej kwadraturowej analizie dyskryminacyjnej (*Quadratic Discriminant Analysis* - QDA). Poniżej zaprezentowano wyniki klasyfikacji wraz z macierzami błędów dla klasyfikatorów LDA oraz QDA (Tab. 8.5-8.6). Cechy to wariancja sygnału EEG w paśmie 8Hz÷30Hz dla 32 elektrod. Błędy zostały obliczone z zastosowaniem 10-krotnego testu krzyżowego.

Tabela 8.5. Macierz pomyłek dla klasyfikatora LDA. Błąd całkowity 23,3%

LDA Klasy przewidziane	Oryginalne klasy		
	K2	K3	K7
K2	781	217	214
K3	84	949	168
K7	143	66	1202

Tabela 8.6. Macierz pomyłek dla klasyfikatora QDA. Błąd całkowity 11,7%

QDA Klasy przewidziane	Oryginalne klasy		
	K2	K3	K7
K2	972	27	177
K3	21	1202	213
K7	8	3	1194


Powyższe wyniki obrazują, że klasyfikator LDA (22% decyzji błędnych) wypada gorzej niż QDA (11% decyzji błędnych). Ponadto, błąd dla obu klasyfikatorów (LDA, QDA) jest większy niż dla klasyfikatora K-NN. Jednak klasyfikatory LDA i QDA działają znacznie szybciej, nie wymagają sprawdzenia odległości od każdej obserwacji, a klasyfikują jedynie na podstawie przynależności do pewnej podprzestrzeni. Jak wspomniano, wyniki klasyfikacji dla QDA są lepsze niż dla LDA, ale liniowa analiza dyskryminacyjna cechuje się większą zdolnością do generalizacji.

### 8.3 Sieci neuronowe MLP

Inną, bardzo popularną metodą klasyfikacji, jest zastosowanie sztucznych sieci neuronowych (*Artificial Neural Networks* - ANN). Sztuczne sieci neuronowe są koncepcją

przetwarzania danych bazującą na sposobie działania neuronów mózgowych organizmów żywych. Neurony to układy o wielu wejściach pobudzanych sygnałami  $x_i$  pochodzącymi z wyjść innych neuronów lub sygnałami pochodzącymi z zewnątrz sieci i jednym wyjściu  $y_i$  (rys 8.5).

Informacja przekazywana przez neuron ma postać liczby z pewnego przedziału wartości. Wejściom neuronu przypisane są współczynniki wagowe  $w$ , modelujące połączenia synaptyczne rzeczywistych neuronów. Poziom aktywności neuronu jest wyznaczany przez nieliniowe przekształcenie  $f(u_j)$  (funkcja aktywacji), ważonej sumy sygnałów wejściowych  $\mathbf{x}^T \mathbf{w}$ . Suma sygnałów wejściowych może być korygowana za pomocą stałego współczynnika zwanego polaryzacją  $\emptyset$ . Natomiast nieliniowa funkcja aktywacji  $f(u_j)$  jest potrzebna po to, aby sygnały wyjściowe neuronów miały ograniczone wartości. Najczęściej wykorzystywane funkcje aktywacji to funkcja sigmoidalna, tangens hiperbolioczny oraz skok jednostkowy.



Rys. 8.5. Matematyczny model neuronu

Sygnał wyjściowy neuronu ma postać [89]:

$$y_j = f \left( \sum_{i=1}^N x_i w_i + \emptyset \right) = f(\mathbf{x}^T \mathbf{w} + \emptyset) \quad (8.1)$$

Można również zapisać wygnał wyjściowy jako  $y_j = f(\mathbf{x}_I^T \mathbf{w}_I)$ , gdzie  $\mathbf{x}_I = [\mathbf{x}^T \ \mathbf{I}]^T$  to rozszerzony wektor wag oraz  $\mathbf{w}_I = [\mathbf{w}^T \ \emptyset]$  to rozszerzony wektor wejściowy. Sieci neuronowe zbudowane z wielu neuronów, ułożonych w tak zwane warstwy, znalazły wiele zastosowań i określane są mianem: *Multilayer Perceptron* (MLP).

Oprócz sieci MLP istnieje wiele odmian sztucznych sieci neuronowych na przykład: sieci radialne, sieci rekurencyjne Hopfielda, sieci samoorganizujące się i inne [139]. Według niektórych naukowców do sieci neuronowych zalicza się również maszynę wektorów

wspierających (*Support Vector Machine- SVM*), która została opisana w osobnym podrozdziale.

Możliwe jest określanie wag  $w$  na etapie uczenia sieci przy użyciu zbioru treningowego. Na wejścia neuronu lub pierwszej warstwy sieci neuronowej podaje się dane uczące (z sekwencji treningowej) i tak koryguje wagi, aby na wyjściu neuronu pojawiły się odpowiednie wartości wyjściowe. Istnieje wiele sposobów doboru odpowiednich wag, co jest kojarzone z tak zwanym procesem uczenia neuronu lub sieci neuronowej. Pierwszym etapem jest losowy dobór wartości wag z pewnego przedziału. Następnie wagi neuronów modyfikowane są zgodnie z reguła Widorfa-Hoffa [139]. Modyfikacja wag ma doprowadzić do minimalizacji błędu klasyfikatora:

$$\Delta w = \eta(d_i - y_i)x_i \quad (8.2)$$

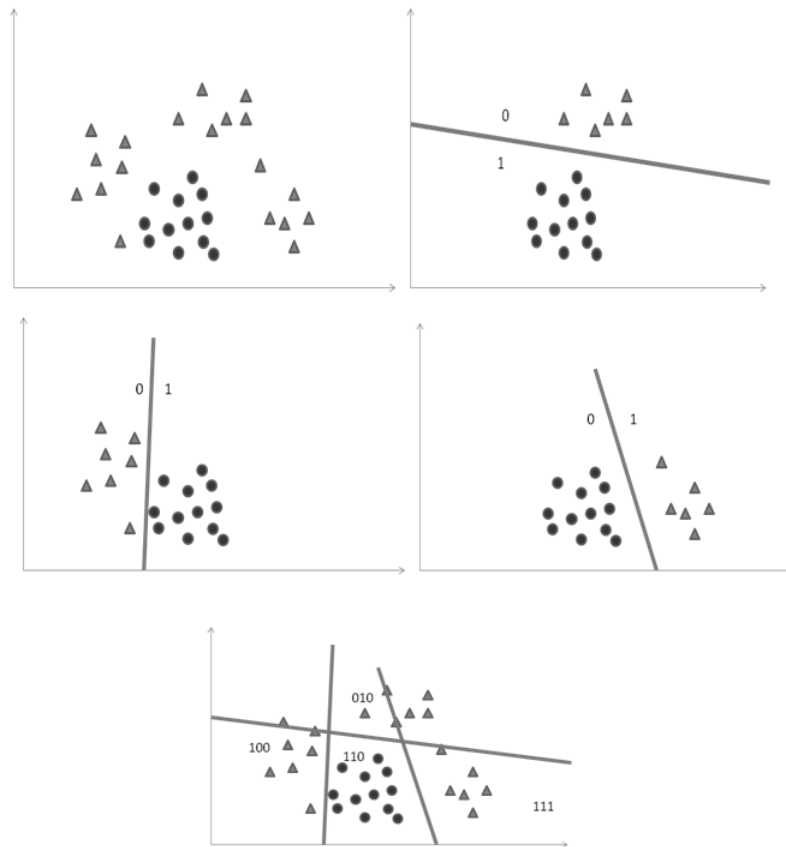
gdzie  $(d_i - y_i)$  to rozbieżność pomiędzy uzyskanymi  $y_i$  i oczekiwanymi  $d_i$  wynikami klasyfikacji danej próbki  $x_i$  dla zbioru przykładowego, a  $\eta$  to stała uczenia. Uczenie wielowarstwowych sieci neuronowych MLP odbywa się najczęściej za pomocą algorytmu wstecznej propagacji błędu (*error back-propagation*) omówionej dokładnie w pracach [100,101,106,72,75].

Już prosty neuron można uznać za liniowy klasyfikator, dzielący przestrzeń cech  $x$  za pomocą hiperpłaszczyzny, utworzonej za pomocą współczynników wagowych  $w$ . Nieliniowo separowalny problem może zostać rozłożony na kilka mniejszych podproblemów separowalnych liniowo, za pomocą pierwszej warstwy sieci neuronowej. Podproblemy mogą zostać złożone, dzięki kolejnej warstwie sieci neuronowej (rys 8.6). Dlatego, można przyjąć, że już sieć dwuwarstwowa powinna sobie poradzić z problemem nieseparowalnym liniowo.

Pozostaje problem doboru liczby neuronów w poszczególnych warstwach sieci, co nie jest zadaniem trywialnym. Przyjmuje się, że liczba neuronów w warstwie ukrytej  $N$  powinna być uzależniona od liczby sygnałów wejściowych do sieci pierwszej  $X$  i liczby wyjść z sieci ostatniej  $Y$ :

$$N = \sqrt{XY} \quad (8.3)$$

Bardzo ważnym elementem trenowania klasyfikatora jest zapewnienie wystarczająco licznego zbioru danych uczących, co w niektórych przypadkach jest dużym utrudnieniem. Autor podjął próbę wykorzystania sieci neuronowych dwuwarstwowych typu MLP do klasyfikacji sygnałów EEG. Dla różnej liczby sygnałów wejściowych (cech) proces doboru struktury sieci jest inny, co może stanowić problemem przy klasyfikacji sygnału EEG, gdzie liczba cech może ulegać zmianie.



Rys. 8.6. Klasyfikacja próbek nieseparowalnych liniowo w dwuwarstwowej sieci neuronowej

Dlatego też dla nowej liczby cech wejściowych wymagany jest dobór nowej struktury sieci (w szczególności liczby neuronów w warstwie ukrytej). Warto zauważyć, że problem ten praktycznie nie istniał w opisanych do tej pory metodach klasyfikacji jak: LDA, QDA, K-NN.


W swoich badaniach metod klasyfikacji sygnału EEG autor stosował losowy sposób, podziału dostępnych danych na trzy zbiory uczący, walidacyjny i testowy. Zbiór uczący wykorzystywany był bezpośrednio do modyfikacji wag sieci, przypadki walidacyjne pozwalały na bieżące monitorowanie procesu uczenia, zaś zbiór testowy służył do ponownej oceny jakości modelu, przeprowadzanej po zakończeniu procesu trenowania sieci.

Poniżej przedstawiono opis badań dotyczących klasyfikacji (3 klasy) sygnału EEG za pomocą sieci MLP, schematycznie przedstawionej na rysunku 8.7. Jako cechy zastosowano pierwiastek z energii 1-sekundowego odcinka sygnału EEG. Liczba danych (cech) uczących wynosiła 3824, a zbiory uczące dla wszystkich klas można uznać za równoliczne.

Liczba wejść pierwszej warstwy sieci wynosiła 32 (równoważna liczbie cech), a wyjść z drugiej sieci było 3 (trzy klasy). Liczba neuronów w warstwie ukrytej wynosiła  $N=30$  neuronów, stosownie do równania (8.3). Ideałem była by sytuacja, gdzie na każdym wyjściu




sieci, pojawiały by się wartości logiczne 1 lub 0. W rzeczywistości otrzymane wyniki będą liczbami z przedziału  $[0;1]$ .



Rys. 8.7. Schemat blokowy sieci neuronowej wykorzystanej w trakcie eksperymentów (Matlab)

W charakterze miary dopasowania wartości do etykiet otrzymywanych na wyjściach sieci, użyto błędu średniokwadratowego (*Mean Squared Error* - MSE). Sieć uczona była za pomocą algorytmu wstecznej propagacji błędu. Dane zostały podzielone na dane uczące, walidacyjne i testujące losowo w proporcjach: 70%, 15% i 15%. Jako funkcję aktywacji zastosowano tangens hiperboliczny dla warstwy ukrytej oraz funkcję liniową dla warstwy wyjściowej. Poniżej zaprezentowano przebieg trenowania sieci w postaci zależności błędu uczenia klasyfikatora dla kolejnych iteracji (rys 8.8).



Rys. 8.8. Przebieg uczenia sieci neuronowej (Matlab – opis rysunku generowany automatycznie)

Wyniki klasyfikacji dla trzech klas, opisane za pomocą tzw. macierzy pomyłek, zamieszczono w tabelach (8.7-8.8).


Tabela 8.7. Macierz pomyłek dla zbioru uczącego sieci neuronowej. Błąd całkowity 22,1%

MLP (30) Klasy przewidziane	Oryginalne klasy		
	K2	K3	K7
K2	436	86	113
K3	68	607	84
K7	104	62	744

Tabela 8.8. Macierz pomyłek dla zbioru testującego sieci neuronowej. Błąd całkowity 23,8%

MLP (30) Klasy przewidziane	Oryginalne klasy		
	K2	K3	K7
K2	137	33	35
K3	33	202	36
K7	29	16	244

Błąd całkowity dla zbioru testowego wyniósł 23.8% a uśredniony błąd dla wszystkich zbiorów: uczącego, walidacyjnego i testującego wyniósł 22.8%. Jak wspomniano, sygnały wyjściowe z sieci neuronowej są pewnymi liczbami ułamkowymi z przedziału  $[0;1]$ , a zatem trzeba ustawić pewną wartość progową, która zastąpi logiczną 1. W celu scharakteryzowania działania sieci neuronowej, dla różnych wartości progowych, zamieszczono przebiegi krzywych ROC<sup>9</sup> (rys. 8.9).




Rys. 8.9. Krzywe ROC dla 3 klas oraz różnych zbiorów danych (Matlab – opis rysunku generowany automatycznie)

<sup>9</sup> Krzywa ROC (*Receiver Operating Characteristic*) jest narzędziem do oceny poprawności klasyfikatora, zapewnia ona łączny opis jego właściwości (pojęcie zaczerpnięte z dziedziny radiolokacji)

Punktem idealnej klasyfikacji dla krzywych ROC jest punkt o współrzędnych (0,1). Krzywe są bardzo wyraźnie wygięte w stronę tego punktu, a zatem klasyfikatory neuronowe MLP działają całkiem sprawnie.

Kolejnym etapem prowadzonych badań był dobór liczby neuronów w warstwie ukrytej sieci neuronowej. Poniżej zaprezentowano wyniki dla przypadku  $N=10$  neuronów (rys. 8.10 i tab 8.9÷8.10. Przedstawiono również krzywe ROC (rys. 8.11).



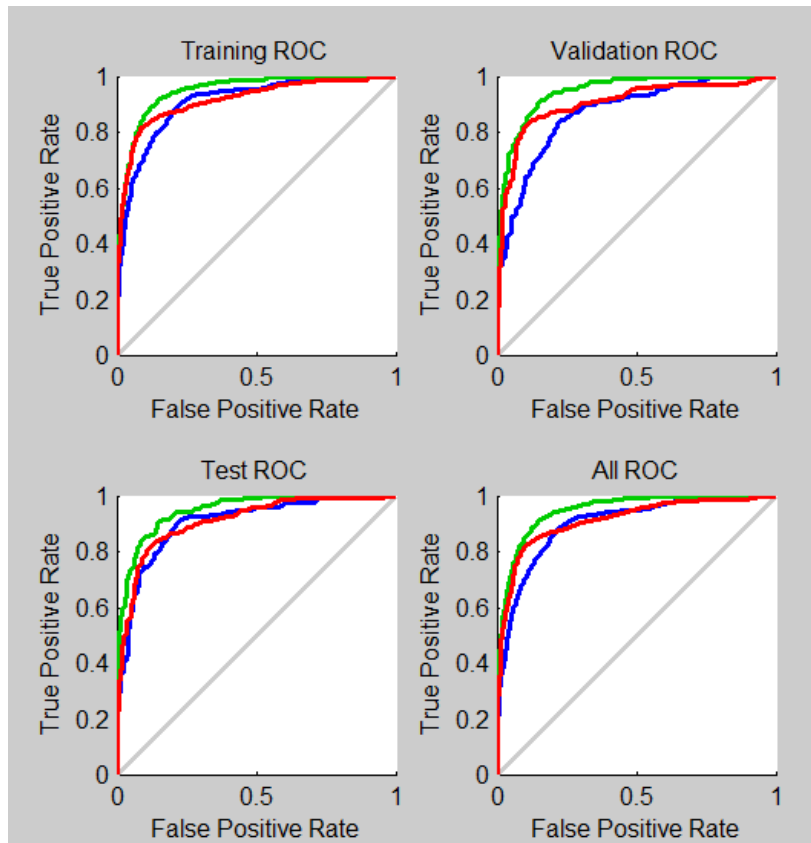
Rys. 8.10. Proces uczenia sieci neuronowej dla  $N=10$  liczby neuronów w warstwie ukrytej (Matlab – opis rysunku generowany automatycznie)

Tabela 8.9. Macierz pomyłek dla zbioru uczącego dla sieci neuronowej MLP (10). Błąd 19,2%

MLP (10)	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	440	65	99
K3	55	632	81
K7	103	38	781

Tabela 8.10. Macierz pomyłek dla zbioru uczącego dla sieci neuronowej MLP (10). Błąd 20,7%

MLP (10)	Oryginalne klasy		
Klasy przewidziane	K2	K3	K7
K2	144	22	33
K3	22	199	30
K7	37	14	264




Rys. 8.11. Krzywe ROC dla N=10 (Matlab – opis rysunku generowany automatycznie)

Pomimo że otrzymane wyniki klasyfikacji są całkiem zadowalające (błąd wynosił 20.7% dla danych testowych), to jednak warto podkreślić, że dość skomplikowane sieci neuronowe nie są najłatwiejszą drogą do klasyfikacji sygnału EEG na użytek interfejsu mózg-komputer. Przede wszystkim dlatego, że dobór liczby neuronów w warstwie ukrytej jest zależny od liczby użytych cech.

#### 8.4 Maszyna wektorów wspierających (SVM)


Ciekawym rozwiązaniem jest metoda klasyfikacji SVM (*Support Vector Machine*) zwana w języku polskim maszyną wektorów wspierających [72], metodą wektorów nośnych [75] lub po prostu siecią SVM [100]. Istotą metody SVM jest separacja zbioru próbek różnych klas za pomocą pewnej hiperpłaszczyzny. Umożliwia ona jednak również separację danych o dowolnej strukturze, nie tylko tych liniowo separowalnych. Ten problem rozwiązywany jest poprzez linearyzację zagadnienia rozpoznawania z powiększonym rozmiarem wektora cech. Istnieje wiele możliwości wyznaczenia hiperpłaszczyzny, ale jakość podziałów nie jest zawsze jednakowa (na rys. 8.12 po zredukowaniu do prostej.) Założeniem metody SVM jest

poszukiwanie takiej hiperpłaszczyzny, która zapewni najlepszy podział cech, a więc największy pas separacji, wewnątrz którego nie znajdują się żadne próbki.



Rys. 8.12. Zbiory danych można podzielić na wiele sposobów, ale tylko jeden jest optymalny

O szerokości pasa decydują próbki skrajne, na których podtrzymywany jest margines separacji. Próbki te nazywane są próbkami (wektorami) podtrzymującymi lub wektorami wspierającymi i stąd pochodzi nazwa metody (rys. 8.13).



Rys. 8.13. Poszukiwana prosta separująca wraz z marginesami - wektory położone najbliżej prostej separującej „podtrzymują” margines

Niech  $(x_i, z_i)$  stanowi zbiór par uczących dla  $i=1, 2, \dots, P$  poddawany klasyfikacji, gdzie  $x_i$  oznacza wektor wejściowy, a  $z_i$  wartość klasy równą 1 lub -1. Przy założeniu liniowej separowalności obu klas równanie hiperpłaszczyzny separującej dwie klasy może być zapisane w postaci:

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = 0 \quad (8.4)$$

gdzie  $\mathbf{w}=[w_1, w_2, \dots, w_N]^T$ ,  $\mathbf{x}=[x_1, x_2, \dots, x_N]^T$ . Wektor hiperpłaszczyzny  $\mathbf{w}$  jest  $N$  wymiarowy. Równania decyzyjne określające przynależność do klas przyjmują postać:

$$\begin{aligned} \mathbf{w}^T \mathbf{x}_i + b > 0 &\longrightarrow z_i = 1 \\ \mathbf{w}^T \mathbf{x}_i + b < 0 &\longrightarrow z_i = -1 \end{aligned} \quad (8.5)$$

Wektory podtrzymujące decydują o położeniu marginesów separacji oraz doborze prostej separującej. Warto zauważyć, że to właśnie one są najtrudniejsze do klasyfikacji. Analitycznym wyrażeniem przedstawionych wymagań (maksymalizacja szerokości marginesów separacji) jest funkcja kryterialna (z mnożnikami Lagrange'a -  $\alpha_i$ ) [101]:

$$C = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=0}^n \alpha_i (z_i (\mathbf{w}^T \mathbf{x}_i + b) - 1) \quad (8.6)$$

Poszukiwane są współczynniki  $\mathbf{w}$  oraz  $b$ , które maksymalizują funkcję kryterialną. Rolą nieujemnych mnożników Lagrange'a  $\alpha_i$  jest „karanie” za błędną klasyfikację próbek. Mnożniki Lagrange'a stanowią dodatkowe zmienne funkcji celu, trzeba więc określić kryterium ich doboru. Wyznaczenie optymalnej hiperpłaszczyzny podziału klas to proces analizy funkcji kryterialnej, która ma być maksymalizowana względem współczynników Lagrange'a, a minimalizowana względem poszukiwanej hiperpłaszczyzny. Większość praktycznych problemów rozróżnienia klas nie należy do zagadnień separowalnych w sposób liniowy. Dlatego, aby móc w pełni wykorzystać potencjał metody SVM, często stosuje się zwiększenie liczby przestrzeni cech za pomocą nieliniowego przekształcenia  $\varphi$ . Zwiększenie wymiarowości dziedziny zwiększa szansę na uzyskanie rozkładów danych, które umożliwią separację liniową. Trening i działanie klasyfikatorów SVM bazuje na wyznaczaniu iloczynów skalarnych przekształconych próbek  $\varphi(\mathbf{x})$ . Funkcję  $K(\mathbf{u}, \mathbf{v}) = \varphi^T(\mathbf{u})\varphi(\mathbf{v})$  nazywa się funkcją jądra (*kernel function*). To właśnie wprowadzeniu funkcji jądra metoda SVM zawdzięcza swoją skuteczność. Powszechnie zastosowanie znalazły funkcje jądra w postaci funkcji liniowych, wielomianów, funkcji radialnych lub sigmoidalnych. Zastosowanie odpowiedniej funkcji jądra zwiększa szansę na poprawienie separowalności danych oraz skuteczność klasyfikacji. Poniżej przedstawiono różne rodzaje funkcji jądra wraz z opisem (tabela 8.11).

Tabela 8.11. Typy jądra SVM

Typ jądra	Równanie	Uwagi
Liniowe	$K(\mathbf{u}, \mathbf{v}) = \mathbf{u}^T \mathbf{v} + \gamma$	$\gamma$ – dowolna wartość
Wielomianowe	$K(\mathbf{u}, \mathbf{v}) = (\mathbf{u}^T \mathbf{v} + \gamma)^p$	$p$ - stopień wielomianu
Radialne	$K(\mathbf{u}, \mathbf{v}) = \exp(-\gamma \ \mathbf{u} - \mathbf{v}\ ^2)$	$\gamma$ – wspólne dla wszystkich f. jądra
Sigmoidalne	$K(\mathbf{u}, \mathbf{v}) = \text{tgh}(\beta_1 \mathbf{u}^T \mathbf{v} + \beta_0)$	Ograniczenia na $\beta_0$ oraz $\beta_1$

W zasadzie, rozważania dotyczące SVM prowadzone do tej pory ograniczały się do dyskryminacji co najwyżej dwóch klas danych. Jednak, jak już wspomniano, problem klasyfikacji sygnału EEG na użytek interfejsu mózg-komputer, jest najczęściej zadaniem wieloklasowym (co najmniej 3 klasy). Dlatego też wprowadza się stosowne modyfikacje algorytmu SVM. Istnieje kilka strategii umożliwiających rozróżnienie większej liczby klas. Najpopularniejsze z nich to: jedna klasa przeciw jednej, jedna przeciw pozostałym oraz jedna przeciw wszystkim [110]. Autor wybrał strategię *jeden przeciw pozostałym*, w której podstawą jest znalezienie klasy za pomocą dzielenia danych na podzbiory (dziel i rządź). W zadaniu trzyklasowym w pierwszej kolejności testowana jest pierwsza klasa (1) przeciwko pozostałym (2+3); Jeśli wygra klasa (1) to próbka przydzielana jest do tej klasy; Jeśli nie wygra klasa (1) lecz pozostałe tzn. (2+3) wtedy testowane są kolejne klasy z podzbioru (2+3) czyli klasa (2) przeciwko (3). Prowadzi to do wyłonienia (jednego) zwycięzcy.

Autor przeprowadził badania przydatności metody SVM do klasyfikacji sygnałów EEG na użytek interfejsu mózg-komputer. Jako cechy zastosowano pierwiastek z wariancji sygnału EEG w paśmie 8Hz÷30Hz. Dane zostały podzielone na uczące (80%) i testujące (20%). Dodatkowo autor przebadął zastosowanie różnych funkcji jądra na jakość klasyfikacji dla danych uczących i testujących (tabele 8.12-8.19).

Tabela 8.12. Macierze pomyłek dla danych uczących SVM, liniowa funkcja jądra, całkowity błąd dla danych uczących 25,4%

Liniowe jądro SVM	Oryginalne klasy		
	K2	K3	K7
Klasy przewidziane			
K2	132	22	22
K3	53	210	67
K7	17	14	228

Tabela 8.13. Macierze pomyłek dla danych testujących SVM, liniowa funkcja jądra, całkowity błąd dla danych testujących = 27,3%

Liniowe jądro SVM	Oryginalne klasy		
	K2	K3	K7
Klasy przewidziane			
K2	31	6	9
K3	11	54	15
K7	9	3	56

Tabela 8.14. Macierze pomyłek dla danych uczących SVM, jądro dla wielomianu stopnia drugiego, całkowity błąd dla danych uczących = 0,13%

Wielomian 2 stopnia SVM	Oryginalne klasy		
	K2	K3	K7
Klasy przewidziane			
K2	201	0	0
K3	1	246	0
K7	0	0	317

## 8. KLASYFIKATORY EEG

Tabela 8.15. Macierze pomyłek dla danych testujących SVM, jądro dla wielomianu stopnia drugiego, całkowity błąd dla danych testujących = 13,4%

<b>Wielomian 2 stopnia SVM</b>	<b>Oryginalne klasy</b>		
<b>Klasy przewidziane</b>	K2	K3	K7
<b>K2</b>	44	3	8
<b>K3</b>	5	56	4
<b>K7</b>	2	4	68

Tabela 8.16. Macierze pomyłek dla danych uczących SVM, jądro wielomianu stopnia trzeciego stopnia, całkowity błąd dla danych uczących = 0%

<b>Wielomian 3 stopnia SVM</b>	<b>Oryginalne klasy</b>		
<b>Klasy przewidziane</b>	K2	K3	K7
<b>K2</b>	202	0	0
<b>K3</b>	0	264	0
<b>K7</b>	0	0	317

Tabela 8.17. Macierze pomyłek dla danych testujących SVM, jądro wielomianu stopnia trzeciego stopnia, całkowity błąd dla danych testujących = 17,5%

<b>Wielomian 3 stopnia SVM</b>	<b>Oryginalne klasy</b>		
<b>Klasy przewidziane</b>	K2	K3	K7
<b>K2</b>	39	5	8
<b>K3</b>	7	55	6
<b>K7</b>	5	3	66

Tabela 8.18. Macierze pomyłek dla danych uczących SVM, jądro RBF, Całkowity błąd dla danych uczących=0%

<b>RBF SVM</b>	<b>Oryginalne klasy</b>		
<b>Klasy przewidziane</b>	K2	K3	K7
<b>K2</b>	202	0	0
<b>K3</b>	0	264	0
<b>K7</b>	0	0	317

Tabela 8.19. Macierze pomyłek dla danych testujących SVM, jądro RBF, całkowity błąd dla danych testujących = 20,1%

<b>RBF SVM</b>	<b>Oryginalne klasy</b>		
<b>Klasy przewidziane</b>	K2	K3	K7
<b>K2</b>	29	4	3
<b>K3</b>	15	59	10
<b>K7</b>	7	0	67

Jak wskazują otrzymane wyniki klasyfikacji SVM, w przypadku cech w postaci energii sygnału, najlepiej sprawuje się klasyfikator z funkcją jądra w formie wielomian drugiego stopnia.

Inne przebadane funkcje jądra (RBF czy wielomianu trzeciego stopnia) również dobrze separują dane testujące, ale zbyt „dopasowują” się do zbioru treningowego i źle klasyfikują dane testujące. Ponadto na wyniki ma wpływ sposób podziału danych na uczące



i testujące. Być może przy innym podziale danych (cech) lub innej metodzie testowania (test krzyżowy walidacyjny) błędy te były mniejsze.

### **8.5 Inne parametry wpływające na trafność klasyfikacji**

Trafność i błąd klasyfikacji klasyfikatorów można stosunkowo prosto zmierzyć, jednak nie jest to jedyna forma oceny jakości systemów BCI. Inną bardziej praktyczną miarą (dedykowaną konkretnemu systemowi), możliwą do wykorzystania w trybie *on-line*, jest liczba liter (znaków) możliwych do napisania w wybranej jednostce czasu. Jak już wspomniano wcześniej związaną z nią, lecz bardziej ogólną miarą oceny interfejsów mózg-komputer jest tzw. współczynnik ITR (*Information Transfer Rate*).

Jednocześnie wiadomo, że im szersze okno czasowe analizy, tym lepsza trafność klasyfikacji, ale i tym większe opóźnienie w przekazaniu intencji maszynie. Powstaje pytanie, jak szerokie ma być okno czasowe i czy okna (tradycyjnie) powinny na siebie zachodzić. Większa liczba wspólnych próbek (silniejsze zachodzenie na siebie okien) pozwala na wygenerowanie dużej liczby przykładów, co z kolei ułatwia trenowanie klasyfikatora dla wybranej sesji użytkownika. Jednak dla nowych danych (nowej sesji użytkownika) może się okazać, że ten sposób prowadzi do tzw. „przetrenowania” klasyfikatora i daje duże błędy klasyfikacji.

Istotne jest wskazanie jak najlepszej strategii doboru parametrów okien czasowych tak na potrzeby wyznaczenia cech jak i trenowania klasyfikatora. Do oceny najlepszego rozwiązania posłużył błąd klasyfikacji wyliczony dla danych z zupełnie innej sesji niż ta, na której trenowano klasyfikator. Ważnym elementem było sprawdzenie zachowania się klasyfikatorów, takich jak K-NN i LDA.

Autor przeprowadził badania polegające na wyznaczeniu najlepszej szerokości  $T$  okna czasowego. Jako cechy zastosowano energię sygnału w paśmie 8Hz÷30Hz, dla każdej z elektrod. Użytkownik realizował 3 "zadania myślowe". Użyto 32 elektrod, więc z jednego okna sygnału zawsze ekstrahowane były 32 cechy, które posłużyły do trenowania i testowania klasyfikatorów K-NN oraz LDA.


Jak już wspomniano systemy BCI działają w dwóch trybach, kalibracji oraz eksploatacji. Na etapie kalibracji realizowane są: przetwarzanie sygnału, ekstrakcja cech, trenowanie klasyfikatora (po przeprowadzeniu jednej sesji). W trakcie eksploatacji systemu dokonywane są: przetwarzanie sygnału, ekstrakcja cech oraz klasyfikacja, która odbywa się przy

wykorzystaniu zupełnie nowych danych dla nowej sesji. Dlatego, w efekcie końcowym, istotna jest trafność klasyfikacji tych nowych danych.

Podczas eksperymentu, klasyfikator testowano na danych pochodzących z innej sesji niż dane użyte do treningu. Taka sytuacja będzie miała miejsce w rzeczywistości, w trakcie eksploatacji. W tabeli 8.20 przedstawiono wyniki obrazujące jak szerokość okna czasowego (wrażana w próbkach) wpływa na błąd klasyfikacji dla klasyfikatorów K-NN oraz LDA. Ponadto, dla klasyfikatora K-NN zamieszczono wartość współczynnika ITR dla nowej sesji użytkownika (rys.8.14). Wartość częstotliwości próbkowania wynosiła 512Hz, a okno czasowe było przesuwane co połowę jego szerokości (50% nakładanie).


Tabela 8.20. Wpływ szerokości okna czasowego na wyniki klasyfikacji oraz wartość współczynnika ITR dla K-NN. ( $f_s=512$  Hz)

Szerokość okna	Błąd LDA [%]	Błąd K-NN [%]	B	ITR [bit/min]
256	38,8	47,5	0,112	13,39
384	33,8	43,3	0,165	13,24
512	32,1	43,6	0,161	9,69
640	31,4	35,1	0,299	14,36
768	32,3	35,4	0,293	11,70
896	31,3	29,4	0,417	14,29
1024	31,2	33,3	0,333	10,00
1152	29,4	29,4	0,417	11,13
1280	30,0	31,6	0,369	8,87
1408	34,1	27,7	0,456	9,94
1536	37,1	30,8	0,386	7,71
1664	25,3	28,1	0,448	8,26
1792	29,9	25,5	0,510	8,74
1920	27,6	22,0	0,603	9,66
2048	36,1	25,2	0,518	7,77
2176	32,7	22,1	0,601	8,49
2304	25,5	23,6	0,561	7,48
2432	27,7	17,8	0,731	9,23
2560	30,5	23,2	0,573	6,87
2688	26,1	25,0	0,524	5,98
2816	20,7	26,4	0,487	5,32
2944	37,3	20,5	0,649	6,77
3072	21,3	16,3	0,782	7,82
3200	28,6	16,9	0,761	7,31
3328	37,8	13,5	0,878	8,11
3456	16,9	15,5	0,808	7,18
3584	52,9	20,0	0,663	5,68
3712	20,9	16,4	0,777	6,43
3840	48,4	15,6	0,803	6,43
3968	24,2	11,3	0,963	7,46
4096	36,7	15,0	0,825	6,19
4224	49,2	18,6	0,705	5,12
4352	38,6	12,3	0,925	6,53
4480	30,4	14,3	0,850	5,83
4608	25,9	13,0	0,899	5,99
4736	57,7	15,4	0,812	5,27
4864	47,1	15,7	0,801	5,06
4992	42,0	14,0	0,861	5,30
5120	50,0	10,4	0,999	5,99



Rys. 8.14. Zależność wartości współczynnika ITR od szerokości okna czasowego dla K-NN

Kolejny etap badań miał na celu sprawdzenie jak na jakość klasyfikacji oraz wartość ITR wpływa stopień nakładania okien czasowych podczas trenowania klasyfikatora. W tym celu wybrano okno czasowe (1024 próbki) i generowano cechy przesuwając okno co 32 próbki. Następnie zwiększono stopień nakładania o kolejne 32 próbki itd. Wyniki zamieszczono w tabeli 8.21 oraz na rysunku 8.15.



Rys. 8.15. Zależność wartości współczynnika ITR od stopnia nakładania okien czasowych dla K-NN

Tabela 8.21. Wpływ stopnia nakładania okien czasowych na wyniki klasyfikacji oraz wartość współczynnika ITR dla K-NN


Nakładanie okna	Błąd LDA [%]	Błąd K-NN [%]	B	ITR [bit/min]
32	31,0	31,2	0,378	11,33
64	31,3	30,5	0,392	11,75
96	31,6	31,3	0,374	11,23
128	31,5	27,0	0,474	14,22
160	32,3	27,9	0,452	13,55
192	30,7	31,4	0,374	11,21
224	30,8	28,8	0,431	12,94
256	33,0	27,5	0,462	13,85
288	30,4	32,8	0,345	10,34
320	32,7	27,4	0,463	13,89
352	34,5	26,1	0,496	14,88
384	30,7	31,3	0,375	11,24
416	30,8	30,1	0,401	12,02
448	30,5	27,6	0,460	13,79
480	30,8	28,5	0,439	13,16
512	31,2	33,3	0,333	10,00
544	31,7	31,3	0,376	11,29
576	32,2	31,8	0,366	10,97
608	29,5	31,0	0,382	11,45
640	31,6	31,6	0,369	11,08
672	32,4	35,2	0,298	8,93
704	34,7	24,3	0,543	16,28
736	32,7	37,0	0,265	7,94
768	36,5	35,8	0,285	8,55
800	36,2	31,6	0,369	11,08
832	32,2	31,5	0,371	11,13
864	32,6	32,6	0,348	10,43
896	29,9	25,5	0,510	15,29
928	31,1	32,6	0,349	10,46
960	28,3	32,3	0,355	10,64
992	32,5	39,0	0,230	6,89
1024	37,8	35,3	0,295	8,86

W pracy zamieszczono wyniki tylko dla jednego użytkownika, jednak podobne błędy i trendy pojawiały się dla pozostałych. Okazało się, że największą wartość ITR (w bitach na minutę) otrzymuje się dla okien o najmniejszej szerokości (im węższe okno, tym więcej możliwych wyborów w jednostce czasu), ale błąd klasyfikacji jest wtedy stosunkowo duży. Jednak w opinii autora, wydaje się być sensowne stosowanie krótszych okien czasowych nawet kosztem jakości klasyfikacji. Należy jednak pamiętać, że podczas przeprowadzania eksperymentu użytkownicy (w niektórych przypadkach – dla wąskich okien czasowych) realizowali zadania myślowe dłużej niż czas trwania okna czasowego, co mogło mieć wpływ na wyniki. Ponadto należy brać pod uwagę, że użytkownicy mogą mieć trudności z szybką realizacją nowych zadań myślowych. Dlatego, sensowne wydaje się być stosowanie okien czasowych trwających jedną sekundę.


Ekspertyzy dotyczące stopnia nakładania okien nie pozwalają wysnuć jednoznacznych wniosków. Nie zaobserwowano znaczącego trendu w zakresie błędu klasyfikacji zależnego od

stopnia nakładania okien (rys. 8.16). Podczas testowania klasyfikatora 10-krotnym testem krzyżowym zwiększanie stopnia nakładania okien znacznie poprawiało trafność klasyfikacji podczas trenowania, jednak nie przekładało się to na wartość błędu klasyfikacji dla testowanych danych. Oczywiście należy pamiętać, że zarówno trafność klasyfikacji jak i ITR obliczane były tylko dla jednego typu cech, pierwiastek z wariancji sygnału.

Średni błąd dla wszystkich szerokości okien czasowych, podczas testowania klasyfikatorów wynosił 33,8% dla klasyfikatora LDA oraz 23,7% dla klasyfikatora K-NN. Dlatego można stwierdzić, że klasyfikator K-NN lepiej nadaje się do klasyfikacji cech występujących pod postacią pierwiastka z wariancji sygnału (rys. 8.16-8.17).



Rys. 8.16. Zależność wartości błędu klasyfikacji (LDA) od szerokości okna czasowego analizy



Rys. 8.17. Zależność wartości błędu klasyfikacji (K-NN) od szerokości okna czasowego analizy

---

## 9. EKSPERYMENTY FINALNE

---

W poprzednich rozdziałach opisano, w sposób krytyczny oraz wnikliwy, algorytmy przetwarzania, analizy i klasyfikacji sygnału EEG stosowane w autorskich pracach do konstruowania asynchronicznych interfejsów mózg-komputer. Przedstawiono też częściowe wyniki, z sugestią, które cechy oraz stowarzyszone z nimi elektrody wnoszą najwięcej do procesu klasyfikacji sygnału EEG. Okazało się, że najlepsze cechy oraz rozmieszczenie elektrod zdeterminowane są nie tylko poprzez rodzaje zadań myślowych (wyobrażeń ruchu), ale również poprzez psychofizyczne i anatomiczne różnice międzyosobnicze.

Jednym z głównych zadań pracy było przebadanie algorytmów przetwarzania, ekstrakcji i selekcji cech dla znacząco ograniczonego zbioru elektrod, w stosunku do zestawu pełnego, 32-elektrodowego. Istotne było pytanie dotyczące liczby oraz rozmieszczenia elektrod. Wyniki eksperymentów przeprowadzone na pełnym zbiorze elektrod, opisane w poprzednich rozdziałach rozprawy, z użyciem wybranych algorytmów ekstrakcji oraz selekcji cech (a także klasyfikacji) umożliwiły, w mniemaniu autora, wskazanie najlepszych elektrod. Pozostawało pytanie do ilu elektrod można ograniczyć ich zbiór. Autor zdecydował się na ograniczenie zbioru do ośmiu elektrod. Liczba ta wybrana została zarówno na podstawie przeprowadzonych eksperymentów jak i teoretycznej wiedzy neuropsychologicznej. Z praktycznego punktu widzenia warto wspomnieć, że na rynku dostępne są wzmacniacze z liczbą kanałów równą wielokrotności ośmiu. Poniżej zaprezentowano tabelę wskazującą, które elektrody zostały wyselekcjonowane podczas eksperymentów, a które elektrody wskazywane są przez wiedzę neuropsychologiczną i założenia systemu BCI2000 [131] (tabela 9.1). Podano również liczbę wystąpień (suma) danej elektrody w zastosowanych metodach selekcji cech. Uwzględniono wyłącznie elektrody, które wybrane zostały przynajmniej w jednej z metod. Szarym tłem zaznaczono elektrody wybrane przez autora do dalszych eksperymentów. Kolejny etap badań to uruchomienie uprzednio wybranych metod przetwarzania, ekstrakcji i klasyfikacji sygnału EEG dla wyselekcjonowanego, ograniczonego zbioru elektrod. Celem sprawdzenia, czy metody przetwarzania wstępnego poprawiają jakość sygnałów został przebadany sygnał EEG bez przetwarzania wstępnego dla wybranych 8 elektrod.

Tabela 9.1 Wykaz elektrod wybranych podczas eksperymentów z różnymi metodami ekstrakcji i selekcji cech

Nr elektrody	Nazwa	BCI2000	GA DWT	GA FFT	SFS VAR	Suma
1	Fp1				+	1
4	F3	+				1
7	T7	+				1
8	C3	+	+		+	3
9	CP1		+	+	+	3
10	CP5			+		1
13	Pz	+				1
17	O2				+	1
22	CP2			+		1
23	C4	+	+	+	+	4
24	T8	+			+	2
26	FC2				+	1
27	F4	+				1
32	Cz	+	+		+	3

Wszystkie eksperymenty zostały wykonane z użyciem algorytmów opisanych w poprzednich rozdziałach. Celem syntetycznego opisu całego toru przetwarzania, analizy i klasyfikacji sygnału EEG, autor posłużył się skrótami zamieszczonymi w tabeli 9.2.

Tabela 9.2 Oznaczenia wykorzystywanych algorytmów

Nr	Nazwa	Skrót
1	Wybielanie sygnału	SW
2	Analiza składowych niezależnych	ICA
3	<i>Common Spatial Pattern</i>	CSP
<b>Nr</b>		
<b>Nazwa</b>		
<b>Skrót</b>		
4	Energia sygnału	VAR
5	Dyskretne przekształcenie Fouriera	FFT
6	Dyskretna transformata Fouriera + Statystyki Wyższych rzędów	DWT/HOS
7	Model AR	AR
<b>Nr</b>		
<b>Nazwa</b>		
<b>Skrót</b>		
8	K-Fisher	K
9	t-statystyki	t
10	Sekwencyjne przeszukiwanie w przód	SFS
11	Algorytmy genetyczne	GA
<b>Nr</b>		
<b>Nazwa</b>		
<b>Skrót</b>		
12	Klasyfikator najbliższego sąsiada	K-NN
13	Liniowa analiza dyskryminacyjna	LDA
14	Kwadraturowa analiza dyskryminacyjna	QDA
15	Sieci neuronowe	MLP
16	Maszyna wektorów wspierających	SVM

## 9.1 Ograniczenie liczby elektrod

W celu sprawdzenia na ile ograniczenie do liczby 8 elektrod pogarsza trafność klasyfikacji, porównano błędy uzyskane dla kompletu wszystkich 32 elektrod oraz 8 wyselekcjonowanych. Jako cechy stosowano energię sygnału w paśmie 8Hz÷30Hz. Użyto klasyfikatora najbliższego sąsiedztwa (10-NN). Zastosowano 10-krotny test krzyżowy. Syntetyczne zestawienie eksperymentów zamieszczono w tabeli 9.3.

Tabela 9.3 Syntetyczne zestawienie eksperymentów dla sprawdzenia czy wyselekcjonowane elektrody wystarczą do poprawnej klasyfikacji

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
32	Brak	VAR	Brak	K-NN
8	Brak	VAR	Brak	K-NN

W tabeli 9.4 zaprezentowano wyniki z zastosowaniem całego zbioru 32 elektrod oraz wyselekcjonowanych 8 elektrod. Zaprezentowane wyniki zawierają wykaz błędów klasyfikacji dla 3 sesji pojedynczego użytkownika. Podobne błędy otrzymano dla innych użytkowników.

Tabela 9.4 Błąd klasyfikacji dla 32 oraz 8 elektrod

Liczba elektrod	Użytkownik pierwszy		
	Sesja 1	Sesja 2	Sesja 3
32	0,6%	0,7%	0,5%
8	4,5%	4,1%	3,5%

Wyniki wskazują, że zbiór 8 elektrod pozwala na klasyfikację z zaledwie 4% błędem. Jest to bardzo mały błąd, dlatego można uznać, że 8 elektrod wystarcza do wykrycia w sygnale EEG i skutecznej klasyfikacji wybranych zdarzeń (zadań myślowych). Ponadto, należy uwzględnić fakt, że użytkownik może nauczyć się właściwego generowania potencjałów poprzez *neurofeedback*.

## 9.2 Przetwarzanie wstępne

Kolejnym przeprowadzonym eksperymentem było sprawdzenie, czy metody przetwarzania wstępnego wpływają na jakość klasyfikacji sygnału EEG, dla ograniczonego zbioru elektrod. Badaniu poddano następujące metody: wybielanie sygnału (SW), analizę składowych niezależnych (ICA) oraz wspólne wzorce przestrzenne (CSP). Jako cechy wykorzystano energię sygnału EEG z zakresu 8Hz÷30Hz. W celu generowania cech zastosowano okno 1-



sekundowe przesuwane co 62.5 ms. Klasyfikator 10-NN testowano z użyciem 10-krotnego testu krzyżowego. Wykaz eksperymentów zawarty jest w tabeli 9.5.

Tabela 9.5 Eksperymenty sprawdzające metody przetwarzania wstępnego

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	<b>brak</b>	VAR	Brak	K-NN
8	<b>WS</b>	VAR	Brak	K-NN
8	<b>ICA</b>	VAR	Brak	K-NN
8	<b>CSP 6</b>	VAR	Brak	K-NN
8	<b>CSP 24</b>	VAR	Brak	K-NN

Wyniki klasyfikacji, dla trzech sesji jednego użytkownika, zawarto w tabeli 9.6. Podobne wyniki klasyfikacji otrzymano dla pozostałych użytkowników. Do wyznaczenia składowych niezależnych (ICA) zastosowano algorytm *Fixed-Point*. Metodę CSP zastosowano dla ograniczonego zbioru 8 elektrod. W wyniku działania algorytmu CSP powstało 8 składowych (osiem nowych sygnałów). Składowe CSP wyznaczano poprzez rozróżnienie par klas K2-K3, K2-K7 oraz K3-K7. Otrzymano w ten sposób 24 składowe (CSP24). Autor przebadął również algorytm CSP dla 2 najlepszych składowych, dla każdej pary, co dało 6 składowych (CSP6). Wyniki przeprowadzonych eksperymentów przedstawiono w tabeli 9.6.

Tabela 9.6 Wyniki eksperymentów dla 8 elektrod i różnych metod przetwarzania wstępnego

Metoda przetwarzania wstępnego	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>brak</b>	4,5%	4,4%	3,5%	<b>4,2%</b>
<b>WS</b>	4,4%	3,5%	2,3%	3,4%
<b>ICA</b>	2,2%	1,5%	2,8%	<b>2,2%</b>
<b>CSP6</b>	15,1%	10,8%	9,9%	11,9%
<b>CSP24</b>	1,1%	1,5%	1,5%	<b>1,4%</b>

Zawartość tabeli 9.6 wskazuje, że każda z przebadanych metod przetwarzania wstępnego (z wyjątkiem CSP6) poprawia wyniki klasyfikacji. Na uwagę zasługuje analiza składowych niezależnych (ICA), która pomimo niewielkiej liczby elektrod pozwoliła na otrzymanie nowych, rozseparowanych sygnałów. Poprawiło to wyniki klasyfikacji dwukrotnie. Jeszcze lepsza okazała się metoda wspólnych wzorców przestrzennych (CSP). Dla metody CSP 24 błędy klasyfikacji zmalały prawie czterokrotnie.

Na otrzymane wyniki niewątpliwie ma wpływ połączenie konkretnej metody ekstrakcji cech z konkretną metodą klasyfikacji. Proporcje, a nawet same wyniki, mogą zmieniać się dla innych metod ekstrakcji. Poniżej przebadano wpływ metod przetwarzania wstępnego dla innego sposobu generowania cech to jest okna trwającego sekundę, ale przesuwanego co 0,5

sekundy. Takie wyniki klasyfikacji dla testu K-NN są zbliżone do wyników eksperymentów prowadzonych w czasie rzeczywistym (*on-line*). W kontekście powyższych uwag przeprowadzono eksperymenty w innych warunkach ekstrakcji cech. Okno czasowe przesuwane było co 0,5 sekundy. Wyniki otrzymane podczas eksperymentów zawiera tabela 9.7.

Tabela 9.7 Błąd klasyfikacji dla okna przesuwanego co 1/2 sekundy dla klasyfikatora K-NN

Metoda przetwarzania wstępnego	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>brak</b>	31,1%	27,1%	27,1%	<b>28,4%</b>
<b>WS</b>	30,4%	24,5%	21,2%	25,3%
<b>ICA</b>	25,8%	20,6%	26,1%	<b>24,1%</b>
<b>CSP6</b>	43,5%	36,1%	37,9%	39,1%
<b>CSP24</b>	29,3%	23,4%	23,4%	<b>25,3%</b>

W tym przypadku, metody przetwarzania wstępnego również spełniły swoją rolę. Najlepsze okazały się ICA oraz CSP24. Następnym etapem było sprawdzenie jak zmieniają się wyniki dla innej metody klasyfikacji. W tym etapie jako klasyfikator zastosowano liniową analizę dyskryminacyjną (LDA). Wykaz eksperymentów zawiera tabela 9.8, zaś wyniki eksperymentów zebrano w tabeli 9.9.

Tabela 9.8 Wykaz eksperymentów z nakładaniem okien co 1/2 sekundy i klasyfikatorem LDA

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	<b>brak</b>	VAR	Brak	LDA
8	<b>WS</b>	VAR	Brak	LDA
8	<b>ICA</b>	VAR	Brak	LDA
8	<b>CSP 6</b>	VAR	Brak	LDA
8	<b>CSP 24</b>	VAR	Brak	LDA

Tabela 9.9 Błąd klasyfikacji dla klasyfikatora LDA i różnych metod przetwarzania wstępnego

Metoda przetwarzania wstępnego	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>brak</b>	34,5%	30,6%	27,5%	<b>30,9%</b>
<b>WS</b>	31,7%	28,0%	23,4%	27,7%
<b>ICA</b>	26,2%	21,8%	31,7%	<b>26,6%</b>
<b>CSP 6</b>	36,9%	34,3%	38,5%	36,6%
<b>CSP 24</b>	29,1%	26,0%	18,8%	<b>24,6%</b>

Widać, że w tym przypadku najlepiej wypadają metody przetwarzania wstępnego takie jak ICA oraz CSP24. Zatem można uznać za zasadne stwierdzenie, że w przypadku energii sygnału w paśmie 8Hz÷30Hz warto stosować wybrane metody przetwarzania wstępnego.

Poprawę wyników uzyskano dla różnych klasyfikatorów oraz różnych sposobów nakładania okien czasowych. Bardzo podobne wyniki otrzymano dla pozostałych użytkowników (te same trendy zmian).

### 9.3 Ekstrakcja cech

W poprzednich eksperymentach w charakterze cech wykorzystywano energię sygnału (wariancja) w paśmie 8Hz÷30Hz. W opinii autora warto powtórzyć wspomniane eksperymenty dla innych metod ekstrakcji cech. Co może pozwolić na wskazanie najlepszej metody spośród wytypowanych.

Jako metodę selekcji cech zastosowano sekwencyjne przeszukiwanie w przód (SFS), a jako metodę klasyfikacji kwadraturową funkcje dyskryminacyjną (QDA). W metodzie SFS wybierano 40 najlepszych cech. Przebadano kilka metod ekstrakcji cech takich jak VAR, FFT, DWT/HOS czy AR. Rząd modelu AR wynosił 16. W metodzie DWT/HOS zastosowano falkę db4 oraz 7 poziomów dekompozycji i wyznaczano 3 HOS: skośność, wariancję i kurtozę. Prążki FFT ograniczono od 8Hz do 30 Hz. Wykaz nowych eksperymentów zawiera tabela 9.10, zaś uzyskane wyniki zebrano w tabelach 9.11÷9.13.

Tabela 9.10 Wykaz eksperymentów z różnymi metodami przetwarzania wstępnego oraz różnymi metodami ekstrakcji cech dla klasyfikatora QDA

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	<b>VAR</b>	SFS	QDA
8	brak	<b>FFT</b>	SFS	QDA
8	brak	<b>DWT/HOS</b>	SFS	QDA
8	brak	<b>AR</b>	SFS	QDA
8	ICA	<b>VAR</b>	SFS	QDA
8	ICA	<b>FFT</b>	SFS	QDA
8	ICA	<b>DWT/HOS</b>	SFS	QDA
8	ICA	<b>AR</b>	SFS	QDA
8	CSP 24	<b>VAR</b>	SFS	QDA
8	CSP 24	<b>FFT</b>	SFS	QDA
8	CSP 24	<b>DWT/HOS</b>	SFS	QDA
8	CSP 24	<b>AR</b>	SFS	QDA

Tabela 9.11 Błędy klasyfikacji dla wybranego użytkownika dla sygnału bez przetwarzania wstępnego.

Brak przetwarzania wstępnego	Użytkownik pierwszy			
	Sesja 1	Sesja 2	Sesja 3	Średnia
<b>VAR</b>	34,5%	28,6%	24,2%	<b>29,1%</b>
<b>FFT</b>	25,9%	19,2%	18,1%	<b>21,1%</b>
<b>AR</b>	51,4%	47,2%	45,4%	48,0%
<b>DWT/HOS</b>	22,3%	21,2%	21,0%	<b>21,5%</b>

Tabela 9.12 Błędy klasyfikacji dla wybranego użytkownika dla sygnału po zastosowaniu ICA

ICA	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>VAR</b>	25,8%	19,7%	28,2%	<b>24,5%</b>
<b>FFT</b>	24,3%	14,6%	20,6%	<b>19,8%</b>
<b>AR</b>	56,3%	50,5%	47,6%	51,5%
<b>DWT/HOS</b>	27,7%	20,1%	22,1%	<b>23,3%</b>

Tabela 9.13 Błędy klasyfikacji dla wybranego użytkownika dla sygnału po zastosowaniu CSP 24

CSP 24	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>VAR</b>	26,2%	21,8%	19,4	<b>22,5%</b>
<b>FFT</b>	25,7%	19,0%	18,8	<b>21,2%</b>
<b>DWT/HOS</b>	20,1%	19,2%	19,5	<b>19,6%</b>

Przedstawione wyniki wskazują, że metoda FFT oraz DWT/HOS polepsza jakość klasyfikacji w porównaniu z wariancją sygnału w charakterze cech. Dotyczy to sygnału bez przetwarzania wstępnego, ale i sygnału po przetworzeniu za pomocą metod ICA i CSP. Model AR rzędu 16 nie sprawdza się dla okna trwającego 1 sekundę. Bardzo podobne wyniki otrzymano dla innych użytkowników.

## 9.4 Selekcja cech

W następnym etapie badań autor przeprowadził eksperymenty mające na celu wykrycie wpływu selekcji cech (za pomocą przekształceń) na trafność klasyfikacji. Jako metodę selekcji cech zastosowano liniową analizę dyskryminacyjną (LDA), generującą nowe wektory cech. Liczba cech została dobrana eksperymentalnie. W eksperymencie przebadano metody LDA dla sygnału bez przetwarzania wstępnego oraz z przetwarzaniem metodą ICA. W każdym z przypadków jako pierwotne cechy, wykorzystano współczynniki FFT oraz statystyki wyższych rzędów na detalach transformaty falkowej (DWT/HOS). Liczba cech (w formie nowych składowych) wynosiła 2 dla FFT i 3 dla DWT/HOS, bowiem przy takiej liczbie składowych błąd klasyfikacji był najmniejszy. Na wstępie do klasyfikacji użyto algorytmu K-NN. Błąd klasyfikacji sprawdzano z użyciem 10-krotnego testu krzyżowego. Wykaz eksperymentów zawarto w tabeli 9.14, zaś otrzymane wyniki klasyfikacji zaprezentowano w tabelach 9.15 oraz 9.16.

Na rysunku 9.1 przedstawiono zależność błędu klasyfikacji od liczby użytych (kolejnych) składowych LDA w procesie selekcji cech. Najmniejszy błąd klasyfikacji występował dla dwu pierwszych składowych (FFT jako cechy).

Tabela 9.14 Wykaz eksperymentów do oceny czy metoda rzutowania LDA, selekcji cech, poprawia trafność klasyfikacji


Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	FFT	LDA	K-NN
8	brak	DWT/HOS	LDA	K-NN
8	ICA	FFT	LDA	K-NN
8	ICA	DWT/HOS	LDA	K-NN

Tabela 9.15 Błąd klasyfikacji dla zastosowanej metody LDA jako selekcji cech (bez przetwarzania wstępnego)

Bez preprocesingu	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	5,7%	3,3%	5,3%	4,8%
<b>DWT/HOS</b>	11,5%	10,4%	10,2%	10,7%

Tabela 9.16 Błąd klasyfikacji dla zastosowanej metody LDA jako selekcji cech (ICA)

ICA	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	8,6%	3,1%	6,2%	5,9%
<b>DWT/HOS</b>	13,3%	7,7%	9,1%	10,1%



Rys. 9. 1. Błąd klasyfikacji w zależności od liczby składowych LDA wybranych do klasyfikacji

Następnie, przy tych samych założeniach wstępnych użyto do klasyfikacji liniowej analizy dyskryminacyjnej (LDA) w miejsce K-NN. Wykaz eksperymentów zamieszczono w tabeli tabela 9.17, zaś uzyskane wyniki zawarto w tabelach 9.18 i 9.19. Z kolei na rysunku 9.2 zaprezentowano rozkład cech dla 3 klas po zastosowaniu metody LDA, w charakterze selektora. Warto podkreślić, przy okazji, że cechy po tej transformacji umożliwiają nawet wizualną klasyfikację.

Tabela 9.17 Wykaz eksperymentów z zastosowaniem metody LDA do klasyfikacji


Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	FFT	LDA	LDA
8	brak	DWT/HOS	LDA	LDA
8	ICA	FFT	LDA	LDA
8	ICA	DWT/HOS	LDA	LDA

Tabela 9.18 Błąd klasyfikacji dla LDA

Bez przetwarzania wstępnego	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	6,4%	3,9%	5,1%	5,1%
<b>DWT/HOS</b>	12,2%	9,5%	9,3%	10,3%

Tabela 9.19 Błąd klasyfikacji dla LDA

Przetwarzanie wstępne: ICA	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	7,3%	3,5%	6,8%	5,9%
<b>DWT/HOS</b>	14,1%	6,2%	9,7%	10,1%



Rys. 9. 2. Rozkład cech FFT: 8Hz÷30 Hz, po selekcji z LDA dla dwóch składowych - łatwiej separowalne

Wyniki jednoznacznie obrazują, że metoda LDA generuje nowe, bardziej separowalne cechy i znacząco poprawia trafność klasyfikacji. Najlepsze wyniki osiągnięto dla cech FFT: 8Hz÷30Hz (z rozdzielczością 1 Hz). Przy czym nie ma wielkiej różnicy w błędach klasyfikacji dla sygnałów bez przetwarzania wstępnego oraz z przetwarzaniem (metoda ICA).

## 9.5 Klasyfikacja

Wszystkie, poprzednio opisane eksperymenty, odbywały się z użyciem 10-krotnego testu krzyżowego. Takie podejście, choć jest bardzo wygodne i powszechnie stosowane, odbiega od rzeczywistości. Jak już wspomniano wcześniej, w trakcie eksploatacji systemów BCI wstępny zbiór rejestrowanych sygnałów wykorzystuje się do kalibracji systemu, a następnie uruchamia się system dla danych rejestrowanych na bieżąco. Dlatego, sensownym wydaje się być sprawdzenie działania wybranych algorytmów klasyfikacji w trybie trenowania na pewnej liczbie dostępnych danych, w wymiarze 80% całości, oraz testowania na pozostałej części, w wymiarze 20%. Wykaz zaproponowanych eksperymentów, z wykorzystaniem t-statystyk w charakterze selektora cech, zawiera tabela 9.20 dla klasyfikatora K-NN oraz tabela 9.21 dla klasyfikatora SVM. Uzyskane wyniki klasyfikacji, dla dwu różnych metod ekstrakcji cech i dla danych z podziałem: 80% - trenowanie, 20% - testowanie, zaprezentowano w tabelach 9.22÷9.27.

Tabela 9.20 Wykaz eksperymentów dla klasyfikatora K-NN

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	FFT	t-statystyki	<b>K-NN</b>
8	brak	DWT/HOS	t-statystyki	<b>K-NN</b>
8	ICA	FFT	t-statystyki	<b>K-NN</b>
8	ICA	DWT/HOS	t-statystyki	<b>K-NN</b>
8	CSP 24	FFT	t-statystyki	<b>K-NN</b>
8	CSP 24	DWT/HOS	t-statystyki	<b>K-NN</b>

Tabela 9.21 Wykaz eksperymentów dla klasyfikatora SVM

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	FFT	t-statystyki	<b>SVM</b>
8	brak	DWT/HOS	t-statystyki	<b>SVM</b>
8	ICA	FFT	t-statystyki	<b>SVM</b>
8	ICA	DWT/HOS	t-statystyki	<b>SVM</b>
8	CSP 24	FFT	t-statystyki	<b>SVM</b>
8	CSP 24	DWT/HOS	t-statystyki	<b>SVM</b>

Tabela 9.22 Błędy klasyfikacji dla metody SVM bez wstępnego przetwarzania danych

Ekstrakcja cech	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	35,4%	25,8%	44,1%	35,1%
<b>DWT/HOS</b>	33,3%	27,9%	54,8%	38,7%

Tabela 9.23 Błędy klasyfikacji dla metody SVM z przetwarzaniem wstępnym (ICA)

Ekstrakcja cech	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	41,9%	8,6%	45,1%	31,9%
<b>DWT/HOS</b>	41,9%	12,9%	46,2%	33,7%

Tabela 9.24 Błędy klasyfikacji dla metody SVM z przetwarzaniem wstępnym (CSP24)

Ekstrakcja cech	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	3,4%	21,5%	45,1%	33,6%
<b>DWT/HOS</b>	4,8%	21,5%	38,7%	33,6%

Tabela 9.25 Błędy klasyfikacji dla metody K-NN bez wstępnego przetwarzania danych

Ekstrakcja cech	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	34,4%	23,6%	31,1%	29,7%
<b>DWT/HOS</b>	40,8%	29,0%	36,5%	35,4%

Tabela 9.26 Błędy klasyfikacji dla metody K-NN z przetwarzaniem wstępnym (ICA)

Ekstrakcja cech	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	38,7%	18,2%	35,4%	30,8%
<b>DWT/HOS</b>	63,4%	20,4%	40,8%	41,5%

Tabela 9.27 Błędy klasyfikacji dla metody K-NN dla z przetwarzaniem wstępnym (CSP24)

Ekstrakcja cech	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>FFT</b>	36,5%	26,8%	32,2%	31,9%
<b>DWT/HOS</b>	48,3%	27,9%	33,3%	36,5%

Jak wskazują otrzymane wyniki, w tym trybie testowania klasyfikatora, bliższym rzeczywistości, otrzymuje się nieco gorsze wyniki klasyfikacji w porównaniu do testu krzyżowego 10-krotnego. Ponadto, w tym przypadku nie stwierdzono poprawy trafności klasyfikacji po zastosowaniu różnych metod przetwarzania wstępnego.

Te same eksperymenty dla klasyfikatora SVM z liniową funkcją jądra, przeprowadzono z innym rodzajem selekcji cech: liniowa analiza dyskryminacyjna (LDA) w miejsce t-statystyk. Wykaz zaproponowanych eksperymentów zawiera tabela 9.28, a wyniki zebrane są w tabeli 9.29. Wyniki wskazują znaczącą poprawę trafności klasyfikacji po zastosowaniu transformacji LDA. Dotyczy to zarówno algorytmu z przetwarzaniem wstępnym ICA oraz algorytmu bez przetwarzania wstępnego.

Ostatnim elementem, na etapie badań dotyczących klasyfikacji, było sprawdzenie klasyfikatora K-NN działającego na danych po selekcji LDA. Wykaz eksperymentów zawiera tabela 9.30, a wyniki tabela 9.31.



Tabela 9.28 Wykaz eksperymentów dla klasyfikatora SVM z LDA w roli selekcji cech

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	FFT	LDA	SVM
8	ICA	FFT	LDA	SVM

Tabela 9.29 Błędy klasyfikacji dla metody SVM z LDA w roli selekcji cech

FFT	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
Brak	10,7%	4,3%	10,7%	8,6%
ICA	18,2%	5,3%	13,9%	12,5%

Tabela 9.30 Wykaz eksperymentów dla klasyfikatora K-NN z LDA w roli selekcji cech

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	FFT	LDA	K-NN
8	ICA	FFT	LDA	K-NN

Tabela 9.31 Błędy klasyfikacji dla metody K-NN z LDA w roli selekcji cech

FFT	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
Brak	7,5%	3,2%	9,6%	6,8%
ICA	12,9%	5,3%	8,6%	8,9%

Jak wskazują otrzymane wyniki wszystkie klasyfikatory spełniły swoje zadanie. Najlepiej, nawet dla rzeczywistego podziału danych: uczące 80% i testujące 20%, wypada połączenie klasyfikatora K-NN z metodą ekstrakcji cech w postaci FFT: 8Hz÷30H oraz selekcji w postaci LDA. Bardzo dobrze w roli klasyfikatora spisuje się algorytm K-NN.

## 9.6 Badania kompleksowe dla wszystkich użytkowników

Prezentowane do tej pory (w wersji ilościowej) wyniki eksperymentów dotyczyły tylko jednego wybranego (pierwszego) użytkownika. Wyniki zawarte w tym punkcie obrazują działanie interfejsu dla wszystkich użytkowników oraz wszystkich sesji. Wykaz eksperymentów zawiera tabela 9.32. Celem tego badania było sprawdzenie, czy wyselekcjonowane elektrody oraz opracowane kombinacje algorytmów przetwarzania danych wpływają na poprawę trafności klasyfikacji dla wszystkich (dostępnych w bazie) użytkowników. Otrzymane wyniki zaprezentowano w tabelach 9.32÷9.35. Wyniki nie są zebrane w postaci macierzy błędów, a występuje jedynie błąd całkowity. W opinii autora, takie przedstawianie rezultatów jest bardziej czytelne.

Tabela 9.32 Wykaz eksperymentów dla wszystkich użytkowników i wszystkich sesji

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	FFT	LDA	SVM
8	brak	FFT	LDA	K-NN

Tabela 9.33 Błąd klasyfikacji dla użytkownika pierwszego

Klasyfikator	Użytkownik pierwszy			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>SVM</b>	10,7%	4,3%	10,7%	8,6%
<b>K-NN</b>	7,5%	3,2%	9,6%	6,8%

Tabela 9.34 Błąd klasyfikacji dla użytkownika drugiego

Klasyfikator	Użytkownik drugi			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>SVM</b>	8,5%	4,3%	5,3%	6,1%
<b>K-NN</b>	13,8%	4,3%	10,7%	9,6%

Tabela 9.35 Błąd klasyfikacji dla użytkownika trzeciego

Klasyfikator	Użytkownik trzeci			Średnia
	Sesja 1	Sesja 2	Sesja 3	
<b>SVM</b>	15,1%	12,7%	17,2%	15,0%
<b>K-NN</b>	10,7%	9,5%	17,2%	12,5%

Na podstawie zamieszczonych wyników, dla systemu ośmioelektrodowego, można stwierdzić, że opracowane połączenie algorytmu FFT jako ekstrakcji cech, LDA jako selekcji cech oraz SVM lub K-NN jako klasyfikatora spełnia doskonale swoje zadanie. Uzyskuje się wystarczająco małe błędy klasyfikacji dla wszystkich użytkowników. Warto zauważyć, że otrzymane wyniki dotyczą klasyfikacji danych pobieranych sekwencyjnie z zaledwie 1-sekundowego zapisu EEG. Gdyby uśrednić trzy okna, nawet na siebie zachodzące, błędy wyszłyby zapewne o wiele mniejsze. Obniżyłoby to jednak wartość współczynnika ITR. Z kolei sesja z *neurofeedbackiem* mogłaby znacząco usprawnić sposób generowania danych przez użytkownika i poprawić trafność klasyfikacji.

## 9.7 Eksperymenty na danych własnych

Wszystkie opisane dotychczas eksperymenty prowadzone były z wykorzystaniem ogólnodostępnej bazy danych [93]. Dlatego też, kolejnym ważnym etapem badań było zarejestrowanie danych pochodzących od dwu użytkowników MK oraz AM, dla tego samego trybu pracy interfejsu (ERD/ERS), z wykorzystaniem własnego rejestratora i porównanie wyników klasyfikacji. Sposób zebrania własnych danych doświadczalnych został opisany w rozdziale dotyczącym akwizycji sygnału. Wykaz eksperymentów zamieszczono w tabeli

9.36. Zastosowano klasyfikatory 10-NN oraz SVM z liniową funkcją jądra. Podział zbioru na dane uczące i testujące dokonany został w proporcji 80% do 20%.

Tabela 9.36 Wykaz eksperymentów na danych własnych

Zbiór EEG	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
EEG 8	brak	FFT	LDA	SVM
EEG 8	brak	FFT	LDA	K-NN

Tabela 9.37 Błąd klasyfikacji dla badań na danych własnych autora

Klasyfikator	Użytkownik MK		Średnia
	Sesja 1	Sesja 2	
<b>SVM</b>	19,3%	15,0%	17,2%
<b>K-NN</b>	17,2%	9,6%	13,4%

Tabela 9.38 Błąd klasyfikacji dla badań na danych własnych autora

Klasyfikator	Użytkownik AM		Średnia
	Sesja 1	Sesja 2	
<b>SVM</b>	22,5%	12,9%	17,7%
<b>K-NN</b>	17,2%	10,7%	13,9%

Zaprezentowane wyniki (tabele 9.37-9.38) wskazują, że dla danych zarejestrowanych przez autora opracowane algorytmy spełniają swoje zadanie. Pomimo, że sygnał EEG, dla użytkownika AM, zawierał dużą liczbę artefaktów (wpływ sygnału EKG), klasyfikacja nie odbiega znacząco od obserwowanej dla użytkownika MK.

W dotychczasowych eksperymentach do obliczenia składowych LDA wykorzystywano cały zbiór danych. Taka sytuacja nie będzie miała miejsca w rzeczywistości. Dlatego należy się spodziewać, że wyniki trafności działania systemu w czasie rzeczywistym (*on-line*) będą gorsze. Następnym testem było sprawdzenie algorytmu w przypadku, gdy tylko połowa próbek jest użyta od obliczenia składowych LDA. Szczegóły dotyczące eksperymentu zawiera tabela 9.39. Wyniki klasyfikacji, dla danych z podziałem w proporcjach 80% do 20% (uczące-testujące) zawarto w tabeli 9.40.

Tabela 9.39 Etapy eksperymentu z selekcją LDA na ograniczonym zbiorze danych (80%)

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	FFT	LDA	<b>K-NN</b>

Choć błędy wychodzą faktycznie wyższe, to są one zbliżone do rzeczywistych i wynoszą średnio 25,5% dla użytkownika MK. Podobne błędy otrzymano dla użytkownika AM. Kolejny algorytm przebadany na danych własnych zawierał metodę FFT do ekstrakcji cech,

metodę SFS do ich selekcji, klasyfikator QDA z 10-krotnym testem krzyżowym. Opis eksperymentu zawiera tabela 9.41.

Tabela 9.40 Błąd klasyfikacji dla eksperymentu z selekcją LDA na ograniczonym zbiorze danych (80%)

Klasyfikator	Użytkownik MK		
	Sesja 1	Sesja 2	Średnia
<b>K-NN</b>	28,4%	22,7%	25,5%

Tabela 9.41 Eksperyment autorski – ekstrakcja FFT, selekcja SFS, klasyfikacja QDA

Liczba elektrod	Przetwarzanie wstępne	Ekstrakcja	Selekcja	Klasyfikacja
8	brak	<b>FFT</b>	SFS	QDA

Wyniki eksperymentów dla wszystkich zarejestrowanych sygnałów EEG przedstawiono w tabeli 9.42 oraz 9.43.

Tabela 9.42 Błąd klasyfikacji dla badań autora użytkownik MK

Klasyfikator	Użytkownik MK		
	Sesja 1	Sesja 2	Średnia
<b>QDA</b>	32,6%	25,9%	29,3%

Tabela 9.43 Błąd klasyfikacji dla badań autora - użytkownik AM

Klasyfikator	Użytkownik AM		
	Sesja 1	Sesja 2	Średnia
<b>QDA</b>	32,4%	34,7%	33,5%

Wyniki w tabelach 9.42 i 9.43 pokazują, że za pomocą zaledwie 1-sekundowego okna czasowego, z sygnału EEG zarejestrowanego za pomocą 8 elektrod możliwe jest wydobywanie informacji umożliwiającej całkiem skuteczną klasyfikację (średnio 29,3% dla użytkownika MK oraz 33,5% dla użytkownika AM). Błąd klasyfikacji dla klasyfikatora działającego w sposób losowy powinien wynosić 66,6%. Warto podkreślić, że zarejestrowane we własnym zakresie sygnały EEG zawierały artefakty, które znacząco zakłócały sygnał EEG.

## 9.8 Wnioski z eksperymentów *off-line*

Podczas eksperymentów realizowanych w ramach niniejszej pracy wykorzystano kombinację wielu starannie wyselekcjonowanych algorytmów do przetwarzania wstępnego sygnału EEG, ekstrakcji cech, selekcji cech oraz ich klasyfikacji. Autorowi nie jest znane tak szeroko ujęte zastosowanie różnych algorytmów do przetwarzania tego samego sygnału EEG.

Nie było możliwe przeprowadzenie wszystkich kombinacji algorytmów, ponieważ liczba takich kombinacji sięga kilkuset. Dlatego autor wybrał kilkanaście kombinacji algorytmów, które dawały nadzieję na skuteczną klasyfikację sygnału EEG. Podczas wstępnych eksperymentów autor posługiwał się sygnałami z ogólnodostępnej bazy danych (32 elektrody). Wykorzystane sygnały pochodziły z bazy danych przygotowanej na użytek jednego z konkursów BCI [93]. Dane te pozwoliły na wyselekcjonowanie za pomocą skomplikowanych narzędzi uczenia maszynowego kilku najlepszych cech i stowarzyszonych z nimi elektrod. Następnie autor przebadął wybrane algorytmy przetwarzania i analizy sygnału na ograniczonym zbiorze 8 elektrod i wskazał wpływ wybranych metod na jakość klasyfikacji.


Okazało się jednak, że wyniki uzyskane przez uczestników konkursu są bardzo trudne do wykorzystania w trybie porównawczym, właśnie z powodu subtelnych różnic w stosowanych algorytmach przetwarzania sygnału, nie do końca ujawnionych. Jedno jest pewne, zwycięzca konkursu uzyskał średni wynik dla wszystkich trzech użytkowników na poziomie 31.3% z wykorzystaniem pełnego zbioru sygnałów [26], pochodzących ze wszystkich 32 elektrod. Podobne wyniki autor uzyskał wykorzystując zaledwie 8, skrupulatnie wybranych elektrod.

Ostatnim elementem badań był test z własnymi sygnałami na ograniczonej liczbie elektrod. Opracowane algorytmy pozwoliły na skuteczną klasyfikację sygnału EEG. Przeprowadzone eksperymenty wykazały, że dla ograniczonego zbioru elektrod lepsze wyniki klasyfikacji dają metody ekstrakcji cech takie jak FFT czy DWT/HOS niż VAR (energia sygnału). Okazało się również, że poprawę wyników klasyfikacji daje użycie liniowej analizy dyskryminacyjnej, w charakterze selektora cech.

Warto pamiętać, że ograniczenie zbioru elektrod nastąpiło na podstawie badań dla kilku użytkowników z rejestracją sygnałów z 32 elektrod. Zaobserwowano niewielkie zmiany położenia najlepszych elektrod dla różnych użytkowników. Dlatego celowe wydaje się opracowanie procedury rejestracji sygnału EEG z większą liczbą elektrod, a następnie przeprowadzenie etapu selekcji elektrod dla konkretnego użytkownika. Na tak wybranym zbiorze elektrod należałoby przeprowadzić ponowny etap „douczenia” interfejsu mózg-komputer. W kolejnej fazie użytkownik, z pomocą *neurofeedbacku*, uczyłby się generowania "lepszych" potencjałów w sygnale EEG. Po kilkunastu sesjach możliwe było by właściwe działanie interfejsu mózg-komputer (eksploatacja).

## 9.9 Eksperymenty w czasie rzeczywistym

Przeprowadzone eksperymenty w trybie *off-line* umożliwiły wybranie najlepszych elementów toru przetwarzania, analizy i klasyfikacji sygnału. W końcowym etapie autor podjął się trudnego zadania implementacji wybranego toru działającego w czasie rzeczywistym (*on-line*) dla interfejsu asynchronicznego. Do implementacji został wybrany tor składający się z: modułu akwizycji sygnału, filtracji pasmowoprzepustowej (0,1Hz÷40Hz), ekstrakcji cech (FFT 8Hz÷40Hz) i klasyfikatora najbliższego sąsiedztwa (1-NN). Akwizycja obejmowała rejestrację sygnału EEG z wyselekcjonowanych uprzednio 8 elektrod: F3, T7, C3, CP1, C4, T8, F4 oraz Cz. Rejestracji tej dokonywano z użyciem aktywnych elektrod i profesjonalnego wzmacniacza (patrz dodatek D1). Częstotliwość próbkowania wynosiła  $f_s=256\text{Hz}$ . Zarejestrowane dane, poprzez interfejs USB 2.0, przekazywane były do komputera klasy PC. Głównym elementem systemu było oprogramowanie BCI2000 wraz z zaimplementowanymi przez autora skryptami programu Matlab (rys 9.3). Sterowanie wszystkimi modułami zapewniał system BCI2000.



Rys. 9. 3. Implementacja wybranego algorytmu działającego w czasie rzeczywistym

Pierwszym elementem przetwarzania było przefiltrowanie sygnału w celu usunięcia zakłóceń sieciowych 50Hz i niektórych artefaktów. Następnie, przefiltrowany sygnał w postaci macierzy (32 próbek×8 kanałów) przekazywany był do zaimplementowanych przez autora modułów (funkcje Matlab). Pierwszy zaimplementowany moduł zawierał blok buforowania danych w celu tworzenia 1-sekundowego okna, przekazywanego do modułu ekstrakcji cech. Z użyciem funkcji FFT liczono prążki widma w zakresie 8Hz÷30Hz, które posłużyły jako cechy. Liczba uzyskanych cech wynosiła 184 (8 kanałów×23 cechy). Wektor cech przekazywany był do modułu klasyfikacji, z użyciem klasyfikatora najbliższego sąsiedztwa (1-NN). Jak zwykle, przed uruchomieniem trybu eksploatacji, była uruchomiona sesja kalibracyjna z identycznymi modułami.

W celu weryfikacji działania algorytmu, w czasie rzeczywistym, autor przeprowadził szereg eksperymentów. W pierwszym etapie uruchomiono i przetestowano algorytm na sygnałach symulowanych oraz sygnałach rzeczywistych zebranych za pomocą wzmacniacza. Podczas eksperymentów okazało się, że istotny wpływ na czas wykonywania algorytmów ma rozmiar bufora. W sposób doświadczalny stwierdzono, że optymalny rozmiar bufora wynosi 32 (32 próbki dla każdego z 8 kanałów). Umożliwia to działanie systemu w czasie rzeczywistym, bez opóźnień. Uzyskana szybkość odświeżania interfejsu użytkownika wynosiła 0,125 sekundy.


Test eksploatacji systemu, w czasie rzeczywistym, przeprowadzony został dla zupełnie nowego użytkownika, oznaczonego jako MC. Użytkownik MC nie uczestniczył w procesie prototypowania systemu (*off-line*) i nie miał żadnego doświadczenia z interfejsami mózg-komputer. Na początku doświadczeń został on poinformowany o celu prowadzenia eksperymentu i zadaniach użytkownika w trakcie jego trwania. W pierwszym etapie przeprowadzona została sesja kalibracyjna. Zadaniem użytkownika była realizacja następujących procesów myślowych:

1. Wyobrażenie sobie ruchu lewą ręką (klasa K2)
2. Wyobrażenie sobie ruchu prawą ręką (klasa K3)
3. Wyobrażanie sobie wypowiedzania słów na losowo wybraną literę (klasa K7).

Wykonano tylko 1 sesję kalibracyjną, trwającą około 4 minuty. Użytkownik realizował zadanie przez około 15 sekund, po czym następowała sekundowa przerwa, a następnie losowa zmiana zadania na inne. Polecenia dla użytkownika pojawiały się w formie strzałek na ekranie monitora. Strzałka skierowana w prawą stronę oznaczała zadanie pierwsze (klasa K3), w lewą stronę zadanie drugie (klasa K2), a strzałka skierowana do góry zadanie trzecie (klasa K7).

Do testowania systemu, w czasie rzeczywistym, wykorzystano interfejs aplikacji BCI2000. Zadaniem użytkownika MC, było sterowanie ruchem piłeczki (kursora) na ekranie monitora, tak aby osiągnęła jeden z dwu celów (rys 9.4). W założeniu autora: wyobrażanie ruchu prawą ręką - miało powodować ruch piłeczki w górę, wyobrażanie ruchu lewą ręką - miało powodować ruch piłeczki w dół, wyobrażanie wypowiedzania słowa - miało nie powodować zmiany położenia piłki w pozycji pionowej. W kierunku poziomym piłeczka poruszała się ze stałą prędkością. Na skierowanie piłeczki do odpowiedniego obszaru (celu) użytkownik miał 5 sekund. Próba powtarzana była wielokrotnie. Średnia skuteczność osiągnięcia celu wynosiła 81,8%. Autor postawił (przewrotną) hipotezę, "że wybór celów jest losowy i poprawna klasyfikacja na poziomie większym niż 80% jest tylko przypadkiem". Okazało się jednak, że

oszacowana istotność wyników była na poziomie  $p=0,0327$  i była mniejsza od konwencjonalnego poziomu istotności 0,05. Pozwoliło to na podważanie hipotezy. Innymi słowy szansa na to, że osiągnięte wyniki były przypadkiem wynosi 3,27%.



Rys. 9. 4. Interfejs graficzny użytkownika testowanego systemu

Opracowany interfejs był rzeczywistym testem algorytmów. Zasadniczym przeznaczeniem takiego interfejsu jest nauka uruchamiania procesów myślowych (trening) w taki sposób, aby uzyskać w sygnale EEG najbardziej przydatne potencjały do procesu klasyfikacji (*neurofeedback*).



---

## 10. ZAKOŃCZENIE

---

Rozpatrywany w rozprawie asynchroniczny interfejs mózg-komputer jest jednym z trudniejszych wyzwań współczesnej nauki. Świadczą o tym liczne publikacje w czasopismach naukowych jak i ogólne zainteresowanie mediów. Możliwość bezpośredniej interakcji człowieka z komputerem (bez manualnej obsługi urządzeń peryferyjnych) otwiera nowe kanały przekazu informacji w medycynie, psychologii, technikach multimedialnych i wojskowych. Szczególne znaczenie mają tutaj zastosowania tego interfejsu w medycynie zarówno w aspekcie poznawczym, funkcjonowania ludzkiego mózgu, jak i praktycznym, jako jedyna szansa rozwoju dla osób dotkniętych chorobami neurologicznymi. Interfejs mózg-komputer może pomóc w komunikacji ze światem zewnętrznym osobom w ciężkich stadiach takich chorób neurologicznych jak stwardnienie zanikowe boczne, udar mózgowy podkorowy, zespół Guillain-Barre'a, mózgowe porażenie dziecięce czy stwardnienie rozsiane.

Autor, w sposób odpowiednio szeroki, poruszył w pracy problemy przetwarzania, analizy i klasyfikacji sygnału EEG na użytek interfejsu mózg-komputer. Opracował algorytmy, które pozwalają na wskazanie najlepszych cech i skojarzonych z nimi elektrod. Przeprowadził badania na wyselekcjonowanych elektrodach i zaproponował, jego zdaniem, najlepszy tor przetwarzania sygnału EEG. Otrzymane wyniki pozwoliły udowodnić, że postawiona na początku pracy teza jest prawdziwa, *„odpowiedni dobór algorytmów przetwarzania analizy i klasyfikacji sygnału EEG pozwala na znaczące ograniczenie liczby elektrod do kilku na użytek asynchronicznego interfejsu mózg-komputer”*. Takie zmniejszenie liczby elektrod pozwala na konstrukcję wyspecjalizowanych, tańszych wzmacniaczy o mniejszej liczbie kanałów. Dla ograniczonego zbioru elektrod łatwiejsze jest również stosowanie kosztownych, suchych elektrod.

Ważnym elementem jest opracowanie efektywnych algorytmów automatycznej selekcji cech i klasyfikacji sygnału EEG. Umożliwia to uproszczenie systemu BCI, dzięki czemu osoba asystująca przy interfejsie, nie będzie musiała posiadać wiedzy dotyczącej analizy sygnału.

Na drodze do skonstruowania jeszcze bardziej skutecznie działającego interfejsu mózg-komputer stoją wciąż pewne problemy:

- Klasyczny pomiar sygnału EEG wymaga pracochłonnego oklejania głowy elektrodami, z użyciem specjalnych żelów, dla uzyskania odpowiednio niskiej rezystancji kontaktu skóra-elektroda.
- Niezależnie od jakości elektrod, sygnały docierające z mózgu do powierzchni czaszki mają bardzo małe poziomy amplitud, rzędu kilku mikrowoltów i narażone są na szumy oraz zakłócenia. Wydobycie sygnałów z szumu oraz pozbycie się zakłóceń jest zadaniem niezwykle trudnym.
- Sygnał EEG jest nieliniową sumą elektrycznego śladu ogromnej liczby jednoczesnych procesów zachodzących w mózgu. Dlatego ekstrakcja informacji użytecznej do sterowania maszyną wymaga nie tylko wiedzy o tych procesach, ale też zaawansowanych algorytmów analizy i klasyfikacji sygnałów oraz relatywnie dużych mocy obliczeniowych do realizacji BCI w czasie rzeczywistym.

Badania nad asynchronicznymi interfejsami mózg-komputer bez wątplenia wymagają dalszej pracy naukowców z wielu różnych dziedzin. Autor również zamierza kontynuować rozpoczęte prace nad interfejsem mózg-komputer. Ważnym elementem będzie przetestowanie systemu na większej liczbie osób, w tym osób sparaliżowanych, w różnych stadiach ich chorób. Autor postara się również opracować jeszcze bardziej efektywne algorytmy i zaimplementować je w środowisku LabWindows/CVI, celem uzyskania bardziej przyjaznego interfejsu graficznego. Dalsze prace powinny również obejmować prototypowanie i budowę dedykowanego, kilkukanałowego wzmacniacza EEG. Prace w tym kierunku zostały już podjęte. Wszystkie te zamierzenia podyktowane są również próbą uzyskania jak najmniejszych kosztów realizacji systemu.

---

# BIBLIOGRAFIA

---

- [1] Anderson C. W., Effects of Variations in Neural Network Topology and Output Averaging on the Discrimination of Mental Tasks from Spontaneous Electroencephalogram, *J. Int. Systems*, Volume 7 (1997).
- [2] Anderson C.W., Stolz E.A., Shamsunder S., Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks, *IEEE Transactions on Biomedical Engineering*, 45 (1998).
- [3] Augustyniak P., Transformacje falkowe w zastosowaniach elektrodiagnostycznych, ISBN: 83-89388-10-3 AGH (2003).
- [4] Birbaumer N., Kubler A., Ghanayim N., Hinterberger T., Perelmouter J., Kaiser J., Iversen I., Kotchoubey B., Neumann N., Flor H., The Thought Translation Device (TTD) for Completely Paralyzed Patients. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 8 (2000).
- [5] Boulgouris N. V., Plataniotis K. N., Micheli-Tzanakou E., *Biometrics: Theory, Methods, and Applications*, ISBN: 978-0-470-24782-2 Wiley-IEEE Press (2009).
- [6] By Yijun Wang, Xiaorong Gao, Bo Hong , Chuan Jia, Shangkai Gao, Brain-Computer Interfaces Based on Visual Evoked Potentials, *IEEE Engineering in Medicine and Biology Magazine* 27 (2008).
- [7] Cester I., Dunne S., Riera A., Ruffini G., ENOBIO: Wearable, Wireless, 4-channel electrophysiology recording system optimized for dry electrodes. (2006)
- [8] Chanan S., Randy S., Harnarinesingh E.S., Comparison of Pre-Processing and Classification Techniques for Single-Trial and Multi-Trial P300-Based Brain Computer Interfaces, *American Journal of Applied Sciences* 7 (2010).
- [9] Cichocki A. Amari S., *Adaptive Blind Signal and Image Processing*, ISBN:0470845899, (2002).
- [10] Cieślak-Blinowska K., Ginter J., Kamiński M., Kuś R., Multivariate autoregressive model in study of brain dynamics and causal relations between EEG signals, *Materials of Conference on Modeling Mental Processes and Disorders*, (2004)
- [11] Cieślak-Blinowska K., Ginter J., Kuś R., Information transfer during motor task and its imagination, *World Congress on Medical Physics and Biomedical Engineering* (2006).
- [12] Cieślak-Blinowska K., Kuś R., Maciej Kamiński, Joanna Janiszewska Transmission of brain activity during cognitive task, *Brain Topography* 23 (2010).
- [13] Cochin S., Barthelemy C., Lejeune B., Roux S., Martineau J. Perception of motion and qEEG activity in human adults. *Electroencephalogr Clin Neurophysiol*, 107 (1998).
- [14] Cochin S., Barthelemy C., Roux S., Martineau J. Observation and execution of movement: similarities demonstrated by quantified electroencephalography. *Eur J Neurosci*, 11 (1999).
- [15] Cohen-Seat, G. Gastaut, H., Faure J., Heuyer, G. Etudes experimentales de l'activite nerveuse pendant la projection cinematographique. *Rev. Int. Filmologie*, (1954).

- [16] Culpepper J., Discriminating Mental States Using EEG Represented by Power Spectral Density Department of Computer Science, Bioinformatics and Biomedical Engineering, (2008).
- [17] Cunnington, R., Iansak, R., Johnson, K. A., Bradshaw, J. L., Movement-related potentials in Parkinson's disease - Motor imagery and movement preparation, *Brain*, 120 (1997).
- [18] Ding J., Sperling G., Srinivasan R., Attentional modulation of SSVEP power depends on the network tagged by the flicker frequency, *Cereb Cortex*. 16 (2006).
- [19] Durka P., Finding significant correlates of conscious activity in rhythmic EEG, *Eurasip Journal on Applied Signal Processing*, (2005).
- [20] Durka P., Ircha D., Neuper C., Pfurtscheller G., Time-frequency microstructure of event-related EEG desynchronization and synchronization, *Medical & Biological Engineering & Computing* (2001).
- [21] Durka P., Jędrzejewski-Szmek Z., Dobaczewski M., Zito T., Kulewski K., Michalska M., Open projects for brain-computer interfaces and signal analysis: BCI.fuw.edu.pl and SignalML.org, *Frontiers in Neuroinformatics*(2009).
- [22] Durka P., Kuś R., Żygierewicz J., Milanowski, Garcia G., High-frequency SSVEP responses parametrized by multichannel matching pursuit *Frontiers in Neuroinformatics*. Conference Abstract: 2nd INCF Congress of Neuroinformatics (2009).
- [23] Durka P., Żygierewicz J., Klekowicz H., Ginter J., Cieślak-Blinowska K., On the statistical significance of event-related EEG desynchronization and synchronization in the time-frequency plane, *IEEE Transactions On Biomedical Engineering* 51 (2004).
- [24] Ehlers L., Phillips E., Sween A., Slawewski C. J., Event-Related Potential Responses To Alcohol-Related Stimuli In African–American Young Adults: Relation To Family History Of Alcoholism And Drug Usage *Cindy*, *Alcohol & Alcoholism* 38 (2003).
- [25] Farwell L.A., Donchin E., Talking off the top of your head: A mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neuro-physiology*, 70 (1998).
- [26] Galan F., Oliva F., BCI Competition III. Data Set V: Algorithm Description (2005).
- [27] Garcia G.N., Ebrahimi T., Vesin J.-M., Joint Time-Frequency-Space Classification of EEG in a Brain-Computer Interface Application, *EURASIP Journal on Applied Signal Processing*, (2003).
- [28] Garcia G.N., Hoffmann U., Ebrahimi T., Vesin J.-M., Direct Brain-Computer Communication through EEG Signals. To appear in *IEEE EMBS Book Series on Neural Engineering*, (2004).
- [29] Gastaut H. J., Bert, J. EEG changes during cinematographic presentation. *Electroencephalogr. Clin. Neurophysiol* 6, (1954).
- [30] Gilliam D. S., Discrete Fourier Transform, Department of Mathematics Texas Tech University, (1990).
- [31] Ginter J., Cieślak-Blinowska K., Kamiński M., Durka P., Pfurtscheller G, Neuper C., Propagation of EEG Activity in the Beta and Gamma Band during Movement Imagery in Humans, *METHODS OF INFORMATION IN MEDICINE* 44 (2005).
- [32] Glass A., Kwiatkowski A. W., Power spectral density changes in the EEG during mental arithmetic and eye-opening, *Psychological Research Volume* 33, (2011).
- [33] Golub G. H., *Matrix Computations*, Johns Hopkins University Press, ISBN 978-0-8018-5414-9 (1996).

- [34] Grossman A., Inbar G. F., Movement-related potentials during the performance of a motor task II: Cerebral areas activated during learning of the task, *Biological Cybernetics* 85 (2001).
- [35] Guangyu Bin, Xiaorong Gao, Yijun Wang, Bo Hong, Shangkai Gao, VEP-based brain-computer interfaces: time, frequency, and code modulations, *Computational Intelligence Magazine, IEEE*, (2009).
- [36] Guger C., Ramoser H., Pfurtscheller G., Real-Time EEG Analysis with Subject-Specific Spatial Patterns for a Brain-Computer Interface (BCI), *IEEE Transactions On Rehabilitation Engineering* 8, (2000).
- [37] Guyon I., Elisseeff A., An Introduction to Variable and Feature Selection, *Journal of Machine Learning Research* 3 (2003).
- [38] Gyeonghwan Kim, Sekwang Kim, Feature Selection Using Genetic Algorithms for Handwritten Character Recognition, (2000).
- [39] Heung-II Suk, Seong-Whan Lee, Subject and Class Specific Frequency Bands Selection for Multiclass Motor Imagery Classification, *International Journal of Imaging Systems and Technology* 21 (2011).
- [40] Huang E., Cheng S. H., Dressman H., Pittman J., Mei-Hua Tsou, Cheng-Fang Horng, Bild Edwin E., Iversen S., Ming Liao, Chii-Ming Chen, West M., Nevins J. R., Huang A. T., Gene Expression Predictors of Breast Cancer Outcomes. *Lancet* (2003).
- [41] Hyvärinen A. Oja E., Independent Component Analysis: A Tutorial, *Neural Networks*, 13 (2000).
- [42] Hyvärinen A., New approximations of differential entropy for independent component analysis and projection pursuit, *Proceedings of the 1997 conference on Advances in neural information processing systems* (1998).
- [43] Izworski A., Tadeusiewicz R., Paslawski A., Nonlinear processing of auditory brainstem response, *Annual International Conference of the IEEE Engineering in Medicine and Biology* (2001)
- [44] Jain A., Zongker D., Algorithms for Feature Selection: An Evaluation, (1996).
- [45] Jain A., Zongker D., Feature Selection: Evaluation, Application, and Small Sample Performance, *Pattern Analysis and Machine Intelligence, IEEE Transactions* (1997).
- [46] Jarmulak J., Craw S., Genetic Algorithms for Feature Selection and Weighting, *Proceedings of the IJCAI'99 workshop on Automating the Construction of Case Based Reasoners*, (1999).
- [47] Jaśkowski P., *Neuronauka poznawcza - Jak mózg Tworzy umysł*, Vizja Press & IT (2009)
- [48] Javidi S., Mandic D.P., Cichocki A., Complex blind source extraction from noisy mixtures using second-order statistics *IEEE Transactions on Circuits and Systems I: Regular Papers* (2010)
- [49] Jones M. C., Sibson, R., What is projection pursuit? (with discussion), *Journal of the Royal Statistical Society*, 150 (1987).
- [50] Jourdan L., Dhaenens C., El-Ghazali Talbi, A Genetic Algorithm for Feature Selection in Data-Mining for Genetics *Metaheuristics International Conference* (2001).
- [51] Karhunen J., Oja E., Wang, L., Vigário R., Joutsensalo J., A class of neural networks for independent component analysis. *IEEE Trans. on Neural Networks*, 8 (1997).
- [52] Kasprzak W., *Rozpoznawanie obrazów i sygnałów mowy*, Oficyna Wydawnicza Politechniki Warszawskiej (2009).
- [53] Kay S. M., *Modern Spectral Estimation: Theory and Application*, ISBN:9780130151599, (1999).

- [54] Klekowicz H., Malinowska U., Piotrowska A., Wołyńczyk-Gmaj D., Niemcewicz S., Durka P., On the robust parametric detection of EEG artifacts in polysomnographic recordings, *Neuroinformatics* 7 (2009).
- [55] Klepaczko, A., Materka, A., Combining evolutionary and sequential search strategies for unsupervised feature selection, *Lecture Notes in Computer Science* (2010).
- [56] Klepaczko, A., Materka, A. Clustering quality based feature selection method *Machine Graphics and Vision* (2004).
- [57] Klonowski, W. Everything you wanted to ask about EEG but were afraid to get the right answer *Nonlinear Biomedical Physics*, (2009)
- [58] Kołodziej M., Majkowski A., Rak R, **A New Method of EEG Classification for BCI with Feature Extraction Based on Higher Order Statistics of Wavelet Components and Selection with Genetic Algorithms**, *Adaptive and Natural Computing Algorithms Lecture Notes in Computer Science*, (2011).
- [59] Kołodziej M., Majkowski A., Rak R, **Linear discriminant analysis as a feature reduction technique of EEG signal for brain-computer interfaces**, *International Workshop Computational Problems of Electrical Engineering* (2011).
- [60] Kołodziej M., Majkowski A., Rak R, **Optymalizacja doboru okien czasowych do przetwarzania sygnału EEG w interfejsach mózg-komputer**, *Przegląd Elektrotechniczny* (2011).
- [61] Kołodziej M., Majkowski A., Rak R, **Wizualizacja rozkładu potencjału EEG na głowie pacjenta w zastosowaniu do asynchronicznego interfejsu mózg-komputer**, *Symposium Modelowanie i Pomiary w Medycynie* (2011).
- [62] Kołodziej M., Majkowski A., Rak R, **Wykorzystanie maszyny wektorów wspierających (SVM) do klasyfikacji sygnału EEG na użytek interfejsu mózg-komputer**, *Pomiary Automatyka Kontrola* (2011).
- [63] Kołodziej M., Majkowski A., Rak R, **Wykorzystanie t-statystyk do szybkiej selekcji cech sygnału EEG na użytek interfejsu mózg-komputer**. *Przegląd Elektrotechniczny* (2011).
- [64] Kołodziej M., Majkowski A., Rak R., **A new method of feature extraction from EEG signal for brain-computer interface design**, *Przegląd Elektrotechniczny* (2010).
- [65] Kołodziej M., Majkowski A., Rak R., **Implementation of genetic algorithms to feature selection for the use of brain-computer interface**, *International Conference Computational Problems of Electrical Engineering* (2010).
- [66] Kołodziej M., Majkowski A., Rak R., **Matlab FE\_Toolbox - an universal utility for feature extraction of EEG signals for Brain-Computer Interface realization**. *Przegląd Elektrotechniczny* (2009).
- [67] Kołodziej M., Majkowski A., **Wybrane problemy przetwarzania, analizy i klasyfikacji sygnału EEG na użytek interfejsu mózg-komputer**. *Metrologia dziś i jutro* (2010).
- [68] Kołodziej M., Rak R., Majkowski A., **Interfejs mózg-komputer – wybrane problemy rejestracji i analizy sygnału EEG**, *Przegląd Elektrotechniczny* (2009).
- [69] Korbicz J., Obuchowicz A., Uciński D., *Sztuczne sieci neuronowe. Podstawy i ich zastosowania*, Akademyka Oficyna Wydawnicza PLJ, (1994).

- [70] Kornhuber H. H., Deecke L., Changes in human brain potentials before and after voluntary movement studied by recording on magnetic tape and reverse analysis (1964).
- [71] Kornhuber, H. H., Deecke, L. Hirnpotentialänderungen bei Willkürbewegungen und passiven Bewegungen des Menschen: Bereitschaftspotential und reafferente Potentiale. *Pflügers Arch* 284 (1965).
- [72] Koronacki J., Ćwik J., Statystyczne systemy uczące się, *Exit* (2008).
- [73] Królak, A., Strumillo, P. Comparison of eyeblink monitoring and EEG signal analysis for mental fatigue assessment *Proceedings of SPIE - The International Society for Optical Engineering*, (2008).
- [74] Królak, A., Strumiłło, P. Vision-based eye blink monitoring system for human-computer interfacing, *Conference on Human System Interaction*, (2008)
- [75] Krzyśko M., Górecki W., Wołyński T., Skorzybut M., *Systemy uczące się*, WNT (2008).
- [76] Kübler A., Nijboer F., Mellinger J., Vaughan T. M., Pawelzik H., Schalk G., McFarland DJ, Birbaumer N, Wolpaw J. R. Patients with ALS can use sensorimotor rhythms to operate a brain-computer interface. *Neurology*. 24 (2005).
- [77] Kuś R., Ginter J., Cieślak-Blinowska K., Propagation of EEG activity during finger movement and its imagination *ACTA NEUROBIOLOGIAE EXPERIMENTALIS* 66 (2006).
- [78] Lewenstein K., Ślubowska E., Jernajczyk W., Czerwosz L., Detection of Alcohol Addiction Based on PSG Sleep Patterns, *Pol J Med Phys Eng* 12 (2006).
- [79] Li Zhuo, Jing Zheng, Fang Wang, Xia Li, Bin Ai, Junping Qian, A Genetic Algorithm Based Wrapper Feature Selection Method For Classification Of Hyperspectral Images Using Support Vector Machine, *Geoinformatics* (2008).
- [80] Lotte F., Guan C., Regularizing Common Spatial Patterns to Improve BCI Designs: Theory and Algorithms, *IEEE Transactions On Biomedical Engineering* X (2010).
- [81] Mallat S. G, A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Transactionson Patternan analysis and Machine Intelligence* 7 (1989).
- [82] Materka, A. System parameter estimation using neural-network-like approximators of multivariable functions *Systems Analysis Modelling Simulation*, (1996).
- [83] Materka, A., Byczuk, M. Using comb filter to enhance SSVEP for BCI applications *IET Conference Publications*, (2006).
- [84] Materka, A., Byczuk, M., Alternate half-field stimulation technique for SSVEP-based brain-computer interfaces *Electronics Letters*, (2006).
- [85] Materka, A., Byczuk, M., Poryzala, P., A virtual keypad based on alternate half-field stimulated visual evoked potentials, *Proceedings International Symposium on Information Technology Convergence*, (2007).
- [86] Materka, A., Mizushina, S. Parametric signal restoration using artificial neural networks *IEEE Transactions on Biomedical Engineering*, (1996).
- [87] Materka, A., Slot, K., Strumiłło, P. Biometrics for user authentication *International Conference on Signals and Electronic Systems, Proceedings*, (2006).
- [88] McFarland D. J., Wolpaw J. R, Sensorimotor rhythm-based brain-computer interface (BCI): model order selection for autoregressive spectral analysis, *J Neural Eng.* 5 (2008).

- [89] Mehmed K., *Data Mining: Concepts, Models, Methods, and Algorithms*. John Wiley & Sons. ISBN 0471228524, (2003).
- [90] Mélard G., Roy R., Saidi A., Exact maximum likelihood estimation of structured or unit root multivariate time series models, *Journal Computational Statistics & Data Analysis archive* 50 (2006).
- [91] Millan J.d.R., Mourino J.. Asynchronous BCI and local neural classifiers: an overview of the adaptive brain interface project. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11 (2003).
- [92] Millan J.d.R.. A Local Neural Classifier for the Recognition of EEG Patterns Associated to Mental Tasks. *IEEE Transactions on Neural Networks*, 13 (2002).
- [93] Millán, J. del R.. On the need for on-line learning in brain-computer interfaces Proc. Int. Joint Conf. on Neural Networks., (2004).
- [94] Moradi V. A., Khalilzadeh M. A, A new approach for EEG feature extraction in P300-based lie detection, *Computer methods and programs in biomedicine* 94 (2009).
- [95] Muthukumaraswamy S. D., Johnson B. W., McNair N. A., Mu rhythm modulation during observation of an object-directed grasp. *Brain Res Cogn Brain Res*, 19 (2004).
- [96] Nuneza P. L., Srinivasanb R., Westdorpa A. F., Wijesinghea R. S., Tuckerb D. M., Silbersteine R. B., Cadusche P. J., EEG coherency: I: statistics, reference electrode, volume conduction, Laplacians, cortical imaging, and interpretation at multiple scales. *Electroencephalogr Clin Neurophysiol.* (1997).
- [97] Ohme R., Reykowska D., Wiener D., Choromanska A., Analysis of Neurophysiological Reactions to Advertising Stimuli by Means of EEG and Galvanic Skin Response Measures, *Journal of Neuroscience* 2, (2009).
- [98] **Olszewski D., Kołodziej M., Twardy M., A Novel Probabilistic Model for K-Means Algorithm, Przegląd Elektrotechniczny (2010).**
- [99] Ortner R., Grünbacher E., Guger C., *State of the Art in Sensors, Signals and Signal Processing*, g.tec medical engineering GmbH/Guger Technologies OG, Graz, Austria (2011).
- [100] Osowski S., Cichocki A., Siwek K., *Matlab w zastosowaniu do obliczeń obwodowych i przetwarzania sygnałów*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa (2006).
- [101] Osowski S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, (2000):
- [102] Paszkiel Sz., A. Błachowicz, The application of electroencephalographic signals in the aspect of controlling a mobile robot for measurements of incomplete discharges; *Przegląd Elektrotechniczny* (2010).
- [103] Paszkiel Sz., Zmarzły D., Autoryzacja dostępu do sieci komputerowej z wykorzystaniem aktywnych słuchawek elektroencefalograficznych; *Monografia Seminarium naukowego Mechanika w Medycynie* 9 (2008).
- [104] Paszkiel Sz., Zmarzły D., Kawala A., Szmechta M., Zastosowanie pomiarów elektroencefalograficznych EEG w procesie uwierzytelniania biometrycznego użytkowników; *Miesięcznik naukowo-techniczny Pomiary, Automatyka* (2007).
- [105] Patel S. H., Azzam P. N., Characterization of N200 and P300: Selected Studies of the Event-Related Potential. *Int J Med Sci* (2005).



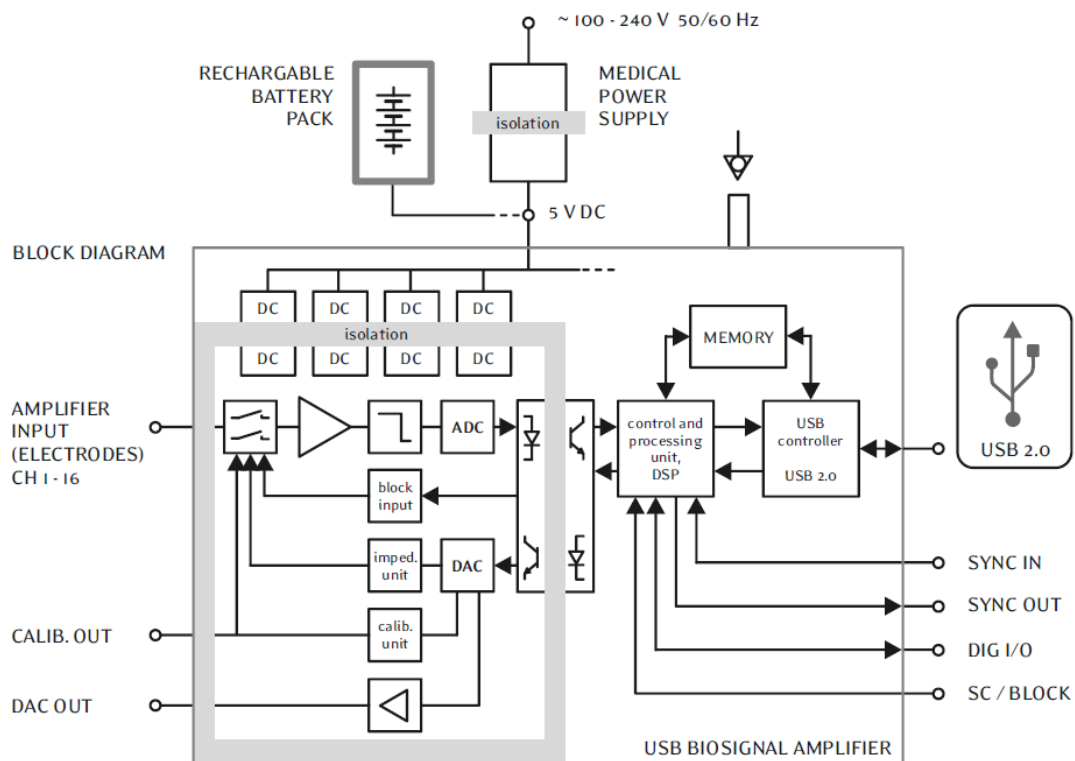
- [106] Penny W. D., Roberts S. J., EEG-based communication via dynamic neural network models, In International Joint Conference on Neural Networks (1999).
- [107] Perelmouter J., Birbaumer N., A Binary Spelling Interface with Random Errors. IEEE Transactions on Rehabilitation Engineering, 8 (2000).
- [108] Pfurtscheller G., Brunner C., Schlogl A., Lopes da Silva F. H., Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks. Neuroimage, 31 (2006).
- [109] Pfurtscheller G., Neuper C., Muller G.R, Obermaier B., Krausz G., Schlogl A., Scherer R., Graimann B., Keinrath C., Skliris D., Wortz, M., Supp G., Schrank C.. Graz-bci: State of the Art and Clinical Applications. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 11 (2003).
- [110] Pineda J. A., Allison B. Z., Vankov A. The effects of self-movement, observation, and imagination on mu rhythms and readiness potentials (RP's): toward a brain-computer interface (BCI). IEEE Trans Rehabil Eng, 8 (2000).
- [111] Polich J., Pollick V. E., Bloom F.E, Meta-analysis of P300 normative aging studies, Article first published online: Psychophysiology (2007).
- [112] Prabhakar, S., Kittler, J., Maltoni, D., O'Gorman, L., Tan, T.: Introduction to the Special Issue on Biometrics: Progress and Directions. IEEE Trans. Pattern Anal. Mach. Intell., (2007).
- [113] Pracki T., Pracka D., Bioelectric amplifier, Sen 2 (2002).
- [114] Pregenzer M., Pfurtscheller G., Frequency Component Selection for an EEG-Based Brain to Computer Interface, IEEE Transactions On Rehabilitation Engineering 7 (1999).
- [115] Principal Components Analysis, Agilent Technologies, (2005).
- [116] Przybyła M., Chmielewski H., Klimek A., Dworniak D., Kaczorowska B., Przydatność potencjału P300 w diagnostyce encefalopatii wątrobowej o etiologii alkoholowej, Wiadomości Lekarskie (2007).
- [117] Qibin Zhao, Liqing Zhang, Cichocki A., Jie Li, Incremental Common Spatial Pattern Algorithm for BCI, IJCNN (2008).
- [118] **Rak R., Kołodziej M., Zastosowanie analizy częstotliwościowej sygnału EEG w interfejsach mózg-komputer. Przegląd Elektrotechniczny (2008).**
- [119] **Rak. R, Kołodziej M., Majkowski A, 9 Rozdział. Metrologia w Medycynie, Interfesj-mózg-komputer. WAT (2011).**
- [120] Ramoser H., Müller-Gerking J., Pfurtscheller G., Optimal Spatial Filtering of Single Trial EEG During Imagined Hand Movement, IEEE Transactions On Rehabilitation Engineering 8, (2000).
- [121] Riera R., Dunne S., Ceste I., Ruffini G., Starfast a Wireless Wearable EEG Biometric System based on the ENOBIO Sensor, Proceedings of 5th pHealth Workshop on Wearable Micro and Nanosystems for Personalised Health (2008).
- [122] Ruffini G., Dunne S., Farres E., Marco-Pallares J., Ray C., Mendoza E., Silva R., Grau C., A dry electrophysiology electrode using CNT arrays, Sensors and Actuators A: Physical, 132, The 19th European Conference on Solid-State Transducers (2006).
- [123] Rutkowski L., Biocybernetyka i Inżynieria Biomedyczna, Częstochowa (2005),
- [124] Rutkowski L., Siekmann J., Tadeusiewicz R., Zadeh L. A., Proceedings of the Seventh International Conference: Artificial Intelligence and Soft Computing, (2004),

- [125] Rutkowski L., Tadeusiewicz R., Zurada J. Artificial Intelligence and Soft Computing, Academic Publishing House EXIT, Warszawa (2006).
- [126] Sa Wang, Cheng-Lin Liu, Lian Zheng, Feature Selection By Combining Fisher Criterion And Principal Feature Analysis, Proceedings of the Sixth International Conference on Machine Learning and Cybernetics, (2007).
- [127] Saa J. F. D., Gutierrez M. S., EEG Signal Classification Using Power Spectral Features and linear Discriminant Analysis: A Brain Computer Interface Application, LACCEI (2010).
- [128] Sawicki D., Augustynowicz M., Multitouch screen – alternative human computer interface. Przegląd Elektrotechniczny (2010).
- [129] Sawicki D., Lesiuk G., System biometryczny w bibliotece, Przegląd Elektrotechniczny (2011).
- [130] Sawicki D., To See or Not to See – Reflections on Human Color Perception, Przegląd Elektrotechniczny (2010).
- [131] Schalk G., McFarland D. J., Hinterberger T., Birbaumer N., Wolpaw J.R., BCI2000: a general-purpose brain-computer interface (BCI) system. E Trans Biomed Eng. 51 (2004).
- [132] Schenk J., Kaiser M., Rigoll G., Selecting Features in On-Line Handwritten Whiteboard Note Recognition: SFS or SFFS?, 10th International Conference on Document Analysis and Recognition (2009).
- [133] Sewell M., Feature Selection, (2007).
- [134] Shaker M. M, EEG Waves Classifier using Wavelet Transform and Fourier Transform International Journal of Biological and Life Sciences (2005).
- [135] Shaker M. M., Modeling of EEG Signal Sound Frequency Characteristic Using Time Frequency Analysis, Mathematical/Analytical Modelling and Computer Simulation,(2010).
- [136] Shannon C.E., Weaver W., A Mathematical Theory of Communication. Bell System Technical Journal, 27 (1948).
- [137] Sielużycki C., Koenig R., Matysiak M., Kuś R., Ircha D., Durka P., Single-Trial Evoked Brain Responses Modelled by Multivariate Matching Pursuit, IEEE Transactions On Biomedical Engineering (2009).
- [138] Sielużycki C., Koenig R., Matysiak M., Kuś R., Ircha D., Durka P., Single-Trial Evoked Brain Responses Modelled by Multivariate Matching Pursuit, IEEE Transactions On Biomedical Engineering 56 (2009).
- [139] Ślot K., Wybrane zagadnienia biometrii, ISBN: 978-83-206-1673-6 (2008).
- [140] Smith L. I., A tutorial on Principal Components Analysis, (2002).
- [141] Swiderski B., Osowski S., Cichocki A., Rysz A., Epileptic Seizure Prediction Using Lyapunov Exponents and Support Vector Machine, ICANNGA (2) (2007).
- [142] Swiderski B., Osowski S., Cichocki A., Rysz A., Single-class SVM and directed transfer function approach to the localization of the region containing epileptic focus. Neurocomputing 72, (2009).
- [143] Swiderski B., Osowski S., Cichocki A., Rysz A., Single-class SVM classifier for localization of epileptic focus on the basis of EEG. IJCNN (2008)
- [144] Tadeusiewicz R. Izworski A. Majewski A., Biometria. Wydawnictwo AGH, (1993).

- [145] Talavera L., An evaluation of filter and wrapper methods for feature selection in categorical clustering, *Advances in Intelligent Data Analysis VI LNCS* (2005).
- [146] Tao Wang, Jie Denga, Bin He, Classifying EEG-based motor imagery tasks by means of time–frequency synthesized spatial patterns, *Clinical Neurophysiology* 115 (2004).
- [147] Vafaie H., De Jong K., Genetic Algorithms as a Tool for Feature Selection in Machine Learning, *Tools with Artificial Intelligence, Proceedings., Fourth International Conference on*, (1992).
- [148] Vafaie H., Imam I. F., Feature Selection Methods: Genetic Algorithms vs. Greedy-like Search, *Proceedings of the International Conference on Fuzzy and Intelligent Control Systems*, (1944).
- [149] Vidal J. J., Toward direct brain-computer communication, *Annu Rev Biophys Bioeng* (1973).
- [150] Welling M., Fisher Linear Discriminant Analysis, Department of Computer Science University of Toronto 10 King’s College Road Toronto, M5S 3G5 Canada
- [151] Wolpaw J. R. McFarland D. J., Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans Laboratory of Nervous System Disorders, *Proc Natl Acad Sci* (2004).
- [152] Wolpaw J. R., Birbaumer N., McFarland D. J., Pfurtscheller G., Vaughan T. M., Brain–computer interfaces for communication and control, *Clinical Neurophysiology* 113 (2002).
- [153] Wolpaw J. R., Ramoser H., McFarland D. J., Pfurtscheller G., EEG-Based Communication: Improved Accuracy by Response Verification, *IEEE Transactions On Rehabilitation Engineering*, 6 (1998).
- [154] Wolpaw J.R., McFarland D.J., Vaughan T.M., Brain-computer interface research at the Wadsworth Center. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 8 (2000).
- [155] Yom-Tov E., Inbar G.F., Feature Selection for the Classification of Movements from Single Movement-Related Potentials, *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 10 (2001).
- [156] YongSeog Kim, Street W. N., Menczer F., Feature Selection in Data Mining, University of Iowa, USA.
- [157] Zieliński T. P., "Cyfrowe przetwarzanie sygnałów: od teorii do zastosowań", Wydawnictwa Komunikacji i Łączności, Warszawa, ISBN 978-83-206-1640-8 (2007).
- [158] Zieliński T. P., "Od teorii do cyfrowego przetwarzania sygnałów", Wydział EAIiE AGH, Kraków (2000).
- [159] Żygierewicz J., Malinowska U., Suffczyński P., Piotrowski T., Durka P., Event-related desynchronization and synchronization in evoked K-complexes, *Acta Neurobiologiae Experimentalis* 69 (2009).
- [160] Zyss T., Sawicki B., Stanisławczyk A., Precise localization of the EEG electrodes placement by help of electromagnetic digitizer *Przeład Elektrotechniczny* (2010).

# D1. Parametry wzmacniacza i elektrod

Podczas badań własnych, wykorzystano profesjonalny wzmacniacz napięć bioelektrycznych firmy g.Tec typ g.UsbAmp 3.0 seria UB. Wzmacniacz g.UsbAmp składa się z 16 niezależnych 24 bitowych przetworników A/C. Częstotliwość próbkowania każdego z przetworników wynosi 38.4kHz na kanał. Ponieważ każdy kanał ma osobny przetwornik A/C, wzmacniacz umożliwia przetwarzanie sygnału dla każdego kanału dokładnie w tym samym czasie. Jest to bardzo duża zaleta wykorzystywanego wzmacniacza, ponieważ nie ma opóźnień rejestrowanych próbek między poszczególnymi kanałami. Poglądowy schemat wzmacniacza zaczerpnięty z dokumentacji przedstawiono na rysunku D1.



Rys. D1. Schemat wzmacniacza g.UsbAmp

Wzmacniacz posiada wbudowany procesor sygnałowy DSP umożliwiający przetwarzanie i filtrację cyfrową sygnału. Dodatkowo, wzmacniacz umożliwia kalibrację przetworników oraz pomiar impedancji pomiędzy elektrodami. Wzmacniacz posiada certyfikat CE oraz FDA pozwalający na pomiary medyczne nieinwazyjne oraz inwazyjne. Dokładne parametry wzmacniacza zamieszczono w tabeli D1.

Tabela D1. Parametry wzmacniacza g.UsbAmp

Czułość	<30nV (LSB) ±250mV
16xADC	24bit (38.4kHz próbkowanie na kanał)
2xDAC	12bit
Kanały wejściowe	16 mono-polarnych, 8 bi-polarnych
Poziom szumu	<0.3uV RMS (0.1-10Hz)
Impedancja wejściowa	>100MΩ
Wymiary	196x155x50mm
Standardy	93/42/EWG EN60601-1: 1996 (+A1 +A2 + A12 +A13) EN60601-2-26: 2004 EN60601-1-2: 2003 EN60601-1-25 +A1: 2001 EN606001-2-40 :1980

Ważnym elementem poprawiającym jakość sygnałów było zastosowanie profesjonalnych elektrod aktywnych wraz ze specjalnym czepkiem. Zastosowano elektrody g.LADYbird firmy g.Tec. Zastosowane aktywnej elektrody Ag/AgCl z mikrowzmacniaczem pozwalało na 10 krotne wzmocnienie sygnału. Aby możliwy był kontakt skóra-elektroda zastosowano specjalny żel g.GAMMAgel. Elektrody aktywne oprócz wzmocnienia sygnału pozwalały na uniknięcie czasochłonnego oczyszczania skóry głowy.

## D2. Wykaz symboli oznaczeń i skrótów

### Wykaz oznaczeń

$r^2$	- współczynnik determinacji
$r_{XY}$	- współczynnik korelacji Pearsona wektorów $X$ i $Y$
$R_{23}$	- wektor różnicy dwóch wektorów cech dla klasy K2 i K3
$\varepsilon_t$	- biały szum
$\lambda_C, L_x, L$	- macierz diagonalna wartości własnych
$\mu_2$	- wektor średniej cech z wektora dla klasy K2
$\mu$	- średnia sygnału
$A$	- macierz mieszająca
$C$	- znormalizowana macierz kowariancji
$c$	- stała modelu AR
$C_c$	- przestrzenna macierz kowariancji
$cov(X,Y)$	- kowariancja wektora $X$ i $Y$
$d_N$	- $N$ -ty detal transformaty falkowej
$E$	- macierz zawierająca sygnały EEG
$E[]$	- wartość oczekiwana
$f(u_j)$	- nieliniowa funkcja aktywacji
$f_s$	- częstotliwość próbkowania sygnału
$K$	- liczba klas
K2, K3, K7	- oznaczenia klas
$K_c$	- suma współczynników K-Fishera pomiędzy wszystkimi parami klas
$N$	- liczba zadań myślowych, liczba kanałów w zapisie sygnału EEG,
$p(i)$	- prawdopodobieństwo zajścia zdarzenia
$p_a$	- średnia skuteczność
$R_{xx}(\tau)$	- funkcja autokorelacji
$R_{yy}$	- macierz kowariancji
$s(t)$	- zbiór niezależnych sygnałów źródłowych
$S_m$	- macierz rozrzutu międzyklasowego
$S_w$	- macierz rozrzutu wewnątrzklasowego
$T$	- liczba próbek w zapisie sygnału EEG

$t$	- wartość $t$ - testu Welcha
$T_{act}$	- czas na wykonanie klasyfikacji
$t_c$	- suma współczynników $t$ pomiędzy klasami
$tr(\mathbf{X})$	- ślad macierzy $\mathbf{X}$
$\mathbf{U}_c, \mathbf{V}_x, \mathbf{U}$	- macierz wektorów własnych
$\mathbf{v}(t)$	- wektor szumów
$V_j$	- potencjał $j$ -tej elektrody
$\mathbf{W}$	- macierz filtru przestrzennego, macierz separująca
$\mathbf{w}$	- kierunek rzutowania
$\mathbf{X}(f)$	- transformacja Fouriera
$\mathbf{x}(t)$	- wektor rejestrowanych sygnałów EEG
$\mathbf{x}_N, \mathbf{s}_N$	- wektor sygnału
$\sigma_2$	- wektor odchyłeń standardowych cech dla klasy K2
$\varphi(\mathbf{x})$	- funkcja jądra SVM
$\varphi_p$	- $p$ -ty współczynnik modelu AR
$\sigma$	- odchylenie standardowe

### Wykaz skrótów

ANN	<i>Artificial Neural Network</i>
AR	<i>Autoregressive Model</i>
BCI	<i>Brain-Computer Interface</i>
BMI	<i>Brain-Machine Interface</i>
BP	<i>Bereitschaftspotential</i>
BSS	<i>Blind Signal Separation</i>
CAR	<i>Common Average Reference</i>
CMRR	<i>Common Mode Rejection Ratio</i>
CSP	<i>Common Spatial Pattern</i>
DT	<i>Decision Trees</i>
DWT	<i>Discrete Wavelet Transform</i>
ECG/EKG	<i>Electrocardiogram</i>
ECoG	<i>Electrocorticography</i>
EEG	<i>Electroencephalography</i>
EMG	<i>Electromyography</i>

EOG	<i>Electrooculography</i>
ERD	<i>Event-Related Desynchronization</i>
ERS	<i>Event-Related Synchronization</i>
FFT	<i>Fast Fourier Transform</i>
FIR	<i>Finite Impulse Response</i>
fMRI	<i>Functional Magnetic Resonance Imaging</i>
GA	<i>Genetic Algorithm</i>
HCI	<i>Human–Computer Interaction</i>
HOS	<i>Higher-Order Statistics</i>
ICA	<i>Independent Component Analysis</i>
IIR	<i>Infinite Impulse Response</i>
IR	<i>Intracortical Recordings,</i>
ITR	<i>Information Transfer Rate</i>
K-NN	<i>K-Nearest Neighbor</i>
LDA	<i>Linear Discriminant Analysis</i>
MEG	<i>Magnetoencephalography</i>
MLP	<i>Quadratic Discriminant Analysis</i>
NIRS	<i>Near Infrared Spectroscopy</i>
PCA	<i>Principal Component Analysis</i>
PET	<i>Positron Emission Tomography</i>
QDA	<i>Quadratic Discriminant Analysis</i>
SCPSc	<i>Slow Cortical Potentials Shifts</i>
SFS	<i>Sequential Forward Selection</i>
SSVEP	<i>Steady State Visually Evoked Potential</i>
SVM	<i>Support Vector Machine</i>