

Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
Wydział Informatyki

PRZETWARZANIE WSTĘPNE NISKO-KANAŁOWYCH SYGNAŁÓW EEG

Paweł Górski

Promotor: dr hab. Izabela Rejer, prof. ZUT

Szczecin 2019

Podziękowania

Dziękuję Pani Profesor Izabeli Rejer, za opiekę naukową, życzliwość i poświęcony mi czas, które przyczyniły się do powstania niniejszej pracy doktorskiej.

Dziękuję mojej żonie Jowicie oraz synowi Leonowi, za cierpliwość, wyrozumiałość oraz niegasnącą wiarę we mnie.

Osobne podziękowania składam moim rodzicom, Barbarze oraz Adamowi, za pomoc na wszystkich etapach nauki oraz wartości wyniesione z domu.

Spis treści

Wstęp	3
Rozdział 1 Sygnał EEG	8
1.1 Rejestracja sygnału EEG.....	8
1.2 Właściwości sygnału EEG.....	13
1.3 Widmo sygnału EEG	17
1.4 Przetwarzanie sygnału EEG.....	22
1.5 Analiza sygnału EEG - zakres zastosowań.....	24
1.5.1 Medycyna.....	25
1.5.2 Interfejs mózg-komputer.....	27
1.5.3 Inne zastosowania	29
Rozdział 2 Przetwarzanie wstępne sygnałów EEG	31
2.1 Artefakty w sygnale EEG	31
2.1.1 Artefakty pochodzenia nefizjologicznego	32
2.1.2 Artefakty pochodzenia fizjologicznego	33
2.2 Metody detekcji i eliminacji artefaktów	36
2.3 Algorytmy automatycznej detekcji i eliminacji artefaktów	41
2.4 Filtry przestrzenne	46
2.4.1 Wspólne wzorce przestrzenne.....	47
2.4.2 Filtr Laplace’a	49
2.4.3 Średnia wartość referencyjna	49
2.4.4 Analiza składowych głównych	50
2.4.5 Filtr minimalnego szumu	51
Rozdział 3 Analiza składowych niezależnych.....	53
3.1 Model i założenia wstępne analizy składowych niezależnych	53
3.2 Podstawowe algorytmy analizy składowych niezależnych	63
3.2.1 FastICA – podejście deflacyjne	66
3.2.2 FastICA – podejście symetryczne.....	67
3.2.3 Infomax	68
3.3 Ograniczenia klasycznego algorytmu analizy składowych niezależnych	69
3.4 Algorytmy ICA dla systemów nisko-kanalowych.....	74
Rozdział 4 Eksperymenty wstępne	79

4.1 Badania prowadzone na sygnałach dźwiękowych.....	79
4.1.1 Badanie 1	82
4.1.2 Badanie 2	84
4.2 Badania prowadzone na benchmarkowym zbiorze danych EEG	86
4.2.1 Badanie 3	88
4.2.2 Badanie 4	90
4.2.3 Badanie 5	94
4.3 Badania prowadzone na danych EEG zarejestrowanych w trakcie zaplanowanych eksperymentów badawczych	97
Rozdział 5 Metoda MAICA.....	105
5.1 Algorytm MAICA.....	105
5.2 Wyznaczenie wektora parametrów filtrów wygładzających	110
Rozdział 6 Weryfikacja działania metody MAICA.....	116
6.1 System 1 – sygnały sinusoidalne	116
6.2 System 2 – pojedynczy ciągły sygnał EEG	131
6.3 System 3 – dane EEG z wielu prób	137
6.4 Wnioski końcowe.....	143
Zakończenie	146
Bibliografia	149

WSTĘP

Jednym z kluczowych, ale wciąż jeszcze niewystarczająco dobrze rozpoznanych aspektów monitorowania aktywności mózgu, jest aspekt rejestrowania sygnału EEG (elektroencefalogramu) poza kontrolowanymi warunkami laboratoryjnymi i bez nadzoru wykwalifikowanego personelu medycznego. Rozwiązanie tego zagadnienia jest niesłychanie ważne z punktu widzenia różnych grup społecznych oraz zawodów, szczególnie tych, które wymagają ciągłego utrzymania wysokiego stopnia koncentracji oraz uwagi (piloci, kierowcy). Inną grupą zainteresowaną możliwością ciągłego monitorowania sygnału EEG w warunkach domowych są opiekunowie osób starszych lub niepełnosprawnych, którym bieżąca informacja o aktywności mózgowej ich podopiecznych może niesłychanie ułatwić codzienne życie oraz pracę. Oczywiście ciągłe monitorowanie sygnału EEG poza laboratoriami naukowymi, ośrodkami badawczymi lub niezależnymi jednostkami medycznymi nie jest zadaniem łatwym, przede wszystkim z uwagi na zbyt niską jakość sygnału rejestrowanego w środowisku poza laboratoryjnym, niedostateczny komfort długotrwałego korzystania z urządzeń do rejestracji sygnału EEG oraz mało intuicyjną obsługę tych urządzeń.

Zazwyczaj jakość sygnału EEG, można poprawić poddając sygnał zarejestrowany z wielu czujników pomiarowych filtracji przestrzennej. Istnieje wiele różnych filtrów przestrzennych, niektóre z nich są nieadaptacyjne (np. wspólna uśredniona referencja (ang. Common Average Reference, CAR) czy filtry Laplace'a [1]), inne - adaptacyjne (np. analiza składowych głównych (ang. Principal Component Analysis, PCA) [2, 3, 4], wspólne wzorce przestrzenne (ang. Common Spatial Patterns, CSP) [5, 6] czy analiza składowych niezależnych (ang. Independent Component Analysis, ICA) [7, 8, 9, 10, 11]). Chociaż filtry z obu klas zazwyczaj poprawiają jakość sygnału, to o wiele lepsze wyniki uzyskuje się po zastosowaniu filtrów z klasy drugiej.

Mapowanie sygnałów zarejestrowanych z czujników pomiarowych do przestrzeni sygnałów źródłowych wykonywane przez adaptacyjne algorytmy filtrowania przestrzennego jest zwykle dużo bardziej precyzyjne w sytuacji, gdy sygnał EEG jest rejestrowany z dużej liczby czujników [1]. Problem polega jednak na tym, że chociaż w laboratorium badawczym możliwe jest stosowanie (prawie) dowolnie gęstej macierzy czujników pomiarowych, w przypadku

rejestracji sygnału w środowisku poza laboratoryjnym każdy dodatkowy czujnik pomiarowy nie tylko zmniejsza komfort użytkownika, ale także utrudnia ich właściwy montaż na powierzchni czaszki. W związku z tym, w środowisku poza laboratoryjnym sygnał EEG powinien być rejestrowany z możliwie najmniejszej liczby czujników. Podsumowując, z jednej strony potrzebna jest duża liczba czujników rozmieszczonych na całej powierzchni czaszki, aby możliwe było zastosowanie filtrów przestrzennych zwiększających stosunek sygnału do szumu, z drugiej natomiast komfort użytkownika oraz łatwość aplikacji sprzętu EEG wymagają stosowania jak najmniejszej liczby czujników.

Aby spełnić oba wskazane powyżej wymagania, należy znaleźć sposób zastosowania technik filtrowania przestrzennego do sygnału rejestrowanego z niewielkiego zestawu czujników. W niniejszej pracy przedstawiona zostanie metoda, którą można wykorzystać do wykonania tego zadania. Zaproponowana metoda, nazwana MAICA (Moving Average Independent Component Analysis), stanowi rozszerzenie klasycznej analizy składowych niezależnych (w dalszej części pracy termin analiza składowych niezależnych będzie używany naprzemiennie z akronimem ICA, ang. Independent Component Analysis).

ICA jest liniowym filtrem przestrzennym często wykorzystywanym w analizie sygnału EEG do wykrywania różnego rodzaju sygnałów zakłócających (artefaktów), np. ocznych [12], mięśniowych, elektrokardiograficznych lub artefaktu sieciowego [13, 14, 15]. Chociaż wiele badań potwierdziło, że zastosowanie metody ICA zwiększa stosunek sygnału do szumu (SNR) w przypadku sygnałów rejestrowanych z dużej liczby kanałów EEG, od 16 [15], przez 19-20 [13] do 71 [16] i więcej, jedynie w nielicznych badaniach analizowano wyniki zwrócone przez algorytmy ICA dla konfiguracji nisko-kanalowej [17, 18, 19]. Wynika to z jednego z dwóch warunków, które muszą być spełnione, aby możliwe było rozwiązanie liniowego modelu ICA [17]: *Liczba sygnałów pobranych z czujników, powinna być co najmniej tak duża, jak liczba wyodrębnionych źródeł.* Warunek ten implikuje, że podczas gdy dla sygnału rejestrowanego za pomocą 64-kanalowej macierzy elektrod istnieje możliwość odzyskania aż do 64 szacowanych źródeł, w przypadku macierzy 3-kanalowej można oszacować jedynie 3 potencjalne źródła. Biorąc pod uwagę fakt, że sygnały rejestrowane z czujników pomiarowych reprezentują nie tylko aktywność mózgu, ale także wszelkiego rodzaju fizjologiczne i poza fizjologiczne artefakty, nie można zakładać, że

rozkład zarejestrowanych sygnałów na zaledwie trzy komponenty będzie wystarczający, aby jednoznacznie określić pochodzenie poszczególnych komponentów. Co więcej, zwykle, jeśli dostępnych jest tylko kilka kanałów, to składowe uzyskane na wyjściu algorytmu ICA raczej nie przedstawiają poszczególnych źródeł, ale nadal są ich kombinacjami. Składowe te będą oczywiście bardziej niezależne niż nieprzetworzone sygnały rejestrowane z powierzchni czaszki (z uwagi na to, że kryterium optymalizacyjnym algorytmu jest dążenie do maksymalizacji niezależności statystycznej składowych), lecz najczęściej nie będą reprezentowały poszczególnych źródeł.

Powyższe rozważania prowadzą do nieokreślonego modelu ICA ($m > n$, gdzie m jest liczbą elementów, a n jest liczbą czujników pomiarowych). W literaturze można znaleźć kilka podejść, które można zastosować do rozwiązania tego modelu. Jedno z pierwszych, o nazwie SCICA (single channel ICA), zostało wprowadzone przez Daviesa i Jamesa [18]. Autorzy zaproponowali rozwiązanie modelu jednokanałowego ICA poprzez podzielenie sygnału zarejestrowanego z jednego czujnika na sekwencję sąsiadujących bloków, a następnie wykonanie algorytmu ICA na macierzy złożonej z tych bloków. Inna propozycja została przedstawiona w pracy [19, 20]. Rdzeniem zaproponowanej metody, zwanej metodą dynamicznego osadzania (ang. dynamical embedding, DE), jest reprezentacja sygnału zarejestrowanego z pojedynczego kanału za pomocą szeregu opóźnionych wektorów pobranych z tego sygnału, a następnie przesłanie macierzy opóźnionych wektorów do jednego z algorytmów ICA. Kolejna metoda, zwana EEMD-ICA (ang. Ensemble Empirical Mode Decomposition ICA), opisana została w [21, 22]. Metoda ta, łączy zmodyfikowaną wersję algorytmu EMD (EEMD) i FastICA. Algorytm EEMD definiuje zestaw niezależnych funkcji wewnętrznych, tzw. IMF's (ang. Intrinsic Mode Functions) uśrednionych dla danej liczby prób. Zestaw uśrednionych IMF's zwróconych przez EEMD stanowi wielokanałową reprezentację oryginalnego jednokanałowego sygnału i stanowi macierz wejściową dla algorytmu FastICA. Ostatnim, wartym wspomnienia podejściem do rozwiązania nieokreślonego modelu ICA, jest połączenie ICA i dyskretnej transformaty falkowej (ang. Discrete Wavelet Transform, DWT) [21, 23, 24, 25, 26]. Podobnie jak we wcześniej wspomnianych metodach, również ten algorytm, zwany WICA (ang. Wavelet ICA), składa się z dwóch części. Pierwsza część ma na celu znalezienie wielokanałowej reprezentacji jednego (lub kilku) sygnałów przy użyciu transformaty

falkowej. Podobnie, jak w przypadku innych podejść, reprezentacja wieloskładnikowa uzyskana jako wynik rozkładu sygnału jest następnie przekazywana do jednego z algorytmów ICA.

Podejścia przedstawione w wymienionych pracach pozwalają na rozkład sygnału na składowe nawet w przypadku rejestracji danych z pojedynczego kanału. Problemem jednak jest to, że są one wymagające obliczeniowo i dlatego trudno jest je obecnie zastosować do analizy sygnału w czasie rzeczywistym. Poza tym, dokładność estymacji sygnałów źródłowych jest w przypadku większości z nich stosunkowo niska (co zostanie pokazane w dalszej części pracy). W niniejszej rozprawie przedstawiony zostanie skuteczny i szybki algorytm pozwalający na rozwiązanie nieokreślonego modelu ICA. Ideą prezentowanego podejścia jest rozszerzenie macierzy sygnałów zarejestrowanych z czujników pomiarowych o sztucznie wygenerowane sygnały utworzone poprzez zastosowanie zestawu filtrów dolnoprzepustowych o zerowej fazie na zarejestrowanych sygnałach, a następnie zastosowanie jednego z klasycznych algorytmów ICA na tak przygotowanej macierzy sygnałów.

Z powyższych rozważań wynika cel oraz hipoteza niniejszej rozprawy. Celem pracy było: *opracowanie metody przetwarzania wstępnego nisko-kanalowych sygnałów EEG, korzystającej z idei połączenia rzeczywistych kanałów EEG z kanałami sztucznie wygenerowanymi*. Z kolei hipotezę postawioną w pracy można sformułować następująco: *Zaproponowana w rozprawie metoda wstępnego przetwarzania nisko-kanalowych sygnałów EEG pozwala na uzyskanie składowych wynikowych charakteryzujących się wyższym podobieństwem do rzeczywistych (bądź przewidywanych) sygnałów źródłowych oraz pozwalających na uzyskanie wyższej dokładności klasyfikacji, aniżeli metody referencyjne. Jednocześnie z uwagi na niski narzut czasowy metoda ta może być z powodzeniem stosowana w interfejsach mózg-komputer pracujących w trybie online*.

Praca składa się z 6 rozdziałów. Pierwszy z nich przedstawia charakterystykę sygnału EEG, zarówno w dziedzinie czasu jak i częstotliwości oraz omawia system do pomiaru aktywności elektrycznej mózgu człowieka. Rozdział drugi koncentruje się na artefaktach zanieczyszczających sygnał EEG oraz na sposobach ich unikania, a także wykrywania i usuwania. Szczególnie dużo uwagi poświęcono w nim różnym metodom filtracji przestrzennej. W kolejnym rozdziale przedstawiona została analiza składowych niezależnych. Opisany został tu zarówno model ICA, jak i podstawowe implementacje algorytmów pozwalających na rozwiązanie tego modelu zarówno

w przypadku zrównoważonym ($m=n$), jak i nieokreślonym ($m>n$). Podczas, kiedy trzy pierwsze rozdziały pracy zawierają przede wszystkim informacje teoretyczne, trzy kolejne mają charakter empiryczny. Rozdział czwarty przedstawia wstępne eksperymenty, które wykonano poszukując rozwiązania postawionego w rozprawie problemu badawczego. Centralnym rozdziałem pracy jest rozdział piąty, w którym przedstawiono autorską metodę MAICA. Metodę tę następnie zweryfikowano na drodze szeregu eksperymentów, których wyniki zostały opisane w rozdziale szóstym, będącym jednocześnie ostatnim w niniejszej rozprawie.

Niniejsza praca doktorska wnosi istotny wkład w dziedzinę informatyki, rozumianą jako dyscyplina naukowa zajmująca się przetwarzaniem informacji z użyciem komputerów [27]. Wkład ten, który stanowi przede wszystkim autorski algorytm MAICA, zgodnie z systemem CCS (Computing Classification System), opracowanym przez Stowarzyszenie na Rzecz Maszyn Obliczeniowych (ang. Association for Computing Machinery, ACM) można umiejscowić w klasie teorii obliczeń, a w szczególności w podklasie analiza algorytmów [28]. Ze względu na wykorzystane metody przetwarzania sygnałów, na których bazują algorytmy z rodziny ICA, praca oraz opracowana metoda jest umiejscowiona w klasie matematycznych metod obliczeń, a autorska implementacja algorytmu w klasie software. Użyteczność metody, a także mnogość urządzeń (elektroencefalograf, komputer, możliwość implementacji algorytmu na urządzeniach mobilnych), które mogą być użyte w systemie wykorzystującym algorytm MAICA dodatkowo dotyka klas zastosowania komputerów oraz środowisk obliczeniowych [28].

ROZDZIAŁ 1

SYGNAŁ EEG

Mózg jako organ od zawsze cieszył się zainteresowaniem człowieka. W czasach prehistorycznych był on co prawda traktowany głównie jako odżywczy posiłek oraz element wierzeń religijnych, jednak wraz z rozwojem ludzkości oraz dzięki ewolucji samego mózgu ludzie zaczęli się mu się również przyglądać z punktu widzenia anatomicznego. Już przed naszą erą Erasistratos (IV-III w. p.n.e.) odkrył cztery komory oraz zwoje w mózgu [29]. Prace Erasistratora były kontynuowane przez wielu nowożytnych badaczy, m.in.: lek. Thomasa Willisa (1621-1675), który opisał sieć tętniczą podstawy mózgu oraz jako pierwszy wprowadził słowo neurologia [30], czy Franza Galla, który przedstawił tezę, mówiącą o tym, że za poszczególne czynności mentalne oraz części ciała odpowiadają różne obszary mózgu [31]. Mózg badano również pod kątem działań odruchowo-warunkowych. W tym obszarze nie sposób nie wspomnieć o Iwanie Pawłowie [32], który, badając fizjologię wydzielania śliny przez psy w reakcji na określone bodźce, wprowadził podział na odruchy bezwarunkowe i warunkowe. Za swoje badania otrzymał Nagrodę Nobla w dziedzinie medycyny w 1904 roku. Współczesność to rozwój elektroencefalografii oraz rozkwit badań nad obrazowaniem mózgu. Badania te spowodowały, że mózgiem zaczęto interesować się ze względu na jego prawdziwą rolę i budowę oraz zaczęto postrzegać go jako zestaw połączonych neuronów, które decydują o ludzkim zachowaniu [33].

1.1 Rejestracja sygnału EEG

Elektroencefalografia jest techniką pozwalającą na odczyt aktywności elektrycznej generowanej przez struktury mózgu. Początki elektroencefalografii sięgają 1875 roku, kiedy to angielski fizyk i wykładowca szkoły medycznej, Richard Caton, zarejestrował sygnały elektryczne z odsłoniętych mózgów królików i małp [34]. Wyniki badań Catona zostały przez niego opublikowane w 1875 w *British Medical Journal* [35]. W kolejnych latach sposoby pomiaru oraz zapisu aktywności elektrycznej mózgu były ciągle ulepszane. Polskim akcentem w początkach elektroencefalografii jest Adolf Beck (1863-1942), polski fizjolog, który niezależnie od Catona wykazał, że wykonywanym przez mózg operacjom towarzyszą zjawiska elektryczne [32].

W 1924 roku Hans Berger, niemiecki neurolog, użył zwykłego sprzętu radiowego do wzmocnienia aktywności elektrycznej mózgu mierzonej z powierzchni ludzkiej głowy. Ogłosił, że słaby prąd elektryczny generowany w mózgu może być rejestrowany bez otwierania czaszki [36, 37]. W celu rejestracji sygnału Berger użył bardzo dużych elektrod płytkowych - najpierw wykonywanych z ołowiu, a później ze srebra - które umieścił nad czołem i potyliczną częścią czaszki. Berger początkowo był bardzo sceptyczny w stosunku do własnych badań i doskonale zdawał sobie sprawę z tego, że sygnały te mogą być artefaktami. Aby udowodnić, że sygnał zebrany ze skóry głowy nie jest artefaktem innych procesów fizjologicznych, lecz został rzeczywiście wygenerowany wewnątrz głowy, zarejestrował też szereg dodatkowych sygnałów bioelektrycznych, znacznie lepiej znanych w tamtym czasie (między innymi elektrokardiogram).


Od samego początku Berger interesował się związkami psychofizjologicznymi. Aktywność, którą obserwował, zmieniała się w zależności od statusu funkcjonalnego mózgu, takiego jak sen, znieczulenie, brak tlenu i niektóre choroby neuronalne, takie jak padaczka. Berger położył podwaliny pod wiele z obecnych zastosowań elektroencefalografii. Użył też słowa elektroencefalogram do pierwszego opisu potencjału elektrycznego mózgu u ludzi. Miał rację z sugestią, że aktywność mózgu zmienia się w spójny i rozpoznawalny sposób, gdy zmienia się ogólny status podmiotu, od relaksacji do czujności [37].

Współcześnie odczyt aktywności mózgowej z powierzchni czaszki dokonywany jest nadal, podobnie jak za czasów Bergera, za pomocą elektrod podłączonych do elektroencefalografu. Zmieniły się jedynie wielkość oraz inne parametry elektrod i elektroencefalografów. Rysunek 1.1.1 przedstawia aparaturę, której używał Hans Berger oraz współczesny elektroencefalograf.

Standardowy elektroencefalograf (nazywany niejednokrotnie w uproszczeniu wzmacniaczem EEG) składa się z bloku wzmacniaczy, zestawu filtrów oraz przetwornika analogowo-cyfrowego [8, 9]. Dzięki zastosowaniu wzmacniaczy sygnał o niskiej amplitudzie przenoszony jest w zakres, w którym może zostać przetworzony do postaci cyfrowej. Dbając o zdrowie pacjenta wzmacniacze elektroencefalograficzne posiadają niskie napięcie zasilające (3-6V). Czulość wzmacniacza ustawiana jest natomiast na 7–10 $\mu\text{V/mm}$ [38]. Wzmacniacze stosowane w elektroencefalografach są wzmacniaczami różnicowymi mającymi za zadanie wzmocnić różnicę potencjałów zarejestrowanych przez dwie elektrody, elektrodę sygnałową i

referencyjną. Wzmocniony sygnał jest poddawany działaniu filtra wygładzającego, którego zadaniem jest odcięcie z analogowego sygnału zarejestrowanego przez elektrody pomiarowe częstotliwości przekraczających częstotliwość Nyquista. Przefiltrowany sygnał jest następnie przekształcany przez przetwornik analogowo-cyfrowy. Zadaniem przetwornika analogowo-cyfrowego jest zmiana reprezentacji sygnału z analogowej na cyfrową [38, 39]. Po przeprowadzeniu tej operacji, dane, przedstawione w postaci serii wartości liczbowych odzwierciedlających zmiany amplitudy sygnału w czasie [9, 40], mogą być już przetwarzane oraz przechowywane w systemie komputerowym. W skład elektroencefalografu mogą również wchodzić filtry górno- oraz dolnoprzepustowe, które mają za zadanie eliminację artefaktów. Częstotliwość odcięcia filtra dolnoprzepustowego ustawiana jest najczęściej na 70 Hz, a jego zadaniem jest eliminacja artefaktów mięśniowych. Częstotliwość odcięcia filtra górnoprzepustowego wynosi natomiast najczęściej 1 Hz, a jego zadaniem jest eliminacja artefaktów niskiej częstotliwości takich jak np.: pocenie się. Filtry dolno- i górnoprzepustowe mogą stanowić element wzmacniacza, ale obecnie częściej są realizowane w postaci softwareowej.


Akwizycja sygnału EEG jest pracochłonnym procesem, który rozpoczyna się od wyznaczenia miejsc na powierzchni czaszki, w których zostaną umieszczone elektrody pomiarowe. Elektrody pomiarowe rozmieszczane są najczęściej w taki sposób, aby mogły rejestrować aktywność elektryczną generowaną w obydwu półkulach kory mózgowej (prawej i lewej) oraz czterech płatach (potylicznym, ciemieniowym, skroniowym i czołowym (Rysunek 1.1.2) [8, 41]. Światowym standardem w rozmieszczaniu elektrod jest układ zwany Systemem 10-20. Nazwa 10-20 odnosi się do odległości pomiędzy głównymi elektrodami układu, które wynoszą 10 lub 20 procent całkowitej przedniej-tylnej lub lewej-prawej długości czaszki badanego [42]. Elektrody są oznaczone literami zależnymi od płatów nad którymi się znajdują: F (ang. frontal) – płat czołowy, P (ang. parietal) – ciemieniowy, O – (ang. occipital) potyliczny, T (ang. temporal) – skroniowy. Oznaczenie numeryczne umieszczone po oznaczeniu literowym pozwala na rozróżnienie prawej (numery parzyste) oraz lewej (numery nieparzyste) półkuli, a także informuje o oddaleniu elektrody od linii środkowej (elektrody znajdujące się dalej od linii środkowej mają numery o większej wartości). Standardowe rozmieszczenie 21 elektrod podstawowych według systemu 10-20 przedstawione jest na Rys. 1.1.3.



Rysunek 1.1.1 a) Fotografia z aparaturą EEG z elektrodami z czasów Bergera, 1926 rok (źródło: https://www.mpiwg-berlin.mpg.de/resrep00_01/Jahresbericht_2_5_section.html), b) Współczesna aparatura do rejestracji sygnału EEG, przedstawiony model to: NEURO PRAX® EEG, (źródło: https://www.neurocaregroup.com/neuro_prax_eeg.html).


Miejsca na powierzchni czaszki, w których mają zostać umieszczone elektrody pomiarowe, powinny zostać odpowiednio przygotowane. Konieczność przygotowania powierzchni czaszki wynika z tego, że w warunkach normalnych skóra głowy pokryta jest różnego rodzaju tłuszczami oraz zrogowacieniami. Opór elektryczny nieprzygotowanej skóry jest dość duży i wynosi nawet $1\text{ M}\Omega$. Rejestracja aktywności mózgowej przy tak wysokim oporze najczęściej jest niemożliwa, ponieważ, z natury bardzo słaby, sygnał EEG zostaje dodatkowo osłabiony i ginie w szumie generowanym przez źródła pozamózgowe. W celu zmniejszenia impedancji skóry do akceptowalnej wartości (poniżej $5\text{ K}\Omega$), miejsca aplikacji elektrod przecierane są pastą ścierną, która usuwa zewnętrzną część skóry, nazywaną warstwą rogową [40].

Elektrody wykorzystywane do rejestracji aktywności elektrycznej mózgu dzieli się najczęściej na dwie grupy, elektrody mokre oraz suche, przy czym za bardziej dokładne uważa się te pierwsze [43]. Podczas montażu elektrod mokrych wykorzystuje się specjalne żele przewodzące, których zadaniem jest zmniejszenie impedancji oraz poprawienie parametrów odczytu – operacja ta nie jest konieczna w przypadku elektrod suchych, określanych czasami w literaturze jako elektrody kolczaste, ze względu na kształt elektrody [40]. W grupie elektrod mokrych znajdują się też tzw. elektrody wodne, w przypadku których substancją przewodzącą jest zwykła woda. Elektrody mogą być przymocowane do powierzchni czaszki za pomocą kleju lub osadzone w specjalnym czepku.



Rysunek 1.1.2 Rozmieszczenie pól mózgowych u człowieka.

Źródło: http://www.anatomia.gmo.pl/ukl_ner.html




Rysunek 1.1.3 Rozmieszczenie oraz nazewnictwo 21 elektrod EEG według systemu 10-20.

Źródło: <http://thomaskosch.com/index.php/2016/09/28/visualizing-real-time-brain-localization-in-3d/>

Elektrody umieszczone na powierzchni głowy rejestrują napięcia mierzone między każdą z elektrod sygnałowych, a wspólną elektrodą referencyjną (tzw. montaż monopolarny) lub między dwoma elektrodami sygnałowymi (tzw. montaż bipolarny). W montażu monopolarnym (Rysunek 1.1.4a) kanał EEG tworzony jest więc przez parę elektroda sygnałowa – elektroda odniesienia. Elektroda odniesienia może znajdować się w dowolnym miejscu ciała człowieka, niekoniecznie

na powierzchni głowy. W montażu bipolarnym różnice napięć są rejestrowane między dwiema elektrodami sygnałowymi, przy czym każda para tworzy osobny kanał EEG [44].



Rysunek 1.1.4 Montaż (a) monopolarny oraz (b) bipolarny.


Źródło: <https://neupsykey.com/electroencephalographic-electrodes-channels-and-montages-and-how-they-are-chosen/>

1.2 Właściwości sygnału EEG

Sygnał EEG ma postać szeregu czasowego, czyli sekwencji punktów danych zapisywanych w określonym czasie. Pojedyncza próbka sygnału odzwierciedla napięcie zarejestrowane w danym momencie czasu w danym kanale EEG (Rysunek 1.2.1). Napięcie rejestrowane przez elektrodę pomiarową jest wypadkową aktywności elektrycznej generowanej przez wiele tysięcy neuronów znajdujących się w obszarze recepcyjnym tejże elektrody. Stąd czasowy przebieg sygnału EEG rejestrowanego z pojedynczego kanału jest najczęściej nieregularny, wysoce nieliniowy, nie-gaussowski, losowy i nieskorelowany.

Cztery podstawowe charakterystyki wykorzystywane do opisu sygnału EEG to: napięcie, morfologia, lokalizacja oraz częstotliwość. Napięcie, jak wspomniano powyżej, to aktywność elektryczna generowana przez zespół neuronów, rejestrowana przez elektrodę powierzchniową. Zakres napięć sygnału EEG standardowo rejestrowanych w elektroencefalografii klinicznej wynosi od 10 μ V - 100 μ V [45, 46]. Wartości te są dość silnie zależne od techniki rejestracji oraz od jakości sprzętu rejestrującego, więc często, zwłaszcza w przypadku badań poza klinicznymi, mogą one znacznie odbiegać od podanego zakresu. Przy opisie sygnału EEG w kategoriach

napięcia wykorzystuje się pojęcia takie jak: tłumienie, hipersynchroniczność oraz napadowość. Tłumienie to nic innego jak zmniejszenie amplitudy (spadek napięcia) sygnału EEG wynikający najczęściej ze zmniejszenia liczby synchronicznie pracujących neuronów. Hipersynchroniczność, przejawiająca się wzrostem napięcia, jest przeciwieństwem tłumienia. Termin ten oznacza wzrost liczby elementów nerwowych przyczyniających się do powstania danego rytmu (synchronicznie pracujących na danej częstotliwości) [47]. Ostatni z terminów, napadowość, jest związany z tzw. grafoelementami, czyli krótkimi fragmentami sygnału wykazującymi określone cechy i pojawiającymi się w określonych stanach mózgu. Napadowość jest to wystąpienie zjawiska grafoelementu z nagłym początkiem, szybkim osiągnięciem maksimum (dość wysokie napięcie) i nagłym zakończeniem aktywności (powrót do niższej wartości napięcia) [48].




Rysunek 1.2.1 Jedna sekunda zarejestrowanej próbki surowego sygnału EEG. Źródło:

https://pdfs.semanticscholar.org/7e4c/65c0360c3cc35640ccbde44fc66f539bdc0d.pdf?_ga=2.203412051.371460869.1554716859-2058687032.1552914876

Druga z czterech wskazanych charakterystyk sygnału EEG - morfologia – informuje o kształcie przebiegu sygnału. Kształt sygnału EEG jest determinowany przez częstotliwości z którymi pracują różne grupy neuronów znajdujące się w polu recepcyjnym elektrody oraz ich zależności fazowe i napięciowe. Wzorce widoczne w sygnale mogą być: monomorficzne, polimorficzne, sinusoidalne oraz przejściowe. O wzorcach monomorficznych mówimy, gdy aktywność EEG wydaje się być złożona z jednej dominującej częstotliwości. W sytuacji, gdy aktywność EEG składa się z wielu częstotliwości, które łącząc się tworzą złożony kształt fali – mówimy o wzorcach polimorficznych. Wzorce sinusoidalne to wzorce przypominające fale sinusoidalne (aktywność monomorficzna zwykle jest sinusoidalna). Wreszcie wzorce przejściowe są rozpoznawane w sytuacjach, w których występuje izolowana fala lub wzór, który wyraźnie różni się od aktywności tła. Dwa najbardziej charakterystyczne wzorce przejściowe to fala ostra oraz kolec. Fala ostra to przejściowa fala ze spiczastym szczytem i czasem trwania 70-200 ms. „Kolec” (zwany również wyładowaniem iglicowym) jest również przejściową falą o spiczastym

szczycie, ale o znacznie krótszym czasie trwania: od 20 do 70 ms. Przykład fali typu „kolec” przedstawiony jest na Rysunku 1.2.2 (na przykład na początku przebiegu Fp2-F4).


Lokalizacja to informacja o miejscu zarejestrowania sygnału. W przypadku stosowania standardowego układu elektrod 10-20, lokalizacja to nic innego jak nazwa elektrody, bądź elektrod, tworzących dany kanał EEG. Informacja o lokalizacji sygnału jest bardzo istotna, ponieważ w przypadku wystąpienia sygnału odbiegającego od normy pomaga ustalić, które ośrodki mózgowe nie działają prawidłowo.



Rysunek 1.2.2 Sygnał EEG zarejestrowany u osoby dorosłej w stanie czuwania, przedstawiający asynchroniczne wyładowania iglicowe m.in. w obszarze ciemieniowym oraz skroniowym. Źródło: https://www.researchgate.net/publication/233536748_22q112_Microduplication_syndrome_and_epilepsy_with_continuous_spikes_and_waves_during_sleep_CSWS_A_case_report_and_review_of_the_literature/figures?lo=1

Częstotliwość sygnału EEG, standardowo mierzona w Herzach (Hz), to powtarzalna rytmiczna synchroniczna aktywność dużej grupy neuronów. Aktywność EEG o w przybliżeniu stałej częstotliwości określa się mianem aktywności rytmicznej. Z kolei aktywność, w której nie występują stabilne rytmy, nazywa się aktywnością arytmiczną. Wreszcie aktywność dysrytmiczna występuje w przypadku, kiedy charakterystyczne rytmy i/lub wzorce aktywności EEG, pojawiają

się rzadko, bądź jedynie u określonych grup pacjentów. Zakres częstotliwości normalnego sygnału EEG to 1 Hz - 100 Hz, przy czym rzadko kiedy udaje się zarejestrować z powierzchni czaszki sygnał o częstotliwości powyżej 50 Hz [49]. Opis częstotliwościowy sygnału jest realizowany poprzez analizę widma częstotliwościowego sygnału. Analiza częstotliwościowa polega na rozbiciu sygnału na występujące w nim fale sinusoidalne, a następnie na określeniu i porównaniu mocy poszczególnych fal. Widmo sygnału EEG dzieli się najczęściej na pięć pasm częstotliwości: delta, teta, alfa, beta oraz gamma (Rysunek 1.2.3).




Rysunek 1.2.3 Widmo mocy sygnału EEG, podzielone na pasma częstotliwości, kolejno: delta, teta, alfa, beta.

Źródło:

https://www.researchgate.net/publication/272147753_Mathematical_Modeling_of_Human_Brain_Neuronal_Activity_in_the_Absence_of_External_Stimuli/figures?lo=1

Rozkład sygnału EEG na poszczególne fale sinusoidalne dokonywany jest w taki sam sposób, jak w przypadku każdego innego szeregu czasowego, czyli tak jak pokazano to na Rysunku 1.2.4. Rysunek 1.2.4c jest trójwymiarowym obrazem przedstawiającym dwie fale sinusoidalne w przestrzeni czas-częstotliwość-amplituda. Rysunek 1.2.4a przedstawia rzut trójwymiarowego wykresu z Rysunku 1.2.4c wzdłuż osi częstotliwości. Na rysunku tym widać fale sinusoidalne w dziedzinie czasu oraz, umieszczony nad nimi, przebieg oryginalnego sygnału, będący niczym innym jak zwykłą sumą obu fal. Wreszcie Rysunek 1.2.4b przedstawia rzut wykresu z Rysunku 1.2.4c wzdłuż osi czasu. Każda fala sinusoidalna, wydzielona z sygnału oryginalnego, przedstawiona jest tu jako pionowa linia. Jej wysokość reprezentuje amplitudę, a jej pozycja przedstawia częstotliwość. Należy zaznaczyć, że omawiane przekształcenie nie powoduje

ani dodania, ani utraty informacji zawartej w sygnale - jest to jedynie inna reprezentacja tego samego sygnału. Dla każdego przebiegu sygnału w czasie istnieje odpowiednik w dziedzinie częstotliwości i vice versa.



Rysunek 1.2.4 Związek między domeną czasu i częstotliwości a) Sygnał w dziedzinie czasu b) Sygnał w dziedzinie częstotliwości c) Trójwymiarowy układ współrzędnych czas-częstotliwość-amplituda. Źródło: https://www.researchgate.net/figure/Figure2The-relationship-between-the-time-and-frequency-domains-a-Time-domain-view-b_fig1_280923204


1.3 Widmo sygnału EEG

Standardowe widmo częstotliwości sygnału EEG przedstawione zostało na Rysunku 1.2.3. Jak można zaobserwować, niższe częstotliwości posiadają wyższą amplitudę, wyższe natomiast, niższą. Wśród pięciu pasm (delta, teta, alfa, beta oraz gamma (pasmo powyżej 30Hz, nie przedstawione na rysunku), początkowo zdefiniowanych dla celów diagnostyki klinicznej, a obecnie powszechnie wykorzystywanych również w zastosowaniach pozamedycznych, najwyższą moc wykazują fale delta, najniższą natomiast fale gamma.

Im wyższa moc sygnału w danym paśmie częstotliwości (w porównaniu z mocą referencyjną), tym większe prawdopodobieństwo, że respondent jest w określonym stanie poznawczo-afektywnym związanym z tym pasmem. Jeżeli na przykład w widmie sygnału EEG obserwowany jest wzrost mocy w paśmie teta, to może to świadczyć o tym, że respondent znajduje

się w stanie wysokiego obciążenia umysłowego. Jeżeli natomiast w sygnale EEG dominują częstotliwości z pasma delta, to może to wskazywać na to, że respondent znajduje się w stanie snu [50].

Fale alfa zostały odkryte w 1929 roku przez wspomnianego w podrozdziale 1.1 Hansa Bergera. Zakres częstotliwości fal alfa wynosi od 8 do 13Hz (Rysunek 1.3.1c) [51]. Fale te powszechnie spotykane są u osób dorosłych (najbardziej widoczne są w trakcie relaksu z zamkniętymi oczami). Występują po obu stronach głowy, ale posiadają nieco wyższą amplitudę po stronie niedominującej i są najczęściej rejestrowane w okolicy potylicznej i ciemieniowej mózgu. Fale alfa indukują produkcję serotoniny, neuroprzekaźnika, który zwiększa relaksację i łagodzi ból [33].



Rysunek 1.3.1 Fale mózgowe w różnych pasmach częstotliwości (delta, teta, alfa, beta oraz gamma)

Źródło: <http://yogamudra.pl/wp-content/uploads/2014/06/fale-mozgowe.jpg>

Z uwagi na to, że poziom fal alfa wyraźnie maleje wraz ze wzrostem aktywności umysłowej lub fizycznej, fale te są powszechnie wykorzystywane w badaniach naukowych. Jedną z kategorii umysłowych często badanych w połączeniu z mocą fal alfa jest poziom skupienia uwagi. W badaniach nad poziomem skupienia uwagi badacze przedstawiają uczestnikom badania obiekty, słowa lub bardziej złożone bodźce i monitorują moc fal alfa podczas fazy kodowania

bodźców. U respondentów, którzy są rozproszeni najczęściej wykazywana jest większa moc tych fal [52]. Monitorowanie mocy fal alfa jest wobec tego użyteczne we wszystkich zadaniach, w których konieczne jest długotrwałe zachowanie wysokiego poziomu uwagi, takich jak np. prowadzenie samochodu [53, 54]. Wystarczy tu wspomnieć, że 40% wypadków drogowych jest spowodowanych przez nieuwagę kierowców [55]. Jak wspomniano, niższy poziom fal alfa wiąże się z mniejszym skupieniem, odzwierciedla więc on również stan relaksacji badanego człowieka. W związku z tym monitoring tych fal jest również wykorzystywany w badaniach nad głębokością medytacji, np. przy porównywaniu stopnia medytacji doświadczonych i początkujących medytujących [56]. Ponadto zwiększenie poziomu fal alfa jest jednym z podstawowych celów treningu neurofeedback stosowanego podczas rehabilitacji dzieci cierpiących na ADHD.

Zakres częstotliwości fal beta wynosi od 14 do 36 Hz (Rysunek 1.3.1b). Zwykle fale te są obserwowane w czołowej i centralnej części mózgu. Najczęściej posiadają rytmiczny przebieg i są zauważalne we wszystkich grupach wiekowych [33]. Aktywne, skupione myślenie oraz koncentracja są korelowane z wyższą mocą fal beta [57]. Poziom fal beta obserwowanych nad korą centralą wzrasta również wtedy, gdy planowane lub wykonywane są ruchy [58], w szczególności ruchy sięgania lub chwytania wymagające delikatnych ruchów palców i skupienia uwagi [59]. Co ciekawe, wzrost mocy w paśmie beta jest również zauważalny, gdy jedynie obserwowane są ruchy innych osób. Mózg pozornie naśladuje ruchy kończyn innych ludzi, co wskazuje, że w mózgu istnieje skomplikowany "system neuronów lustrzanych", który jest koordynowany przez fale beta [60].

Z uwagi na to, że fale beta obejmują bardzo szeroki zakres całego pasma sygnału EEG, stosuje się ich podział na trzy podzakresy, a mianowicie na fale: SMR (13-15Hz), beta1 (16-18Hz) i beta2 (18-36Hz) [61]. Pierwsze podpasmo opisywane jest jako rytm czuciowo-ruchowy, czyli rytm sensomotoryczny (ang. Sensorimotor Rhythm, SMR), ponieważ powstaje w pasie sensomotorycznym kory mózgowej. W 1971 roku Sterman udowodnił, że poprzez wzmocnienie fal SMR można zmniejszyć objawy epilepsji i przywrócić zdolność organizmu do utrzymania homeostazy [62]. Niski SMR obserwuje się u osób z deficytem uwagi (ADD), nadreaktywnością (ADHD) oraz zaburzeniami lękowymi i PTSD (syndromem stresu pourazowego) [63]. Stąd też

zwiększenie poziomu fal SMR jest celem treningu neurofeedback stosowanego w trakcie terapii osób cierpiących na wyżej wskazane dolegliwości.

Fale Beta1 odpowiadają za logiczne myślenie, koncentrację, pamięć i status emocjonalny. Wysoki poziom tych fal występuje w warunkach intensywnego wysiłku umysłowego oraz w trakcie realizacji procesów poznawczych, natomiast poziom niski towarzyszy deficytom intelektualnym, zaburzeniom koncentracji i uwagi. Zbyt wysoki poziom fal beta1 w półkuli niedominującej zaburza emisję fal SMR. Fale z ostatniego podpasma beta, beta2, są charakterystyczne dla osób niespokojnych lub nerwowych [64].

Zakres częstotliwości fal delta wynosi od 0,5 do 3 Hz [33] (Rysunek 1.3.1e). Fale te są najczęściej obecne podczas tzw. snu jednopółkulowego (ang. Unihemispheric slow-wave sleep, USWS), czyli gdy jedna półkula mózgu śpi natomiast druga jest w stanie czuwania lub snu wolnofalowego (ang. Non-rapid eye movement, NREM), czyli takiego, w którym nie występują marzenia senne. W laboratoriach snu sprawdza się siłę rytmu delta, aby ocenić głębokość snu. Im silniejszy jest rytm tej fali, tym głębszy jest sen. Moc fal delta jest zwykle wyższa w prawej półkuli mózgu, a źródła tych fal są zazwyczaj zlokalizowane w części mózgu nazywanej wzgórzem. Ponieważ sen wiąże się z konsolidacją pamięci, rytm delta odgrywa kluczową rolę w tworzeniu i wewnętrznym porządkowaniu pamięci biograficznej, a także w utrwalaniu nabywanych umiejętności i zdobywanej wiedzy. Fale delta są również powiązane z nieświadomymi czynnościami naszego ciała, takimi jak regulacja częstotliwości akcji serca i trawienie.

Fale delta są podstawowymi falami wykorzystywanymi w badaniach nad snem i jego zaburzeniami. Ponadto fale te monitoruje się również w trakcie badań nad niektórymi chorobami neurologicznymi, którym często towarzyszą zaburzenia snu, takimi jak choroba Parkinsona, demencja lub schizofrenia. Kolejnym zaburzeniem neurologicznym, którego nasilenie może być diagnozowane poprzez analizę poziomu fal delta jest alkoholizm. Alkohol ma silne skutki uboczne w postaci pogorszenia jakości snu. Intensywne picie zmniejsza ilość snu wolnofalowego, a zatem maleje poziom fal delta – jest to widoczne nawet po długich okresach abstynencji [65].

Oscylacje mózgu w zakresie częstotliwości 4 - 8 Hz (Rysunek 1.3.1d) są określane jako fale teta [51]. Oscylacje te koreluje się z operacjami umysłowymi wymagającymi większego

skupienia uwagi, na przykład operacjami związanymi z przyswajaniem oraz przetwarzaniem informacji, uczeniem się lub przywoływaniem wspomnień. Poziom fal teta rośnie wraz ze wzrostem trudności zadania. Z tego powodu rytm teta zwykle jest kojarzony z procesami leżącymi u podstaw obciążenia umysłowego lub pamięci roboczej [66, 67]. Fale teta są generowane przez szeroką sieć neuronów obejmującą przyśrodkowe obszary przedczołowe, centralne, ciemieniowe i przyśrodkowe obszary kory skroniowej. Z powodu tak szerokiego rozprzestrzenienia aktywności teta sugeruje się, że fale te mogą służyć również jako częstotliwość nośna do przetwarzania poznawczego w oddalonych od siebie regionach mózgu [68].

Z uwagi na związek mocy fal teta z obciążeniem umysłowym, poziom tych fal jest badany podczas wykonywania zadań związanych z nadzorem i monitorowaniem, na przykład takich jak: monitorowanie ruchu lotniczego lub morskiego, kierowanie pojazdami, czy unikanie przeszkód. Monitoring fal teta jest również stosowany w scenariuszach wojskowych, w których wyszkoleni obserwatorzy oceniają zdjęcia satelitarne obszarów walki, a złożone informacje muszą być przetwarzane w trybie natychmiastowym w celu uniknięcia sytuacji potencjalnie zagrażających życiu [69]. Innym rodzajem zadań, w których analizowany jest poziom fal teta są zadania związane z nawigacją przestrzenną. W zadaniach nawigacyjnych wykonywanych w środowisku rzeczywistym lub w rzeczywistości wirtualnej odkryto, że poziom fal teta wzrasta w złożonych układach labiryntów lub w kluczowych punktach orientacyjnych umieszczonych na trasie [70]. Wreszcie jednym z klasycznych zastosowań fal teta w psychologii poznawczej są wszelkie zadania związane z pamięcią roboczą. Jednym z przykładów może być np. zadanie N-powrotów. W tym zadaniu respondenci widzą na ekranie szybkie sekwencje liter, liczb lub ikon. Jednocześnie muszą pamiętać N-elementów wstecz i odpowiedzieć, czy element wykazuje pewne cechy (na przykład "Czy literą dwa kroki wcześniej była M?"). Wraz z dłuższymi przedziałami do zapamiętania wrasta intensywność fal teta (na przykład dla $N = 6$ w porównaniu do $N = 2$) [71].

Fale gamma są związane z percepcją i świadomością, ich zakres wynosi około 30 - 70 Hz (Rysunek 1.3.1a). Aktualnie niewiele wiadomo na temat fal gamma, ponieważ bardzo trudno jest je zarejestrować z powierzchni czaszki. Stąd wciąż nie jest jasne, w których obszarach mózgu fale te są generowane oraz jakim czynnościom odpowiadają. Niektórzy badacze twierdzą, że fale gamma, podobnie jak fale teta, służą jako częstotliwość nośna do wiązania różnych zmysłowych

wrażeń w spójną całość [72]. Inni twierdzą, że częstotliwość gamma jest produktem ubocznym innych procesów neuronalnych, takich jak np. ruchy oczu, a zatem nie odzwierciedla wcale przetwarzania kognitywnego [73].

Fale gamma obserwowane są np. podczas mikroskopowych badań ruchów gałek ocznych. W takim badaniu szybkie ruchy oka osoby badanej łączone są z szybkimi częstotliwościami widocznymi w sygnale EEG. Aby przeanalizować, w jaki sposób subtelne ruchy gałek ocznych wpływają na częstotliwości gamma, obiekty, które ma obserwować uczestnik badania pojawiają się w różnych pozycjach ekranu [74].

1.4 Przetwarzanie sygnału EEG

Jak zostało wcześniej wspomniane widmo sygnału EEG jest zazwyczaj dzielone na pięć podstawowych pasm częstotliwości. Zwiększenie/zmniejszenie mocy w poszczególnych pasmach względem wartości standardowych może świadczyć o występowaniu różnego rodzaju patologii. Czasami trudno jest wychwycić takie zmiany bez szczegółowej analizy. Analiza taka, wykonywana nawet przez wykwalifikowanego specjalistę pracującego w pracowni EEG, jest żmudna i męcząca. Ponadto, zapis EEG może być prowadzony w sposób ciągły przez wiele godzin, a czasami nawet i dni [75], co dodatkowo utrudnia, a nawet uniemożliwia monitorowanie zapisu bezpośrednio przez osobę nadzorującą pacjenta. W celu umożliwienia monitorowania rejestrowanego sygnału EEG oraz ułatwienia jego późniejszej analizy tworzone są systemy do automatycznego przetwarzania sygnału. System taki składa się najczęściej z czterech modułów:

1. modułu rejestracji sygnału,
2. modułu wstępnego przetworzenia sygnału,
3. modułu ekstrakcji cech,
4. modułu analitycznego.

W przypadku, kiedy przetwarzanie sygnału odbywa się w trybie ciągłym, pierwszym blokiem systemu jest blok rejestracji sygnału EEG. Blok ten jest oczywiście zbędny gdy przetwarzanie odbywa się w trybie offline, czyli gdy przetwarzany jest wcześniej zarejestrowany sygnał. Rejestracja sygnału odbywa się na zasadach opisanych w pierwszym podpunkcie niniejszego rozdziału.

Zadaniem drugiego bloku jest przetworzenie wstępne sygnału (ang. preprocessing). Celem działań wykonywanych w tym bloku jest takie przekształcenie sygnału zarejestrowanego przez elektrody pomiarowe, aby uzyskać sygnał o jak najwyższym stosunku sygnału do szumu. Sygnał jest tutaj poddawany filtracji, zarówno częstotliwościowej, jak i przestrzennej. Ponadto, dzięki zastosowaniu algorytmów specyficznych dla poszczególnych rodzajów artefaktów, składowe zakłócające są oddzielane od użytecznej części sygnału. Często na etapie wstępnego przetworzenia sygnału wykorzystywane są algorytmy ślepej separacji sygnałów.

Zadaniem kolejnego bloku (bloku ekstrakcji cech) jest wyodrębnienie takich cech sygnału, które w zwarty sposób opiszą badany sygnał jednocześnie minimalizując utratę ważnych informacji w nim zawartych. Dzięki temu zmniejszana jest ilość zasobów potrzebnych do przechowywania zbiorów sygnałów, zmniejszane są koszty ich przetwarzania oraz minimalizowana jest złożoność implementacji. Współcześnie w procesie analizy sygnałów EEG stosuje się różne metody ekstrakcji cech, pracujące zarówno na sygnale przedstawionym w postaci szeregu czasowego, jak i na sygnale przedstawionym w postaci widma częstotliwości [76]. W zależności od celu badania z sygnału ekstrahowane są cechy czasowe, częstotliwościowe, częstotliwościowo-czasowe bądź tworzone są różne ich połączenia.

Ostatni z modułów, moduł analityczny, oparty jest na procedurach analizy statystycznej lub/oraz na technikach maszynowego uczenia pozwalających na detekcję anomalii, rozpoznawanie wzorców, czy szeroko pojętą klasyfikację. Zadaniem tego modułu jest przekształcenie informacji zawartych w zbiorze cech (bądź w samym sygnale, w przypadku kiedy w systemie pominięty jest blok ekstrakcji cech) w taki sposób, aby ułatwić późniejszą interpretację sygnału lekarzowi diagnoście lub wręcz dostarczyć gotowych odpowiedzi typu: ‘użytkownik systemu jest rozproszony lub podenerwowany’ (w przypadku systemów monitoringu) lub ‘użytkownik systemu wyobraził sobie ruch prawej ręki’; ‘użytkownik systemu wybrał klawisz ‘A’ na klawiaturze’ (w przypadku interfejsów mózg-komputer).

Chociaż teoretycznie ta sama informacja jest zawarta w sygnale EEG przedstawionym w dziedzinie czasu oraz w sygnale przedstawionym w dziedzinie częstotliwości, to wartość interpretacyjna obu postaci sygnału jest znacząco różna. Analiza szeregu czasowego sygnału EEG daje odpowiedź na pytanie czy u badanego podmiotu wystąpił charakterystyczny kształt przebiegu

sygnału. Z kolei analiza widma częstotliwościowego, informująca o wzroście/spadku mocy w poszczególnych pasmach częstotliwości w poszczególnych ośrodkach mózgowych, daje odpowiedź na pytanie o to jak silnie poszczególne ośrodki są zaangażowane w aktualnie wykonywane zadanie.

Obserwacja sygnału w dziedzinie czasu jest bardziej tradycyjnym sposobem badania sygnału EEG [77]. Zaletami tego podejścia jest możliwość badania długich ciągłych segmentów sygnału oraz to, że sygnał przetwarzany jest w swojej „naturalnej” postaci. Należy zaznaczyć, że aby możliwe było wyciągnięcie istotnych konkluzji z obserwowanego sygnału, wymagane jest, aby był on przedstawiony w możliwie jak najczystszej postaci (z jak najmniejszym udziałem komponentów odzwierciedlających aktywność źródeł pozamózgowych). Analiza czasowa sygnału EEG jest najczęściej przeprowadzana w diagnostyce medycznej oraz w badaniach psychologicznych. W diagnostyce medycznej kształt przebiegu czasowego sygnału EEG może być badany np. w celu znalezienia wyładowań iglicowych charakterystycznych dla napadu epilepsji. Z kolei w badaniach psychologicznych analiza czasowa sygnału EEG jest stosowana najczęściej w trakcie badania potencjałów związanych ze zdarzeniem (ERP ang. Event Related Potentials).

Analiza widma częstotliwościowego jest natomiast stosowana wszędzie tam, gdzie dokładny kształt przebiegu czasowego zarejestrowanego z danego ośrodka mózgowego jest nieistotny, a główna informacja jest zawarta we względnej lub bezwzględnej wartości mocy sygnału w poszczególnych pasmach częstotliwości. Przy czym obecnie analizie podlega nie tyle sama moc sygnału, co różnorodne metryki porównujące moc w poszczególnych pasmach częstotliwości bądź ośrodkach mózgowych. Jedną z przykładowych metryk jest metryka asymetrii czołowej [78]. Miernik ten odnosi się do różnicy w aktywności lewej i prawej półkuli mózgu. Asymetryczność wiązana jest z różnymi stanami emocjonalnymi, takimi jak strach, gniew czy agresja. Asymetrię czołową najczęściej bada się w dwóch pasmach częstotliwości, teta i alfa [79].

1.5 Analiza sygnału EEG - zakres zastosowań

Elektroencefalografia stanowi jedną z podstawowych metod umożliwiających ustalenie w obiektywny sposób oceny stanu czynnościowego ośrodkowego układu nerwowego. Zaletami tej

metody są: możliwość bezpośredniego wglądu w podstawowe mechanizmy działania struktur mózgowia, wykonanie badania w sposób nieinwazyjny oraz względnie niewielki koszt zakupu aparatury. Dzięki temu analiza sygnałów EEG znajduje zastosowanie nie tylko w medycynie, ale również w wielu dziedzinach komercyjnych i akademickich.

1.5.1 Medycyna

Podstawowym obszarem, w którym powszechnie wykorzystywane są sygnały EEG jest medycyna. W medycynie informacje dostarczane w wyniku analizy sygnałów EEG wykorzystywane są wszechstronnie, m.in. w profilaktyce, diagnostyce, rehabilitacji a nawet w odbudowie uszkodzeń powstałych w ludzkim organizmie.

Profilaktyka zdrowotna oznacza działania mające na celu zapobieganie chorobom poprzez odpowiednie monitorowanie różnych czynników chorobotwórczych, jak i wczesne wykrywanie i leczenie spowodowanych przez nie uszkodzeń. Tylko z powodu z powodu palenia papierosów corocznie umiera około 7 milionów ludzi [80] oraz około 2.5 miliona z powodu alkoholu [81]. Obie wymienione używki w sposób charakterystyczny wpływają na działanie mózgu, a ich nadużywanie może być wykrywane poprzez analizę fal EEG [82, 83, 84]. Analiza sygnału pozwala na kontrolowanie poziomu uszkodzeń mózgu wynikającego z palenia lub picia alkoholu oraz na odpowiednio wczesną reakcji w przypadku występowania przesłanek sugerujących potencjalne zmiany chorobowe.

Inną chorobą, której przebieg może być monitorowany za pomocą informacji ekstrahowanych z sygnału EEG jest choroba lokomocyjna. Choroba ta jest określana jako nieprawidłowa reakcja organizmu na rzeczywisty lub przewidywany ruch. Powstaje ona poprzez brak zgodności błędnika z bodźcami (sygnałami wzrokowymi) odbieranymi przez mózg. Choroba ta ujawnia się w trakcie korzystania z łodzi, pociągów, samolotów, samochodów oraz w parkach rozrywki. Chociaż zidentyfikowano wiele biomarkerów związanych z chorobą lokomocyjną to sposób oszacowania jej poziomu u człowieka jest ciągle dużym wyzwaniem. Sygnały EEG z obszaru potylicznego pozwalają monitorować aktualny poziom choroby, co z sukcesem zostało potwierdzone w symulatorze jazdy samochodem opartym na wirtualnej rzeczywistości [85].

Pozwala to na opracowanie systemu, który badałby aktualny poziom choroby lokomocyjnej oraz odpowiednio reagował w przypadku przekroczenia poziomu niebezpiecznego dla danej osoby.

Kolejnymi obszarami medycyny wykorzystującymi informacje dostarczane przez analizę sygnałów EEG jest diagnostyka zmian chorobowych. W odróżnieniu od profilaktyki, diagnostyka zajmuje się sygnałami dotyczącymi zmian chorobowych, którym już nie można zapobiec. Monitorowanie stanu mózgu za pomocą aparatury EEG pozwala na wykrywanie wielu problemów zdrowotnych, takich jak nienaturalna struktura mózgu (np. guza/raka mózgu), zaburzenie drgawkowe (takie jak epilepsja), zaburzenie snu (np. narkolepsja) i obrzęk mózgu (np. zapalenie mózgu). Guz mózgu jest jedną z tych chorób, przy której badanie elektroencefalograficzne może szczególnie pomóc w postawieniu szybkiej diagnozy [86, 87]. Do czasu pojawienia się zaawansowanego obrazowania (tomografia komputerowa, MRI), lokalizacja guzów mózgu i innych zmian ogniskowych była trudna. Dawniejsze techniki neuroobrazowania, obejmujące radiografię czaszki, która nie zawsze odzwierciedlała rzeczywisty stan, oraz pneumoencefalogramy, które były inwazyjne i bolesne, nie były w pełni wiarygodne.

Kolejną chorobą, przy diagnozie której można wykorzystać sygnały EEG jest padaczka inaczej określana jako epilepsja. Jest to przewlekła choroba mózgu, która powoduje zaburzone funkcjonowanie grup komórek nerwowych. Jej objawem jest występowanie powtarzających się napadów. Wykrywanie napadów epileptycznych jest realizowane przez doświadczonych klinicystów poprzez wizualną obserwację sygnałów EEG. Jest to zwykle proces czasochłonny i podatny na błędny. Aktualnie prowadzone badania pokazują wysoką skuteczność automatycznych systemów do wykrywania zbliżających się napadów epilepsji oraz ich zapobiegania. W [88] przedstawiono automatyczny system diagnostyczny do wykrywania napadów epilepsji oparty na nieliniowej analizie sygnałów EEG, działający ze średnią dokładnością 99.25%.

Dysleksja to niewyjaśniona niezdolność do nauki dokładnego lub płynnego czytania, która dotyczy około 5-17% dzieci [89]. Również w przypadku tej choroby analiza sygnału EEG może bardzo ułatwić postawienie prawidłowej diagnozy. Dysleksja wiąże się bowiem ze strukturalnymi i funkcjonalnymi zmianami w różnych obszarach mózgu, które wspierają czytanie. Badania neuroobrazowania u niemowląt i dzieci w wieku sprzed okresu rozpoczęcia nauki czytania sugerują, że zmiany te widoczne są w mózgu dziecka przed osiągnięciem umiejętności czytania i

postępują wraz z rozwojem mózgu. Wczesna identyfikacja ryzyka dysleksji ma ważne implikacje dla jej remediacji i złagodzenia skutków psychospołecznych zwykle związanych z niepowodzeniami podczas nauki czytania [90]. Wykazano, że u osób z dysleksją górne częstotliwości pasma teta pokazują inne wzorce niż u osób w pełni zdrowych [91, 92].

Inną z chorób, której diagnozę ułatwia analiza sygnału EEG jest zespół nadpobudliwości psychoruchowej z deficytem uwagi (ang. Attention Deficit Hyperactivity Disorder, ADHD). Zespół ten jest rozumiany jako brak uwagi i koncentracji i jest jednym z najczęściej występujących zaburzeń poznawczych. Z uwagi na to, że z sygnałów EEG można wyekstrahować dość dużą ilość informacji związanych z umiejętnościami poznawczymi, ich stosowanie przy wykrywaniu ADHD jest powszechnie stosowane. Szczególne znaczenie odgrywa tu analiza fal teta oraz beta [93, 94]. Jako że diagnostykę ADHD prowadzi się najczęściej wśród dzieci, akwizycja sygnału EEG odbywa się z reguły podczas wykonywania czynności takich jak granie w gry komputerowe. Dokładność wykrywania ADHD poprzez analizę stopnia koncentracji na zadaniu sięga 98% [95].

Rehabilitacja jest kolejnym z obszarów medycyny, w którym znajduje zastosowanie analiza sygnału EEG. Jedną z poważniejszych chorób, po których wymagana jest rehabilitacja jest niedowład bądź paraliż kończyn powstały wskutek udaru mózgu. Metody wspomagania chorych po udarze mózgu były przedmiotem wielu badań. W badaniach tych wykazano, że struktury mózgu uszkodzone na skutek udaru można zreorganizować [96], a uszkodzone funkcje motoryczne można przywrócić dzięki wykorzystaniu informacji zawartych w sygnale EEG [97, 98]. Poprzez monitorowanie mocy fal alfa nad regionami motorycznymi kory mózgowej rehabilitant w trakcie sesji rehabilitacyjnej może wykryć, czy pacjent stara się wykonać ruch sparaliżowaną częścią ciała i w przypadku jego wykrycia może wspomóc wysiłki pacjenta, co dodatkowo motywuje go do pracy. Najczęściej do tego celu wykorzystywane są sygnały EEG rejestrowane z kory ruchowej [99]. Niewątpliwym wsparciem może tu być zaprojektowany i wdrożony przez m.in. [100] system, gdzie pacjent steruje elektryczną ortopedyczną ręką, która otwiera i zamyka jego dłonie.

1.5.2 Interfejs mózg-komputer

Według Światowej Organizacji Zdrowia około 15% światowej populacji żyje z pewnego rodzaju niepełnosprawnością, spowodowaną zarówno przebytymi urazami (uszkodzenie mózgu

lub rdzenia kręgowego), jak i przebytymi chorobami (np. stwardnienie rozsiane, udar mózgu, stwardnienie zanikowe boczne, miastenia ciężka, porażenie mózgowe itp.). W przypadku cięższych przypadków niepełnosprawności, kiedy osoba niepełnosprawna nie może nawiązać kontaktu z otoczeniem za pomocą standardowych środków komunikacji (dotyk, mowa, gesty, ruch itp.) z pomocą przychodzą interfejsy mózg-komputer.

Zgodnie z formalną definicją podaną przez Wolpawa [101], interfejs mózg-komputer (ang. Brain-Computer Interface, BCI) jest systemem komunikacji, w którym wiadomości oraz komendy sterujące wysyłane przez użytkownika do świata zewnętrznego nie są przekazywane przez standardowe ścieżki wyjściowe mózgu, którymi są nerwy obwodowe oraz mięśnie. Zamiast tego wzorce aktywności mózgowej odpowiadające wysyłanym komunikatom są odczytywane bezpośrednio z mózgu za pomocą dedykowanego urządzenia, na przykład aparatu EEG. Interfejsy mózg-komputer są dedykowane głównie dla osób niepełnosprawnych, dla których często stanowią jedyną możliwość skomunikowania się z światem zewnętrznym [102].

Interfejsy mózg-komputer umożliwiają osobom niepełnosprawnym przede wszystkim kontrolę środowiska zewnętrznego, poprzez sterowanie oświetleniem lub urządzeniami takimi jak telewizor, klimatyzacja, odtwarzacze video itp. [103]. Dostępne są również wyniki badań, w których z powodzeniem testowano nie tylko polecenia sterujące przełączaniem kanałów telewizyjnych, lecz również sterujące otwieraniem i zamykaniem drzwi oraz okien, a także polecenia umożliwiające nawigację i konwersację [104]. Osoby niepełnosprawne z lżejszym stopniem niepełnosprawności ruchowej, mogą wykorzystywać interfejsy mózg-komputer również np. do kierowania robotycznymi kończynami oraz do sterowania wózkiem inwalidzkim. W tym zakresie wykonano już bardzo wiele prac, przegląd obecnie dostępnych i stosowanych rozwiązań przedstawiono np. w [107]. Poza funkcją kontroli interfejsy mózg-komputer umożliwiają również osobom niepełnosprawnym komunikację z otoczeniem. Różnego rodzaju wirtualne klawiatury pozwalające na pisanie i edytowanie tekstu za pomocą sygnałów mózgowych są dość często implementowanym zastosowaniem. W rozwiązaniach tego typu, bardzo często wykorzystuje się potencjał P300 oraz niskobudżetowe urządzenia EEG typu Emotiv EPOC czy OpenBCI [105, 106].

Nie tylko osoby niepełnosprawne mogą wykorzystać interfejsy mózg-komputer. Stosuje się je również np. do monitoringu funkcji mózgowych w trakcie zadań wymagających skupienia uwagi (np. prowadzenia samochodu) oraz informowania o wszelkich odstępstwach od pożądanego poziomu. Innym zastosowaniem przeznaczonym dla szerokiego kręgu odbiorców są gry komputerowe, w których proces sterowania jest wspomagany analizą aktywności mózgowej. Przykład takiej gry, która została przetestowana przez szeroką publiczność podczas publicznego wydarzenia, podano m.in. w [108]. Interfejsy mózg-komputer oparte na różnego rodzaju prostych grach są również szeroko wykorzystywane w zastosowaniach rehabilitacyjnych oraz leczniczych. Aktualnie prowadzone badania dowodzą, że gry oparte na monitoringu sygnału EEG (neurofeedback) mogą wspomagać powrót do zdrowia [109, 110]. Wykorzystanie właściwości fal alfa jest używane jako wspomaganie leczenia dzieci z porażeniem mózgowym i niepełnosprawnością ruchową [109]. Projektowane są również zaawansowane gry wieloosobowe, tworzone w środowisku 3D. Bazują one na monitorowaniu poziomu uwagi, mierzonego za pomocą wartości mocy w pasmach alfa, beta oraz teta [110].

1.5.3 Inne zastosowania

Marketing i promocja produktów poprzez kampanię reklamową jest dobrze znaną praktyką zwiększania sprzedaży i świadomości wśród konsumentów. Zabiegi te mają jeden główny cel, zwiększenie uzyskanego zysku. Znajomość preferencji konsumentów w zakresie podejmowania decyzji i przewidywania zachowania w celu efektywnego wykorzystania produktu przy użyciu procesów nieświadomych nosi nazwę "Neuromarketingu". W badaniach neuromarketingowych kluczową rolę odgrywa badanie procesu aktywacji mózgu pod wpływem określonych bodźców. Umożliwia to sprawdzenie, czy i jak respondent reaguje na reklamę oraz czy reakcja jest właściwa – czyli czy reklama stymuluje mózg w sposób zgodny z założeniem reklamodawcy [111, 112]. Najczęściej w badaniach neuromarketingowych prowadzonych z wykorzystaniem sygnału EEG analizowana jest aktywność kory przedczołowej oraz moc fal teta, które są miarą tego, jak bardzo reklama zapada w pamięć badanego.

Kolejną dziedziną, w której coraz częściej korzysta się z analizy sygnałów mózgowych rejestrowanych za pomocą systemów EEG jest bezpieczeństwo systemów komputerowych. Z punktu widzenia bezpieczeństwa systemu komputerowego kontrola dostępu jest centralnym

elementem zapewniającym uprawnionym użytkownikom dostęp do zasobów w sposób autoryzowany. Taka kontrola dostępu uniemożliwia nieautoryzowanym użytkownikom dostęp do zasobów, a także pozwala uprawnionym użytkownikom na korzystanie z zasobów, zgodnych z ich uprawnieniami [113]. Cechy charakterystyczne mózgu, takie jak chaotyczny charakter i niepowtarzalność, sprawiają, że stanowi on źródło informacji możliwych do zastosowania w systemach autoryzacji. Wiele z takich systemów zostało już z powodzeniem zaprojektowanych oraz stworzonych [113, 114, 115]. Jednym z przykładów uwierzytelniania z użyciem sygnałów EEG rejestrowanych przy wykorzystaniu elektroniki konsumenckiej są bezprzewodowe słuchawki z osadzonymi czujnikami EEG. System taki uzyskuje 99% dokładności uwierzytelniania przy użyciu jednokanałowego sygnału EEG, bazującego na tzw. elektrodach suchych [115].

Coraz częściej systemy EEG są wykorzystywane również w sporcie. Aby osiągnąć dobre wyniki w sporcie, należy wziąć pod uwagę pracę mózgu, ponieważ determinuje ona zarówno kontrolę motoryczną, jak i kluczowe czynniki psychologiczne, takie jak motywacja wewnętrzna, selektywna uwaga, wyznaczanie celów, pamięć robocza, podejmowanie decyzji, pozytywna koncepcja siebie oraz samokontrola [116]. Chociaż poszukiwanie neuronalnych biomarkerów wydajności pozostaje wciąż wyzwaniem w nauce ruchu i psychologii sportu, to nieinwazyjny charakter zapisu elektroencefalograficznego EEG sprawił, że jest to najbardziej obiecująca metoda dostarczania ilościowych informacji zwrotnych praktykom i trenerom [116].

ROZDZIAŁ 2

PRZETWARZANIE WSTĘPNE SYGNAŁÓW EEG

Dobrze wykonane przetwarzanie wstępne w nieinwazyjnym systemie do badania sygnału EEG stanowi kluczowy element całej analizy. Można wyróżnić dwa podstawowe cele przetwarzania wstępnego, mianowicie: eliminacja sygnałów niepożądanych (artefaktów) oraz wzmocnienie sygnałów pożądaných [117, 118, 119]. Metody detekcji artefaktów radzą sobie z pierwszym zadaniem, filtry przestrzenne z obydwojma wyżej wymienionymi [120, 121, 122]. W niniejszym rozdziale zostanie przedstawione pojęcie artefaktu oraz zostaną opisane metody detekcji i eliminacji artefaktów.

2.1 Artefakty w sygnale EEG

Zgodnie z definicją podaną m.in. przez [123, 124, 125] artefaktem w sygnale EEG są wszystkie niepożądane sygnały pochodzenia nie-mózgowego, które pojawiają się w zapisie EEG. Sygnały te mogą „nachodzić” na rzeczywisty zapis aktywności mózgowej i przez to mogą być błędnie interpretowane jako prawdziwe sygnały EEG. Z tego względu istnieje konieczność ich unikania lub w razie niemożliwości uniknięcia, minimalizowania ich wpływu na pozyskany sygnał.

Przebieg oryginalnego sygnału EEG zmienia się pod wpływem zakłóceń, co ma niekorzystny wpływ na jego jakość oraz poprawność interpretacji [126, 127]. Zakłada się, że podczas klasycznej akwizycji sygnału EEG, około 20% z pozyskanych danych jest w znacznym stopniu zanieczyszczonych artefaktami [127, 128]. Tak znaczący procent zakłóceń może powodować wadliwą interpretację sygnału, w efekcie czego jego klasyfikacja (np. przypisanie go do danej jednostki chorobowej) może być nieprawidłowa [127]. Usuwanie artefaktów jest więc tym istotniejsze, im większą rolę odgrywa dokładność interpretacji.

Artefakty znajdujące się w sygnale EEG można podzielić na dwa typy: fizjologiczne i nefizjologiczne [129, 130]. Do artefaktów nefizjologicznych zalicza się artefakty wynikające z: przemieszczenia elektrody, aktywności mechanicznej urządzeń otaczających osobę badaną oraz

aktywności elektrycznej. Natomiast do artefaktów fizjologicznych zalicza się m.in. artefakty wynikające z ruchów gałek ocznych, powiek, bicia serca oraz aktywności innych mięśni [129, 130]. Podział artefaktów ze względu na ich typ oraz pochodzenie przedstawiony jest w Tabeli 2.1.1.

Typ	Nazwa	Pochodzenie
Fizjologiczne	Oczny	Mruganie, ruchy oka
	Mięśniowy	Żucie, połykanie, wężanie, mówienie
	Sercowy	Puls EKG
Niefizjologiczne	Przyrządowy	Przesunięcie lub odłączenie elektrody, ruchy kabli, złe uziemienie
	Zakłóceniewy	Wysokonapięciowe urządzenia w otoczeniu
	Ruchowy	Ruchy głowy i ciała
Pozostałe	Przewodnictwo objętościowe i superpozycja	Pomiary aktywności neuronalnej z jednego obszaru mózgu za pomocą wielu elektrod
	Inne	Oddychanie

Tabela 2.1.1 Podstawowe rodzaje artefaktów zakłócających sygnał EEG. Źródła:

https://www.researchgate.net/publication/325495058_Identification_and_Removal_of_Physiological_Artifacts_from_Electroencephalogram_Signals_A_Review

https://www.researchgate.net/publication/275955830_Methods_for_Artifact_Detection_and_Removal_from_Scalp_EEG_A_Review

2.1.1 Artefakty pochodzenia niefizjologicznego

Artefakty pochodzenia niefizjologicznego to zakłócenia wynikające z oddziaływania czynników zewnętrznych. Wśród najczęściej wymienianych artefaktów niefizjologicznych znajdują się zakłócenia wynikające z: oddziaływania sieci elektrycznej (artefakt sieciowy), złego działania sprzętu oraz nieprawidłowej pracy elektrod [125, 126, 129, 131, 132].

Najpopularniejszym, a jednocześnie stosunkowo łatwym do usunięcia jest artefakt sieciowy. Artefakt ten powoduje wystąpienie w sygnale EEG składowej o częstotliwości równej częstotliwości linii transmisyjnych obowiązujących w danym kraju, wynoszącej 50 lub 60 Hz. Artefakt ten wprowadza zakłócenie w paśmie gamma sygnału EEG. Artefakt sieciowy można łatwo usunąć za pomocą filtra pasmowo-zaporowego, wycinającego z sygnału EEG niepożądaną składową częstotliwościową [125, 126, 132].

Słaby kontakt elektrody ze skórą głowy wywołuje wystąpienie w sygnale artefaktu o niskiej częstotliwości. Artefakt ten jest ograniczony do jednej elektrody i synchronizuje się z aktywnością oddechową badanej osoby, która wywołuje przemieszczanie się elektrody na skórze głowy [132]. Prawidłowe umiejscowienie elektrod oraz przygotowanie skóry głowy minimalizuje możliwość występowania tego artefaktu [125, 129, 126].

Kolejne zakłócenia pochodzenia нефизjologicznego są powodowane przez urządzenia elektroniczne. Promieniowanie o wysokiej częstotliwości z różnych urządzeń, takich jak m.in. radio, telewizor, telefon komórkowy może zakłócać pracę wzmacniaczy EEG [125, 129, 132]. Istnieje wówczas możliwość zaistnienia sytuacji, w której sygnał EEG nie może zostać poprawnie zarejestrowany, ponieważ wykazuje systematyczne odchylenie w jedną stronę. Rozwiązaniem tego problemu jest wyłączenie wskazanych powyżej urządzeń podczas rejestracji sygnału EEG [132]. Wyłączenie urządzeń powinno być dokonane na etapie przygotowania do badania.

Na etapie przygotowania do badania należy również poinstruować badanego oraz pozostałe osoby znajdujące się w pomieszczeniu, aby ograniczyły przemieszczanie się (o ile jest to możliwe). Wszelkie ruchy badanego oraz innych osób znajdujących się w niedalekiej odległości od badanego przyczyniają się do ruchu przewodów łączących elektrody pomiarowe ze wzmacniaczem EEG oraz mikro-przemieszczeń elektrod po powierzchni skóry głowy, co niekorzystnie wpływa na rejestrowany sygnał [125, 129, 132]. Morfologia tego artefaktu oraz jego amplituda, różni się w znaczny sposób od rzeczywistego EEG [132].

Wielu artefaktów нефизjologicznych można uniknąć poprzez odpowiednie przygotowanie i poinstruowanie osoby badanej oraz odpowiedni montaż elektrod. Elektrody powinny ściśle przylegać do powierzchni głowy, a znajdująca się pod nimi skóra powinna być odpowiednio przygotowana (oczyszczona i odtłuszczona). Proces nakładania elektrod jest czasochłonny, aby więc nie powtarzać tej czynności warto dokładnie skontrolować montaż elektrod przed badaniem a w trakcie samej akwizycji na bieżąco monitorować jego poprawność.

2.1.2 Artefakty pochodzenia fizjologicznego

Artefaktami fizjologicznymi określa się sygnały powstałe z powodu aktywności elektrycznej generowanej przez inne, aniżeli mózg, części ciała badanego podmiotu [125, 132].

Źródła artefaktów pochodzenia fizjologicznego mogą być zaklasyfikowane do jednej z trzech kategorii: aktywność mięśniowa (ang. electromyography, EMG), aktywność oczna (ang. electrooculography, EOG) oraz aktywność serca (electrocardiography, ECG) [126].

Artefakty mięśniowe to sygnały generowane przez ruch mięśni. Artefakty te inaczej nazywane są artefaktami EMG, ze względu na to, że mogą być wykrywane podczas badania elektromiograficznego. Sporadycznie określane są również mianem artefaktów miogennych, czyli wynikających z pracy mięśni a nie neuronów. Artefakt EMG występujący w sygnale EEG generowany jest przez niezależne grupy różnych mięśni, w tym przede wszystkim mięśni głowy, twarzy i szyi [133]. W szczególności występowanie tego artefaktu jest związane z zaciskaniem mięśni szczęk (np. żucie, połykanie, ruchy języka) oraz grymasami twarzy [132]. W zależności od tego, które mięśnie spowodowały powstanie artefaktu mięśniowego, będzie on obserwowany z różną siłą w różnych kanałach EEG. Na przykład elektrody czołowe są wrażliwe na ruchy mięśni twarzy (mięsień marszczący brwi i mięsień czołowy), elektrody skroniowe i centralne są wrażliwe na ruchy mięśni przeznaczonych do żucia pokarmów (głównie mięśnie żuchwy oraz mięśnie skroniowe), a elektrody potyliczne wykazują wrażliwość na ruchy mięśni szyi i ramion.

Definicja artefaktu EMG jest dodatkowo komplikowana przez fakt, że sygnał pochodzący z każdej grupy mięśni charakteryzuje się odmiennymi widmami mocy [133]. Generalnie sygnał EMG mięśni szkieletowych i twarzy ma bardzo szeroki rozkład częstotliwości – od 0 do 200 Hz [134]. Poszczególne mięśnie pracują jednak w znacznie węższych zakresach częstotliwości. Na przykład spektrum częstotliwości mięśni czołowych pokrywa pasma 20-30Hz, natomiast mięśnie skroniowe posiadają najczęściej wielomodalne widma o niskim pikie około 20 Hz i szerokim grzbiecie od 40 do 80 Hz. Ustalenia dotyczące wpływu aktywności EMG na poszczególne pasma częstotliwości sygnału EEG przedstawiane w literaturze są sprzeczne [134]. Niektórzy autorzy przyjmują, że aktywność EMG wpływa na pasmo częstotliwości alfa, beta, a czasami również delta [132, 135], inni podają, że artefakty EMG najbardziej widoczne są w częstotliwościach powyżej 13 Hz [133, 134]. Bezspornym jest jednak fakt, że najczęściej artefakty mięśniowe zakłócają pasmo beta właściwego sygnału EEG [132]. Obecność aktywności miogennej w sygnale EEG została przekonująco wykazana przez [136], który zarejestrował EEG podczas prostego zadania poznawczego przed i po podaniu blokady nerwowo-mięśniowej, która sparaliżowała

mięśnie skóry głowy. Po podaniu blokady moc EEG w paśmie 25–30 Hz została zmniejszona o 84% [133]. Artefakty EMG są identyfikowane na podstawie częstotliwości, czasu trwania i morfologii sygnału [125, 137].

Kolejna rodzina artefaktów pochodzenia fizjologicznego, to artefakty powstające na skutek ruchu gałek ocznych [125, 132]. Artefakty związane z ruchem gałki ocznej nazywa się artefaktami EOG, ponieważ mogą być wykrywane za pomocą badania elektrookulograficznego rejestrującego potencjały związane właśnie z ruchem gałki ocznej. Potencjały związane z ruchami oczu rejestrowane są głównie w odprowadzenia przednich (w korze czołowej i przedczołowej). Potencjały te wynikają z tego, że rogówka jest dodatnio naładowana w stosunku do dna oka. Jeżeli więc zbliża się ona do jakiejś elektrody, to zwiększa potencjał na tej elektrodzie, a więc wywołuje dodatnie wychylenie zapisu, a jeżeli oddala się od elektrody, to wywołuje ujemne wychylenie zapisu. Ruchy pionowe oczu są najlepiej widoczne w odprowadzeniach Fp1 i Fp2. Spojrzenie w dół powoduje ujemne wychylenie zapisu, natomiast spojrzenie w górę - dodatnie. Jako że ruch obu oczu jest skojarzony, to odpowiednie wychylenie jest rejestrowane jednocześnie w obu płatach czołowych. Zamknięcie oczu wywołuje tzw. zjawisko Bella, tzn. ruch gałki ocznej w górę, czyli tak jak w przypadku spojrzenia w górę powoduje dodatnie wychylenie krzywej zapisu. Natomiast otwarcie oczu powoduje ujemne wychylenie zapisu z elektrod czołowych. Mruganie przejawia się w zapisie dokładnie tak samo jak zamknięcie, a następnie otwarcie oczu, czyli najpierw występuje wychylenie dodatnie, a od razu po nim wychylenie ujemne. Ruchy poziome oczu widać najlepiej w kanałach F7 i F8, przy czym w przeciwieństwie do ruchów pionowych, gdzie w obu kanałach przedczołowych następowała synchroniczna zmiana, tutaj zmiana jest przeciwna. I tak spojrzenie w lewą stronę, powoduje dodatnie wychylenie na elektrodzie F7 i ujemne na elektrodzie F8, natomiast spojrzenie w stronę prawą, dodatnie wychylenie na elektrodzie F8, a ujemne na elektrodzie F7. Artefakty oczne są artefaktami niskoczęstotliwościowymi, są widoczne w paśmie 0.1-10Hz. Jako że pasmo to pokrywa się z trzema pierwszymi pasmami sygnału EEG, więc odfiltrowanie tego rodzaju artefaktów filtrami częstotliwościowymi nie jest zbyt dobrym rozwiązaniem.

Ostatnią omawianą grupę artefaktów fizjologicznych stanowią artefakty spowodowane aktywnością serca, inaczej określane jako artefakty EKG ze względu na możliwość ich rejestracji

za pomocą elektrokardiografu. Artefakty EKG są uważane za najpowszechniejsze zakłócenia, które można znaleźć w sygnale EEG, szczególnie w przypadku pacjentów o szerokich i krótkich szyjach [125, 132, 138]. Wyróżnia się dwa typy artefaktów związanych z aktywnością serca: mechaniczne oraz elektryczne [47]. Mechaniczny artefakt EKG jest efektem pulsu krążeniowego i może być uznany za rodzaj artefaktu elektrodowego, który pojawia się, gdy elektroda spoczywa nad naczyniem krwionośnym w którym zauważalny jest puls. Artefakt ten objawia się jako okresowa wolna fala o regularnym odstępnie, trwająca około 200ms. Występuje on najczęściej w rejonie czołowym i skroniowym, a rzadziej w okolicy potylicznej, jednak może być obecny w dowolnym miejscu na głowie [47].

Elektryczne artefakty EKG są spowodowane elektryczną aktywnością serca. Ich amplituda jest zazwyczaj niska w porównaniu z amplitudą sygnału EEG (1–2 uV) [132], częstotliwość natomiast jest bliska 1 Hz [138]. Artefakt elektryczny EKG jest najczęściej obserwowany przy montażu monopolarnym z elektrodą referencyjną umieszczoną w okolicy jednego ucha (A1 lub A2). Ponadto, artefakt ten jest zauważalny w kanałach zlokalizowanych nad płacami skroniowymi (np. T3, T4, T5, T6). Rozpoznawalną cechą tego artefaktu jest synchronizacja z tzw. zespołem QRS, który jest fragmentem zapisu EKG składającym się z kilku charakterystycznych załameków oznaczonych jako Q, R i S o czasie trwania od 0.06 do 0.11 s. Ze względu na regularność (rytmiczność), synchronizację z zespołami QRS oraz koincydencję z sygnałem EEG, artefakt EKG można stosunkowo łatwo wykryć i rozpoznać [125]. Sytuacja może się skomplikować, jeżeli aktywność mózgowa synchronizuje się z artefaktem EKG, w takich przypadkach eliminacja artefaktu powoduje jednocześnie eliminację części użytecznego sygnału. Kolejnymi problemami utrudniającymi eliminację artefaktów EKG jest nieregularny rytm bicia serca lub zaburzona morfologia zespołu QRS. Czasami zespoły QRS o kształcie kolca mogą być mylone z aktywnością padaczkową [138]. Dodatkowo należy tu zaznaczyć, że oba artefakty EKG, mechaniczny i elektryczny, są nieznacznie opóźnione względem rzeczywistego sygnału EKG [47].

2.2 Metody detekcji i eliminacji artefaktów

W sygnale EEG, który ma mieć wartość diagnostyczną lub analityczną, komponenty odzwierciedlające aktywność monitorowanych źródeł neuronalnych powinny przeważać nad komponentami odzwierciedlającymi aktywność ośrodków pozamózgowych. Najlepiej byłoby,

gdyby składowe zakłócające sygnał w ogóle nie występowały w zapisie, ale tak postawiony postulat jest zbyt ostry i w praktyce niemożliwy do spełnienia, nawet w ściśle kontrolowanych warunkach laboratoryjnych. Stąd też artefakty są praktycznie zawsze obecne w sygnale rejestrowanym z powierzchni czaszki i przed rozpoczęciem analizy sygnału należy je usunąć. Podstawowym celem metod stosowanych do usuwania artefaktów z sygnału EEG jest detekcja i eliminacja niepożądanych składowych, przy jednoczesnym zachowaniu sygnału generowanego przez źródła mózgowie w stanie nienaruszonym [139].

Najbardziej podstawowym i jednocześnie najprostszym sposobem walki z artefaktami jest unikanie rejestracji artefaktów. Trudno jest nazwać ten sposób metodą, ponieważ nie odnosi się on do jednego konkretnego algorytmu postępowania, lecz jest raczej zbiorem ‘dobrych praktyk’, które mogą różnić się nieco, tak w różnych pracowniach, jak i w różnych zastosowaniach. Rejestracji artefaktów unika się m.in. poprzez odpowiednie instruowanie podmiotu odnośnie jego zachowania w trakcie badania. Jeżeli badanie i warunki na to pozwalają uczestnik badania powinien ograniczyć mruganie oraz ruchy ciała. Również poprawny montaż elektrod, w szczególności prawidłowe uziemienie, pozwalają na stabilniejszą akwizycję sygnału oraz zmniejszenie zakłóceń pochodzących z sieci zasilającej [129, 140]. Kolejnym elementem pozwalającym na zmniejszenie udziału artefaktów w sygnale jest odpowiedni dobór położenia elektrody/elektrod referencyjnych, np. zastosowanie tzw. referencji połączonych uszu minimalizuje udział w sygnale EEG artefaktu EKG.

Minimalizacja udziału artefaktów w sygnale EEG już na etapie jego rejestracji przynosi wymierne korzyści, ponieważ zmniejsza zarówno utratę danych spowodowaną np. odrzucaniem zniekształconych prób na etapie analizy sygnału, jak i złożoność obliczeniową algorytmów stosowanych do automatycznej eliminacji artefaktów. Niestety, czasami nie ma możliwości prowadzenia eksperymentów w ściśle kontrolowanych warunkach laboratoryjnych, a badany jest zarówno rozpraszany przez otoczenie, jak i nie jest w stanie powstrzymać wszystkich czynności fizjologicznych wywołujących zakłócenia zniekształcające sygnał. Poza tym, wielu spośród artefaktów fizjologicznych po prostu nie można uniknąć w trakcie długotrwałego badania. Na przykład artefakt wywołany pracą mięśni serca jest niezależny od woli badanego podmiotu. Pomimo, że wpływ tego artefaktu na sygnał można minimalizować poprzez odpowiedni dobór

referencji, to nie zawsze możliwa jest sama zmiana referencji. Ponadto, w przypadku, kiedy w badaniu uczestniczą dzieci, najczęściej, najlepszy nawet instruktaż nie przynosi żadnego efektu. Podsumowując, niemal zawsze sygnał EEG będzie zakłócony artefaktami, których wpływ na sygnał powinny być marginalizowany na etapie wstępnego przetwarzania sygnału [140].

Eliminacji/minimalizacji artefaktów można dokonywać zarówno w trakcie rejestracji sygnału EEG, jak i po zakończeniu badania. Algorytmy służące do tego celu można sklasyfikować w zależności od potrzeby interwencji człowieka jako:

- manualne – wymagające wizualnej kontroli rejestrowanego sygnału,
- automatyczne – eliminacja artefaktów odbywa się przy wykorzystaniu algorytmów komputerowych,
- półautomatyczne – wymagające wizualnej kontroli efektów uzyskanych za pomocą automatycznych metod usuwania artefaktów.

Metoda manualnego usuwania artefaktów jest uważana za najbardziej niezawodną. Usuwanie artefaktów zgodnie z tą metodą może odbywać się zarówno w trybie online, jak i w trybie offline. W pierwszym przypadku kontrola sygnału odbywa się w trybie ciągłym podczas procesu rejestracji. Kontroli dokonuje osoba prowadząca badanie, która znakuje niewłaściwe fragmenty sygnału za pomocą odpowiednich znaczników. Najczęściej technik EEG oznacza fragmenty sygnału nie na podstawie obserwacji samego zapisu, lecz na podstawie obserwacji badanego podmiotu, odnotowując momenty mrugania, zamknięcia oczu, wykonywania konkretnych ruchów itp. Kontrola w trybie offline jest przeprowadzana po zakończeniu rejestracji sygnału. Osoba prowadząca badanie przegląda cały zapis sygnału i oznacza miejsca, w których wystąpiły artefakty [132]. Oznaczone (w trybie online lub offline) fragmenty są albo całkowicie usuwane z zapisu albo pozostają w zapisie, ale nie są brane pod uwagę w trakcie analizy sygnału. Wadą tej metody jest subiektywny charakter metody, wynikający z udziału czynnika ludzkiego. Dodatkowo wraz z usuwaniem fragmentów sygnału tracone są informacje, które mogą być istotne w procesie analizy [129].

Zautomatyzowany proces usuwania artefaktów nie wymaga interwencji człowieka, co pozwala na wyeliminowanie elementu subiektywności. Ponadto, automatyczna detekcja artefaktów jest nieporównywalnie szybsza niż manualna, co jest szczególnie istotne w

medycznych systemach *time critical*, kiedy diagnoza stanu pacjenta musi być przeprowadzona w trybie natychmiastowym. Dodatkowo, przy długotrwałych zapisach, np. 24-godzinnej rejestracji sygnału lub w trakcie badań polisomnograficznych, automatyczna eliminacja artefaktów jest jedynym możliwym rozwiązaniem.

Dotychczas opracowano wiele procedur automatycznej identyfikacji i korekty artefaktów, jednak żadna z nich nie wyróżnia się na tle innych. Mnogość możliwych artefaktów oraz często ich niedeterministyczny charakter (wliczając w to ich sposób wkomponowania w sygnał EEG) powodują, że skuteczna automatyzacja istniejących algorytmów nie jest łatwa. Algorytmy automatycznej detekcji i eliminacji artefaktów korzystają głównie z trzech podejść:

- podejścia statystycznego,
- filtrowania częstotliwościowego,
- filtrowania przestrzennego.

Metody statystyczne są wykorzystywane głównie do detekcji artefaktów epizodycznych, czyli artefaktów, którym brakuje elementu rytmiczności (np. niektóre artefakty EOG). W podejściu statystycznym jako artefakty oznaczane są te fragmenty sygnału, które przekraczają in plus lub in minus zadaną miarę statystyczną. Najczęściej w procesie poszukiwania artefaktów wykorzystywane są odpowiednie percentyle amplitudy sygnału (np. percentyl 0.05 i 0.95). Przy takim podejściu sygnał o amplitudzie znajdującej się powyżej percentyla górnego (tu 0.95) lub poniżej percentyla dolnego (tu 0.05) uznaje się za nieprawidłowy. Inne metody/miary statystyczne stosowane do wyszukiwania artefaktów to np.: kurtoza, wspólny rozkład prawdopodobieństwa, wartości ekstremalne oraz analiza nieprawidłowości widma [141]. Zastosowanie podejścia statystycznego w procesie detekcji artefaktów wymaga zdefiniowania jak duży fragment sygnału otaczający zidentyfikowany artefakt powinien zostać usunięty z sygnału. Jeżeli sygnał jest podzielony na epoki (częsta sytuacja w badaniach psychologicznych), to z sygnału są usuwane całe epoki zanieczyszczone artefaktem. Natomiast w przypadku, kiedy sygnał jest rejestrowany w trybie ciągłym, przed rozpoczęciem procesu detekcji artefaktów jest on dzielony na okna (o wielkości ustalonej przez osobę nadzorującą proces), które następnie są w całości usuwane z sygnału w przypadku wykrycia w nich artefaktu.

Filtrowanie częstotliwościowe dolno- i górnoprzepustowe jest powszechnie stosowane do usuwania rytmicznych artefaktów o częstotliwościach nienakładających się z częstotliwościami generowanymi przez źródła mózgowe. Filtr górnoprzepustowy jest powszechnie używany do usuwania niektórych artefaktów ocznych ze względu na ich niską częstotliwość. Filtr dolnoprzepustowy pozwala na usunięcie części artefaktów mięśniowych o wysokiej częstotliwości [125]. Do zalet filtrów częstotliwościowych należy zaliczyć łatwość implementacji oraz aplikacji zarówno softwarowej jak i hardwarowej. Ponadto użycie filtra częstotliwościowego nie wymaga dokładnej wiedzy apriori o artefakcie. Do wad tej metody należy zaliczyć to, że filtr zmniejsza amplitudę wszystkich częstotliwości mieszczących się w podanym zakresie. Oznacza to, że w przypadku, kiedy częstotliwości pożądanego składowego sygnału EEG będą pokrywały się z filtrowanym zakresem, to one również zostaną utracone.

Filtry przestrzenne pozwalają na uwypuklenie pożądanego sygnału oraz zminimalizowanie cech niepożądanych, poprzez odpowiednie przeorganizowanie sygnałów zarejestrowanych z dwóch lub większej liczby sensorów [101]. Jak wspomniano w rozdziale pierwszym, sygnał EEG rejestrowany za pomocą pojedynczej elektrody jest sumą sygnałów generowanych przez wiele źródeł. Dokładniej mówiąc, podczas analizy sygnału EEG często zakłada się, że zapis ten rejestrowany z pojedynczego czujnika stanowi liniową kombinację sygnałów generowanych przez poszczególne źródła mózgowe oraz pozamózgowe. Użycie filtrów przestrzennych do separacji składowych generowanych przez źródła mózgowe oraz pozamózgowe jest więc zupełnie naturalne. Najpopularniejszymi filtrami przestrzennymi stosowanymi do reorganizacji grup sygnałów zarejestrowanych w kanałach EEG są: Common Spatial Patterns (CSP), filtry Laplace'a, Independent Component Analysis (ICA) [120, 142], Principal Component Analysis (PCA), Canonical Correlation Analysis (CCA) [143], Maximum Noise Fraction (MNF) [144] Singular Spectrum Analysis (SSA) [145], Morphological Component Analysis (MCA) [146] Common Average Reference (CAR) [147, 148, 149, 150, 151]. Filtry przestrzenne dają bardzo dobre wyniki, jeżeli chodzi o detekcję artefaktów, jednakże pod warunkiem, że sygnał jest rejestrowany z dużej liczby sensorów. Zmniejszanie liczby sensorów z reguły pogarsza wyniki separacji poszczególnych źródeł sygnału.

2.3 Algorytmy automatycznej detekcji i eliminacji artefaktów

Wymienione powyżej podejścia (statystyczne, filtrowanie częstotliwościowe oraz filtrowanie przestrzenne) są stosowane łącznie lub rozłącznie w algorytmach automatycznej detekcji i eliminacji artefaktów. W chwili obecnej wśród najczęściej stosowanych algorytmów znajdują się:

- S.A.R.A <https://qeeepro.eegprofessionals.nl>, dostęp: 29.11.2019
- FORCE [152], <http://www.iandaly.org/force>, dostęp: 29.11.2019
- LAMIC [153]
- FASTER [154] <https://sourceforge.net/projects/faster/>, dostęp: 29.11.2019
- ADJUST [155] http://www.unicog.org/site_2016/, dostęp: 29.11.2019
- AUTOREJECT [156] <https://github.com/autoreject/autoreject>, dostęp: 29.11.2019

Algorytm S.A.R.A (Znormalizowany Algorytm Odrzucania Artefaktów, ang. *Standardized Artifact Rejection Algorithm*) został opracowany w roku 2014 przez Andre Keizer [157]. Algorytm ten dokonuje detekcji czterech kategorii artefaktów EEG:

- mruganie,
- poziome ruchy gałek ocznych,
- artefakty niskiej częstotliwości (np. ruchy głowy),
- artefakty wysokiej częstotliwości (np. napięcie mięśni).

Z algorytmu można skorzystać poprzez serwis internetowy: <https://qeeepro.eegprofessionals.nl/>. Procedura polega na przesłaniu do serwisu nagranych sygnałów EEG, gdzie jest on przetwarzany w celu detekcji oraz usunięcia artefaktów. Po zakończeniu procedury dostarczany jest raport PDF, który przedstawia surowy sygnał EEG wraz z oznaczonymi artefaktami. Ponadto, dostarczany jest również oczyszczony sygnał EEG w standardowym formacie .edf. Minusem tego rozwiązania jest niemożliwość wykorzystania algorytmu do detekcji artefaktów w trybie online oraz zależność od zewnętrznego dostawcy oprogramowania.

Kolejnym z wymienionych algorytmów do automatycznej detekcji i usuwania artefaktów jest algorytm FORCE (ang. *Fully Online and Automated Artifact Removal for brain-Computer*

interfacing, w tłumaczeniu: algorytm do automatycznego usuwania artefaktów w trybie online w interfejsie mózg-komputer). Autorami algorytmu są: Daly, Scherer, Billinger oraz Muller-Putz, którzy zaprezentowali swoje rozwiązanie w 2014 roku [152]. Według autorów FORCE jest w stanie usunąć z sygnału EEG artefakty: mrugania, EKG, ruchowe oraz mięśniowe. Algorytm wykonuje rozkład falkowy na jednosekundowych oknach sygnału EEG. Następnie na uzyskanych współczynnikach detali stosowane są różne kombinacje progów statystycznych celem podjęcia decyzji o ich pochodzeniu. Współczynniki aproksymacji są dalej przetwarzane za pomocą analizy składowych niezależnych, a następnie na uzyskanych składowych wynikowych, podobnie jak na współczynnikach detali, stosowane są różnego rodzaju progi celem identyfikacji składowych stanowiących artefakty. Składowe takie są następnie w całości usuwane [152]. Kod źródłowy algorytmu dostępny jest pod adresem: <http://www.iandaly.org/force/> [dostęp 23.04.2019].


Trzecim z prezentowanych algorytmów jest LAMIC. Nazwa to akronim od angielskiego: *Lagged Auto-Mutual Information Clustering*, co może zostać przetłumaczone jako automatyczne grupowanie informacji wzajemnej z opóźnieniem. Metoda została zaprezentowana w 2007 roku przez Nicolaou, Nicoletta oraz Nasuto [153, 158]. LAMIC to nowatorski algorytm grupowania opracowany z myślą o automatycznym usuwaniu artefaktów z sygnału EEG. Zarejestrowane sygnały są najpierw dekomponowane na składowe za pomocą rozszerzonego algorytmu analizy składowych niezależnych o nazwie: TDSEP (ang.: *Temporal Decorrelation Source SEparation*). Klasyczny algorytm analizy składowych niezależnych, bazuje na maksymalizacji niegaussowości sygnałów. Rozszerzenie algorytmu TDSEP polega na separacji składowych w oparciu o przesunięcie sygnałów w czasie. Uzyskane składowe są następnie grupowane. Miara wykorzystywana w procesie grupowania jest oparta na informacji wzajemnej opóźnionych sygnałów. Informacja wzajemna mierzy ilość informacji jaką zmienna losowa zawiera o innych zmiennych losowych z tego samego zbioru [158]. Stosowanie opóźnień, motywowane jest tym, że sygnały EEG i artefakty posiadają inną dynamikę czasową. Etap budowy klastrów polega na łączeniu w jednym klastrze par sygnałów (a potem par klastrów) za pomocą macierzy sąsiedztwa (bliskości). Łączenie takie jest powtarzane, dopóki wszystkie sygnały nie zostaną zawarte w tym samym klastrze. W ten sposób zostaje utworzone drzewo, które jest dzielone na klastry zawierające artefakty oraz ich nie zawierające. W procesie tym wykorzystuje się metodę wyboru liczby skupień właściwą dla metod hierarchicznych [159]. Klastry zawierające artefakty są


następnie usuwane. W kolejnym kroku, na sygnałach z pozostałych klastrów przeprowadzana jest odwrócona operacja analizy składowych niezależnych.

Algorytm FASTER (ang. *Fully Automated Statistical Thresholding for EEG artifact Rejection*, co można przetłumaczyć jako w pełni zautomatyzowane progowanie statystyczne w celu eliminacji artefaktów EEG) jest kolejnym algorytmem pozwalającym na automatyczne, czyli nienadzorowane usunięcie artefaktów EEG. Został on przedstawiony przez zespół w składzie: Nolan, Whelan oraz Reilly w roku 2010 [154]. Algorytm pozwala na poprawę sygnału EEG w pięciu obszarach: kanały, epoki, składowe niezależne, epoki pojedynczego kanału oraz dane zagregowane (np. dotyczące poszczególnych podmiotów). Algorytm pracuje z osobna na każdym z wymienionych obszarów, dla każdego z nich obliczając zestaw parametrów statystycznych, przedstawionych na Rysunku 2.3.1. Rozróżnienie prawidłowych i zanieczyszczonych danych jest realizowane za pomocą miary Z-score – za wartości odstające od normy uznawane są wartości przekraczające Z-score o ± 3 . W zależności od analizowanego obszaru, przekroczenie zdefiniowanej powyżej normy oznacza: usunięcie (np. epoki), odjęcie (składowej) lub interpolację (np. kanału). Schemat blokowy opisujący kolejne kroki metody FASTER, przedstawiony jest na Rysunku 2.3.1 [154].

Kolejnym algorytmem jest algorytm ADJUST (ang. *An automatic EEG artifact detector based on the joint use of spatial and temporal features*, w tłumaczeniu: automatyczny detektor artefaktów EEG oparty na wspólnym wykorzystaniu cech przestrzennych i czasowych). Autorami algorytmu są Moghona, Jovicich, Bruzzone oraz Buiatti [155]. Algorytm został stworzony w 2010 roku i bazuje na analizie składowych niezależnych. Identyfikuje on składowe artefaktowe poprzez połączenie cech przestrzennych i czasowych specyficznych dla danego artefaktu. Metoda została zoptymalizowana w celu eliminacji mrugnięć, ruchów oczu i ogólnych niespójności w zbiorze danych. Algorytm bazuje na dwóch założeniach: (1) w przypadku dużej liczby artefaktów zawartych w składowych niezależnych, składowe te charakteryzują się rozpoznawalnymi cechami zarówno w czasie, jak i w rozkładzie przestrzennym; oraz (2) podczas gdy pojedyncze cechy mogą nie być wystarczająco dokładne, aby wyodrębnić artefakt, kombinacja wielu cech może skutecznie poprawić dokładność rozpoznawania zanieczyszczeń.

Przetwarzanie wstępne nisko-kanalowych sygnałów EEG





Rysunek 2.3.1 Schemat blokowy opisujący kolejne etapy metody FASTER

Źródło: <http://www.tara.tcd.ie/handle/2262/41103>

W pierwszym kroku algorytm ADJUST rozkłada sygnał na składowe niezależne. Następnie rozważane są cztery klasy artefaktów: trzy klasy są związane z artefaktami EOG (mrugnięcia, pionowe i poziome ruchy oczu), a czwarta klasa artefaktów (zwana niespójnością) przeznaczona jest do wychwytywania anomalnej aktywności zarejestrowanej na pojedynczych elektrodach z powodu złych warunków np. wysokiej impedancji lub niestabilności elektrycznej w urządzeniu rejestrującym. Dla każdej z czterech klas artefaktów implementowany jest odrębny detektor. Jest to realizowane poprzez obliczenie specyficznego dla klasy zestawu funkcji przestrzennych i czasowych na wszystkich składowych. Dla każdej funkcji próg dzielący artefakty

od nie-artefaktów jest szacowany na całym zestawie składowych niezależnych w całkowicie automatyczny sposób za pomocą metody automatycznego progowania z użyciem estymatora największej wiarygodności EM (ang. Expectation-Maximization). Składowa niezależna uznawana jest za zanieczyszczoną, jeżeli wszystkie cechy przestrzenne i czasowe analizowane w danym detektorze przekroczą odpowiednią wartość progową. Funkcje przestrzenne i czasowe stosowane w algorytmie ADJUST są zoptymalizowane przy pomocy rzeczywistego zbioru danych EEG [155].

Ostatnim z przytoczonych wcześniej algorytmów jest Autoreject: Automated artifact rejection for MEG and EEG data. Algorytm został zaprezentowany w 2017 roku przez zespół składający się z: Jas, Engemann, Bekhti, Raimondo oraz Gramfort [156]. Autoreject jest zautomatyzowanym algorytmem odrzucania i naprawy nieprawidłowych kanałów w poszczególnych epokach zarejestrowanych w trakcie badań magnetoencefalograficznych (MEG) oraz elektroencefalograficznych. Algorytm korzysta z walidacji krzyżowej do oszacowania progów wartości międzyszczytowych sygnału. Progi te są następnie wykorzystywane do selekcji zanieczyszczonych kanałów, przy czym selekcja następuje z osobna dla każdej epoki. Algorytm posiada dwa warianty, globalny oraz lokalny. W wersji pierwszej, globalnej, ustalany jest jeden wspólny próg odrzucenia dla wszystkich możliwych kanałów. Podejście to jest jednak wrażliwe na anomalie występujące w pojedynczym kanale (np. zbyt wysokie amplitudy sygnału wynikające z nieprawidłowego montażu elektrody). Wystąpienie takich anomalii powoduje błędne ustawienie progu odrzucenia dla pozostałych kanałów, w związku z czym działanie algorytmu jest niezgodnie z założeniem. Z pomocą przychodzi druga wersja algorytmu, tj. Autoreject w wersji lokalnej, w którym próg jest szacowany oddzielnie dla każdego kanału w każdej epoce [156].

2.4 Filtry przestrzenne

Filtr przestrzenny można zdefiniować jako:

$$\tilde{x} = \sum_i w_i x_i = wX \quad (2.4.1)$$

gdzie $\tilde{x}$ to przefiltrowany przestrzennie sygnał, x_i to sygnał EEG z kanału i , w_i to waga danego kanału w filtrze przestrzennym. X jest to oryginalna macierz sygnałów rejestrowanych ze wszystkich kanałów a w to macierz miksująca te sygnały [125]. Istnieją różne sposoby

definiowania filtrów przestrzennych, różniących się zarówno sposobem doboru wag poszczególnych składowych, jak i warunkami sterującymi procesem konstruowania samych składowych. Wagi mogą być wyznaczone manualnie, zgodnie z ogólną wiedzą neurofizjologiczną lub mogą być wyliczone z danych dostępnych podczas procesu uczenia modelu danego filtru przestrzennego [160]. Natomiast warunki wykorzystywane w procesie doboru składowych są inne dla każdego filtru (np. warunek niezależności składowych w metodzie ICA, czy maksymalizacji wariancji składowych w metodzie PCA). W niniejszym podrozdziale opisano sposób działania ośmiu różnych filtrów przestrzennych, z pominięciem analizy składowych niezależnych (ICA), której został poświęcony cały trzeci rozdział niniejszej pracy.

2.4.1 Wspólne wzorce przestrzenne

Jednym z filtrów przestrzennych często wykorzystywanych podczas analizy sygnału EEG (a zwłaszcza w odniesieniu do interfejsów mózg-komputer) jest algorytm wspólnych wzorców przestrzennych (ang. *Common Spatial Patterns*, CSP). Algorytm ten został zaproponowany przez Ramosera w 2000 roku [161]. Algorytm CSP w swojej podstawowej postaci jest przeznaczony do separacji sygnałów w sytuacji klasyfikacji binarnej. Zakładając, że analizowane są dane reprezentujące dwie klasy aktywności mózgowej, algorytm CSP wyznacza filtr przestrzenny, który maksymalizuje stosunek wariancji danych pochodzących z tych dwóch klas [162]. W sposób bardziej dokładny działanie algorytmu CSP można opisać następująco. Niech X oznacza macierz reprezentującą sygnały EEG pochodzące z pojedynczego badania (epoki) o wymiarach $N \times T$, gdzie N i T oznaczają odpowiednio liczbę kanałów i liczbę próbek pomiarowych w kanale. Dodatkowo, niech macierze X_L oraz X_P reprezentują dane pochodzące z dwóch klas, np. pobrane, kiedy uczestnik badania wykonywał ruch lewą oraz prawą ręką. Wówczas dwie macierze kowariancji, dla dwóch różnych klas, mogą być przedstawione jako:

$$R_L = \frac{X_L X_L^T}{\text{trace}(X_L X_L^T)}, \quad R_P = \frac{X_P X_P^T}{\text{trace}(X_P X_P^T)} \quad (2.4.1.1)$$

gdzie: X^T jest transpozycją X , a $\text{trace}()$ jest funkcją obliczającą sumę elementów macierzy znajdujących się na głównej przekątnej. Średnie macierze kowariancji $\overline{R}_L$ oraz $\overline{R}_P$ są obliczane poprzez uśrednienie macierzy kowariancji wyznaczonych dla wszystkich epok danej klasy.

Następnie, łączna kowariancja obu klas jest rozkładana na czynniki za pomocą wektorów i wartości własnych w następujący sposób:

$$R = \overline{R_L} + \overline{R_P} = QDQ^T, \quad (2.4.1.2)$$

gdzie: Q jest macierzą wektorów własnych a D jest diagonalną macierzą wartości własnych. Następnie definiowana jest macierz wybielająca (normalizująca wariancję) o postaci:

$$P = \sqrt{D^{-1}}Q^T \quad (2.4.1.3)$$

Macierz ta jest wykorzystywana do wybielenia średniej macierzy wariancji każdej z klas:

$$S_L = P\overline{R_L}P^T \quad S_P = P\overline{R_P}P^T \quad (2.4.1.4)$$

W następnym etapie macierze S_L i S_P są rozkładane na wartości i wektory własne. Dzięki wcześniejszemu wybieleniu obu macierzy, macierze te dzielą wspólne wektory własne, co oznacza, że suma odpowiednich wartości własnych obu macierzy jest równa 1:

$$S_L = QD_LQ^T \quad S_P = QD_PQ^T \quad D_L + D_P = I \quad (2.4.1.5)$$

gdzie I jest macierzą jednostkową. Wektory własne z największymi wartościami własnymi dla S_L posiadają więc najmniejsze wartości własne dla S_P i vice versa. Macierz transformacji W , będąca macierzą współczynników filtra przestrzennego, może zostać zapisana jako:

$$W = Q^T P \quad (2.4.1.6)$$

Kolumny W^{-1} są wspólnymi wzorcami przestrzennymi i mogą być postrzegane jako niezmiennie w czasie wektory rozkładu EEG [163, 164].

Algorytm CSP tworzy wspólne wzorce przestrzenne poprzez jednoczesną diagonalizację dwóch macierzy kowariancji [165]. Różni się on więc od większości metod filtrowania przestrzennego, które wymagają jedynie próbek reprezentujących sygnał EEG, bez informacji o etykietach klas przypisanych do poszczególnych fragmentów sygnału. Jak wykazano w wielu artykułach, w przypadku rejestracji sygnału z wielu kanałów, zastosowanie filtra CSP wyraźnie zwiększa dokładność klasyfikacji w interfejsach mózg-komputer (np. 55 kanałów [166], 56 [161,

167], 118 [168, 169], 127 [170]). Jednocześnie w wielu artykułach podkreśla się, że algorytm CSP nie nadaje się do bezpośredniego wykorzystania w interfejsach nisko-kanałowych [171].

2.4.2 Filtr Laplace’a

Filtr Laplace’a jest kolejnym filtrem przestrzennym wykorzystywanym podczas analizy sygnałów EEG. Zaproponowany został przez francuskiego matematyka Pierre Simona de Laplace’a w roku 1785 [172]. Należy on do rodziny filtrów krawędziowych. W zastosowaniach graficznych filtr ten służy do uwypuklenia krawędzi obrazu i przez to lokalnego zmniejszenia efektu rozmazania i części szumu tła. Przybliżeniem filtru, w przypadku dyskretnego sygnału, jest suma różnic wartości poszczególnych punktów i punktu centralnego, którą można zapisać jako:

$$x_i^{Laplasjan} = x_i - \sum_{j \in N(i)} \left(\frac{x_j}{d_{ij} \times \sum_{k \in N(i)} \left(\frac{1}{d_{ik}} \right)} \right) \quad (2.4.2.1)$$

gdzie $N(i)$ jest zbiorem elektrod w sąsiedztwie elektrody i , a d_{ij} reprezentuje odległość między elektrodami i oraz k . Dla równych odległości i przy założeniu, że N oznacza liczbę elektrod w sąsiedztwie elektrody i , powyższą formułę można zredukować do:

$$\hat{x}_i = x_i - \frac{1}{N} \sum_{j \in N(i)} x_j \quad (2.4.2.2)$$

Dla sygnałów EEG Laplasjan jest często definiowany jest jako 4-krotność wartości kanału centralnego minus wartości 4 kanałów otaczających kanał centralny. Na przykład, filtr Laplace’a dla kanału C3 może być zdefiniowany jako [160]:

$$C3_{Laplacian} = 4C3 - FC3 - C5 - C1 - CP3 \quad (2.4.2.3)$$

Odpowiednie zastosowanie filtrów tego typu znacznie zwiększa dokładność klasyfikacji oraz może przyczynić się do zmniejszenia szumu tła i odrzucenia nieistotnych informacji pochodzących z niechcianych źródeł [160].

2.4.3 Średnia wartość referencyjna

Metoda średniej wartości referencyjnej ze wszystkich kanałów, tzw. Common Average Reference (CAR) jest kolejnym filtrem przestrzennym z powodzeniem stosowanym podczas

wstępnego przetwarzania sygnałów EEG [147, 148, 149, 150, 151]. Autorem metody jest Offener (1950) [173]. Metoda CAR polega na uśrednieniu próbek ze wszystkich kanałów i wykorzystaniu wyniku tej operacji jako globalnej referencji dla każdego kanału. Model matematyczny metody CAR, dla K -kanałowej macierzy x , oraz i -tego sygnału, może zostać zapisany jako [174]:

$$\hat{x}_i = x_i - \hat{n} \quad (2.4.3.1)$$

Gdzie:

$$\hat{n} = \frac{1}{K} \sum_{k=1}^K x_k \quad (2.4.3.2)$$

Na przykład, dla 34 kanałowego systemu oraz elektrody Cz, zastosowanie filtru CAR wygląda następująco [149]:

$$\widehat{Cz} = Cz - \frac{Fp1+AF3+F7 \dots +Fz}{34} \quad (2.4.3.3)$$

gdzie: Fp1, AF3, F7, ... Fz – nazwy wykorzystanych kanałów.

Metoda CAR wykazuje skuteczność w odpowiednich warunkach, ale posiada pewne wady wynikające z tego, że przyjmuje się w niej, że szumy są identyczne lub co najmniej bardzo podobne dla wszystkich kanałów. Tymczasem, w rzeczywistych pomiarach okazuje się, że odmienne charakterystyki poszczególnych kanałów mogą powodować nieprzewidywalne amplitudy szumu. Ponadto, dla niektórych kanałów amplituda sygnału właściwego jest tak duża, że dominuje w średniej, powodując wygenerowanie niedokładnego odniesienia.

2.4.4 Analiza składowych głównych

Za najstarszy filtr przestrzenny uważa się filtr PCA (ang. Principal Component Analysis, analiza składowych głównych). Został on opracowany niezależnie przez Pearsona w 1901 oraz Hotellinga w 1933 [175]. Jego główną ideą jest zmniejszenie wymiarowości zbioru danych składającego się z dużej liczby powiązanych zmiennych, przy zachowaniu jak największego zróżnicowania badanego zbioru. PCA jest metodą statystyczną, można ją zdefiniować jako projekcję liniową przekształcającą oryginalny zestaw wielowymiarowych zmiennych w nowy zestaw składowych niezależnych liniowo. Kolejne składowe wyznaczane są w taki sposób, aby

były ortogonalne względem istniejących składowych i posiadały malejącą wariancję. Przyjmując za X , zbiór wejściowy, gdzie n to liczba kanałów, a t to liczba próbek w kanale, algorytm PCA wylicza wektory i wartości własne z macierzy kowariancji: $C_x = XX^T$. Z uwagi na to, że macierz kowariancji jest macierzą kwadratową o wymiarze $n \times n$, posiada ona n wektorów własnych. Wektory własne są sortowane według odpowiadających im wartości własnych, w kolejności od największej do najmniejszej wartości własnej. Ostatecznie dane z kanałów pierwotnych są rzutowane na przestrzeń rozpiętą na m -pierwszych wektorów własnych.

2.4.5 Filtr minimalnego szumu

Autorem kolejnego filtru przestrzennego, filtru minimalnego szumu (ang. Minimum Noise Fraction MNF) [176, 177] jest Green, który przedstawił go w 1988 [178]. Początkowo algorytm wykorzystywany był do przetwarzania danych satelitarnych. Dopiero po pewnym czasie zaczął być wykorzystywany również do oczyszczania szeregów czasowych. Podstawą algorytmu MNF jest skonstruowanie takiego zbioru wektorów bazowych, który pozwoli na maksymalizację stosunku sygnału do szumu w transformowanym zbiorze danych. Charakterystyczną cechą algorytmu (wynikającą z zastosowanego kryterium optymalizacyjnego) jest to, że wektory bazowe mają naturalny porządek oparty na stosunku sygnału do szumu [176]. Załóżmy, że sygnał X składa się z surowego sygnału S oraz szumu N połączonych w następujący sposób:

$$X = S + N \quad (2.4.5.1)$$

Wówczas algorytm maksymalizuje stosunek sygnału do szumu, poprzez znalezienie wektora bazowego α :

$$SNR = \max_{\alpha \neq 0} \frac{\|S\alpha\|}{\|N\alpha\|} = \max_{\alpha \neq 0} \frac{\|X\alpha\|}{\|N\alpha\|} \quad (2.4.5.2)$$

Powyższy wzór jest prawdziwy, jeżeli S i N są ortogonalne. Jeżeli szum N charakteryzuje się wysokimi częstotliwościami, wówczas $N^T N$ jest kowariancją sygnału a sam sygnał jest przesunięty o 1 [179].

W wyniku działania algorytmu otrzymuje się więc składowe uszeregowane zgodnie z ilością zawartego w nich szumu, co pozwala na łatwą klasyfikację sygnałów ze względu na ich

przydatność w dalszym przetwarzaniu. Składowe o wysokim stosunku sygnału do szumu zostają usunięte jako zbędne, natomiast składowe o niskim stosunku sygnału do szumu zostają przyjęte do dalszego przetwarzania. Dzięki temu nie tylko polepsza się jakość sygnału, ale dodatkowo dane wejściowe ulegają kompresji [179].

ROZDZIAŁ 3

ANALIZA SKŁADOWYCH NIEZALEŻNYCH

Elektroda pomiarowa umieszczona na powierzchni czaszki rejestruje sygnał będący wypadkową sygnałów źródłowych generowanych jednocześnie przez wiele różnych źródeł korowych. Dostęp do informacji źródłowej wymaga więc dekompozycji sygnału zarejestrowanego przez elektrodę pomiarową. Dekompozycja ta nie jest jednak trywialna, ponieważ wymaga znalezienia nie tylko sygnałów źródłowych, ale również macierzy współczynników określających wielkość udziału poszczególnych źródeł w sygnale zarejestrowanym z powierzchni czaszki. Dostęp do informacji źródłowej wymaga więc rozwiązania tak zwanego problemu ślepej separacji sygnału (ang. Blind Source Separation, BSS). W niniejszym rozdziale zostanie opisana metoda obecnie najczęściej stosowana do rozwiązania tego problemu, nazywana analizą składowych niezależnych (ang. Independent Component Analysis, ICA).


3.1 Model i założenia wstępne analizy składowych niezależnych

Do obrazowego przedstawienia zagadnienia rozkładu sygnałów obserwowanych na sygnały źródłowe często wykorzystywany jest przykład pokoju, w którym znajduje się dwoje ludzi mówiących równocześnie (Rysunek 3.1.1). W dwóch różnych miejscach pokoju ustawione są dwa mikrofony, które rejestrują przebieg rozmowy. Kiedy proces rejestracji kończy się, dostępne są dwa sygnały, po jednym z każdego mikrofonu. Każdy z zarejestrowanych sygnałów stanowi liniową kombinację dwóch głosów, a więc zawiera w sobie słowa wypowiedziane przez obu rozmówców. Stąd, bez odpowiedniego przetworzenia sygnałów z mikrofonów nie jest możliwe odczytanie informacji zawartych w sygnałach źródłowych. Opisany problem, polegający na wydzieleniu słów każdego z rozmówców jako osobnego sygnału przy wykorzystaniu jedynie sygnałów zarejestrowanych przez mikrofony, znany jest w literaturze pod nazwą „problemu przyjęcia cocktailowego” (ang. cocktail party problem) [180].

Problem cocktail party jest typowym problemem rozwiązywanym przy wykorzystaniu metod służących do tzw. ślepej separacji sygnałów (ang. Blind Source Separation, BSS). Zadaniem metod BSS jest znalezienie liniowej transformacji, która pozwoli na odzyskanie

sygnałów źródłowych z sygnałów obserwowanych [181, 182]. Termin ‘ślepa’, oznacza, że nieznana jest zarówno macierz mieszająca, jak i sygnały źródłowe [181]. Do najpopularniejszych metod BBS należą analiza składowych niezależnych (ang. Independent Component Analysis, ICA) [7, 183, 184, 185], nieujemna faktoryzacja macierzy (ang. Non-negative Matrix Factorization, NMF), równoległa analiza wieloczynnikowa (ang. Parallel Factor Analysis - PARAFAC), analiza składowych głównych (ang. Principal Component Analysis, PCA) [175], analizator składowych czasowo-częstotliwościowych (ang. time-frequency component analyzer), ślepa dekonwolucja wielokanałowa (ang. Multichannel Blind Deconvolution, MBD) [186], metoda minimalnego szumu (ang. Minimum Noise Fraction, MNF) [176, 177] oraz morfologiczna analiza składowych (ang. Morphological Component Analysis, MCA)[187, 188, 189].

Spośród wszystkich tych metod, obecnie najczęściej wykorzystywana jest analiza składowych niezależnych, która dostępna jest w bardzo wielu odmianach i konfiguracjach [190].



Rysunek 3.1.1 Przykład problemu przyjęcia cocktailowego,
Źródło: <https://www.statsoft.pl/textbook/graphics/Speakers.gif>

Podstawy algorytmu analizy składowych niezależnych zostały po raz pierwszy przedstawione we wczesnych latach 80, przez Juttena oraz Ansa [191]. Metoda nie wyszła jednak poza francuskie środowisko naukowe. Powodem tego było początkowe niekompletne jej opisanie oraz dynamiczny rozwój algorytmu propagacji wstecznej, sieci Hopfielda oraz samoorganizującej się mapy Kohonena (SOM), które były wówczas tematami dominującymi w środowisku

naukowym zajmującym się przetwarzaniem sygnałów [192, 193]. Algorytm pozostawał nieznany do 1994 r., kiedy to Perrie Common wprowadził nazwę analiza składowych niezależnych i przedstawił ją jako koncepcję nowej metody [192, 194]. Algorytm ICA często postrzegany jest jako rozszerzona wersja, omówionego w rozdziale drugim, algorytmu PCA. Podstawową różnicą pomiędzy algorytmami jest to, że PCA znajduje nieskorelowane składowe sygnału, natomiast ICA znajduje składowe, które nie tylko są nieskorelowane, ale dodatkowo niezależne [192].

Model matematyczny ICA można przedstawić następująco. Załóżmy, że obserwowanych jest n sygnałów $x_1, \dots, x_n$ składających się z n niezależnych składowych. Wektor x można wówczas zapisać w postaci:

$$x = As, \quad (3.1.1)$$

gdzie: A - reprezentuje macierz mieszającą o wymiarach $n \times n$ a s - wektor sygnałów źródłowych. Model ICA jest przykładem klasycznego modelu liniowego, który zakłada, że sygnały obserwowane (x) są liniową kombinacją sygnałów źródłowych (s).

Celem algorytmu ICA jest znalezienie takiej macierzy W (tj. odwrotności macierzy A), która pozwoli na uzyskanie wektora y możliwie najbardziej zbliżonego do wektora s [7, 190]:

$$y = Wx \cong s, \quad (3.1.2)$$

Składowe niezależne (wektor y) są zmiennymi utajnionymi, co oznacza, że nie jest możliwa ich bezpośrednia obserwacja. Zakłada się również, że macierz mieszająca A nie jest znana. Jedyną znaną macierzą jest więc macierz x . Zadaniem stawianym przed algorytmem jest jednoczesne obliczenie macierzy A i wektora y , przy wykorzystaniu wektora x [7, 195].

Aby separacja sygnałów za pomocą algorytmu ICA była możliwa muszą być spełnione trzy warunki:

- sygnały źródłowe s muszą być statystycznie niezależne,
- maksymalnie jeden sygnał źródłowy może mieć rozkład zbliżony do rozkładu Gaussa,
- liczba sygnałów obserwowanych musi być równa lub większa od liczby sygnałów źródłowych.

Spółród trzech powyższych warunków najważniejszy jest warunek pierwszy mówiący o statystycznej niezależności sygnałów źródłowych. Warunek ten jest istotny z tego powodu, że algorytmy ICA dokonując rozkładu sygnałów obserwowanych na potencjalne sygnały źródłowe bezpośrednio wykorzystują założenie o statystycznej niezależności składowych, orientując proces poszukiwania na szukanie takich składowych, które maksymalizują statystyczną niezależność wynikowego zbioru składowych.

Zgodnie z definicją, jeżeli dwie zmienne a oraz b są statystycznie niezależne to wartość zmiennej a nie dostarcza żadnych informacji o wartości zmiennej b i vice versa [7, 182]. Technicznie niezależność może być określona przez funkcję gęstości prawdopodobieństwa dla zmiennej losowej. Całka z tej funkcji, obliczona w odpowiednich granicach, jest równa prawdopodobieństwu wystąpienia danego zdarzenia losowego. Niech $p(x_1, x_2)$ oznacza łączny rozkład prawdopodobieństwa (ang. probability density function, pdf) losowych zmiennych x_1 oraz x_2 , a $p_1(x_1)$ oraz $p_2(x_2)$ ich rozkłady brzegowe, które dla zmiennych dyskretnych można zapisać jako:

$$p_1(x_1) = \sum_{y_2} p(x_1, x_2), \quad p_2(x_2) = \sum_{y_1} p(x_1, x_2) \quad (3.1.3)$$

natomiast dla zmiennych ciągłych jako:

$$p_1(x_1) = \int p(x_1, x_2) dx_2, \quad p_2(x_2) = \int p(x_1, x_2) dx_1 \quad (3.1.4)$$

Zmienne x_1 oraz x_2 są niezależne, jeżeli ich wspólny rozkład prawdopodobieństwa jest równy iloczynowi rozkładów brzegowych:


$$p(x_1, x_2) = p_1(x_1)p_2(x_2) \quad (3.1.5)$$

Z powyższej definicji wywodzi się bardzo ważna właściwość niezależnych zmiennych losowych. Mianowicie, dla dowolnych dwóch funkcji h_1 oraz h_2 , których argumentami są zmienne losowe, spodziewana wartość iloczynu tych funkcji jest równa iloczynowi ich spodziewanych wartości [7]:

$$E\{h_1(x_1)h_2(x_2)\} = E\{h_1(x_1)\}E\{h_2(x_2)\} \quad (3.1.6)$$

Większość obecnie stosowanych algorytmów ICA dokonuje rozkładu obserwowanych zmiennych losowych na statystycznie niezależne zmienne losowe korzystając z jednego z trzech

podstawowych podejść (Rysunek 3.1.2): maksymalizacji niegaussowości, minimalizacji informacji wzajemnej oraz metody największej wiarygodności (ang. Maximum Likelihood - ML) [192].



Rysunek 3.1.2 Najczęściej stosowane podejścia do rozkładu obserwowanych zmiennych losowych na statystycznie niezależne zmienne losowe. Źródło: opracowanie własne

Maksymalizacja niegaussowości polega na takiej modyfikacji zbioru sygnałów obserwowanych, aby ich rozkłady były możliwie jak najbardziej różne od rozkładów normalnych [190]. Stopień normalności rozkładu może być mierzony za pomocą różnych miar, przy czym najczęściej wykorzystuje się w tym celu kurtozę bądź negentropię [7].

Termin „kurtoza” został po raz pierwszy zastosowany przez Pearsona w 1905 roku [196]. Kurtozę, uznawaną za klasyczną miarę niegaussowości, formalnie można zdefiniować jako znormalizowany czwarty moment centralny:

$$\beta_2 = \frac{E(X-\mu)^4}{(E(X-\mu)^2)^2}, \quad (3.1.7)$$

gdzie X – to n -elementowa zmienna losowa, E jest wartością oczekiwaną, μ średnia arytmetyczna, μ_4 jest natomiast momentem centralnym czwartego rzędu [197]. Wartością oczekiwaną jest spodziewany wynik doświadczenia losowego, wyliczany wg wzoru:

$$E(X) = \sum_{i=1}^n x_i * P(X = x_i) = \sum_{i=1}^n x_i * p_i \quad (3.1.8)$$

gdzie: x_i to wartość i -tej obserwacji a $p_i = P(X = x_i)$ to prawdopodobieństwo wystąpienia tej obserwacji (często zapisywany również jako $p(x_i)$). Moment centralny czwartego rzędu jest to miara koncentracji obserwacji, określana jako:

$$\mu_4 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4 \quad (3.1.9)$$

gdzie: $\bar{x}$ to średnia arytmetyczna. Odchylenie standardowe, czyli pierwiastek kwadratowy z wariancji, dla zmiennej losowej przedstawiane jest jako:

$$\sigma = \sqrt{\frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}} \quad (3.1.10)$$

Po uwzględnieniu wzorów 3.1.7-3.1.9 wzór na kurtozę przyjmuje postać:

$$\beta_2 = \frac{\mu_4}{\sigma^4} \quad (3.1.11)$$


gdzie σ to odchylenie standardowe. Jako że wyznaczona z wzoru 3.1.7 dla rozkładu normalnego kurtოza równa jest 3 ($\beta_2 = 3$), często koryguje się wzór 3.1.11 odejmując z jego prawej strony liczbę 3 i uzyskując tym samym zerową wartość miary koncentracji dla rozkładu normalnego:

$$Ex = \frac{\mu_4}{\sigma^4} - 3, \quad (3.1.12)$$

Miara taka, dla odróżnienia od ścisłej definicji kurtοzy, określana jest jako eksces [196].

Wartość kurtοzy wyznaczona dla danego rozkładu zmiennej losowej informuje o kształcie tego rozkładu. Rysunki 3.1.3 a) oraz b) ilustrują rozkłady z kurtοzą dodatnią (leptokurtyczne), taką, że $\beta_2 - 3 > 0$ oraz kurtοzą ujemną (platokurtyczne) dla której $\beta_2 - 3 < 0$. Rozkład normalny przedstawiony jest linią przerywaną. Rozkład leptokurtyczny posiada wyższy pik oraz mniejszą koncentrację wokół średniej niż w rozkładzie normalnym. Rozkład platokurtyczny charakteryzuje się niższym pikiem oraz większą koncentracją wokół średniej niż rozkład normalny [197].

Kolejną miarą stosowaną do oszacowania stopnia normalności rozkładu zmiennej losowej jest negentropia. Po raz pierwszy terminu ujemnej entropii (czyli negentropii) użył Schrödinger w 1943 roku [198]. Dziesięć lat później, w 1953 roku, Brillouin sformułował pojęcie negentropii oraz połączył je z teorią informacji [199, 200]. W teorii informacji entropia jest definiowana jako średnia ważona ilość informacji niesiona przez pojedynczą wiadomość.



Rysunek 3.1.3 Ilustracja kurtozy. Linie przerywane pokazują rozkłady normalne, natomiast linie ciągłe przedstawiają rozkłady z kurtozą dodatnią - leptokurtyczną (a) i kurtozą ujemną - platokurtyczną (b).

Źródło: <http://www.columbia.edu/~ld208/psymeth97.pdf>

Negentropię zmiennej losowej można wyznaczyć obliczając różnicę pomiędzy maksymalną wartością entropii tej zmiennej, a jej wartością aktualną. Zgodnie z teorią informacji, największą entropię wśród zmiennych losowych o równej wariancji posiada zmienna o rozkładzie normalnym (wynosi ona $\log(\sqrt{2\pi e})$ [7, 201]), wartość ta stanowi więc punkt odniesienia. Negentropia może być zdefiniowana jako:

$$J(X) = H(X_{gauss}) - H(X), \quad (3.1.13)$$

gdzie X_{gauss} to zmienna losowa o rozkładzie normalnym i wariancji takiej jak wariancja wektora X , $H(X)$ to wartość entropii. Wartość entropii n elementowej zmiennej losowej X można wyznaczyć z następującego wzoru:

$$H(X) = -\sum_{i=1}^n p(x_i) \log_r p(x_i) \quad (3.1.14)$$

gdzie x_i to wartość i -tej obserwacji a $p(x_i)$ to prawdopodobieństwo zajścia zdarzenia x_i . W teorii informacji najczęściej stosuje się logarytm o podstawie 2 ($r=2$). W takim przypadku jednostką entropii jest *bit*. Negentropia charakteryzuje się tym, że jest zawsze nieujemna oraz niezmienna względem dowolnego liniowego przekształcenia współrzędnych. Posiada wartość równą zero tylko wówczas, gdy zmienna ma rozkład normalny.

Kolejne z, wskazanych na Rysunku 3.1.2, podejść do rozkładu obserwowanych zmiennych losowych na statystycznie niezależne zmienne losowe opiera się na minimalizacji informacji wzajemnej występującej między parami zmiennych [7]. Informacja wzajemna jest miarą zależności między dwiema zmiennymi losowymi. Wyraża ilość informacji o zmiennej X , która jest dostępna z obserwacji zmiennej Y . W domenie dyskretnej informacja wzajemna o dwóch zmiennych losowych X i Y jest zdefiniowana jako [202]:

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (3.1.15)$$

gdzie $p(x, y)$ to wspólny rozkład prawdopodobieństwa X i Y , natomiast $p(x)$ oraz $p(y)$ oznaczają prawdopodobieństwa w rozkładach zmiennych X i Y . Informację wzajemną można również przedstawić z wykorzystaniem entropii w następujący sposób [190, 202, 203]:

$$I(X; Y) = H(X) - H(X|Y), \quad (3.1.16)$$

gdzie: $H(X|Y)$ - jest warunkową entropią zmiennej X przy znanej zmiennej Y , a $H(X)$ - jest entropią zmiennej X . Definicja warunkowej entropii wygląda następująco [203]:

$$H(X|Y) = H(X, Y) - H(Y), \quad (3.1.17)$$

gdzie: $H(X, Y)$ jest wspólną entropią zmiennych X i Y a $H(Y)$ jest entropią zmiennej Y . Im mniejsza wartość informacji wzajemnej, tym więcej informacji dostępne jest na temat danego systemu [190]. Konstrukcja algorytmu ICA szukającego składowych w jak największym stopniu niezależnych polega więc na znalezieniu takiego przekształcenia macierzy W która minimalizuje informację wzajemną dla poszczególnych sygnałów obserwowanych [7]. Minimalizacja informacji wzajemnej jest związana z metodą największej wiarygodności. Różnią się one jedynie znakiem oraz określoną stałą, co zostanie pokazane poniżej [7, 192].

Ostatnią z metod powszechnie stosowanych w algorytmach ICA do przekształcenia zbioru obserwowanych sygnałów w zbiór składowych statystycznie niezależnych jest metoda największej wiarygodności (ang. Maximum Likelihood, ML). Za jej autora uważa się Fishera, który zaproponował oraz przedstawił metodę największej wiarygodności w serii prac publikowanych w latach 1912 do 1932 [204]. Metoda największej wiarygodności jest stosowana między innymi w algorytmie Infomax, który zostanie przedstawiony w dalszej części rozdziału.

Gęstość prawdopodobieństwa p_x , dla macierzy x oraz składowych niezależnych s może zostać przedstawiona następująco:

$$p_x(x) = |detW|p_s(s) = |detW| \prod_i p_i(s_i) \quad (3.1.18)$$

gdzie $W = A^{-1}$, p_i oznacza gęstość prawdopodobieństwa i -tej składowej niezależnej a $|detW|$ to wyznacznik macierzy W . Wzór ten może być wyrażony jako funkcja od $W = (w_1, \dots, w_n)^T$ (gdzie n to liczba składowych niezależnych) oraz x , jako:

$$p_x(x) = |detW| \prod_i p_i(w_i^T x) \quad (3.1.19)$$

zakładając N obserwacji $x: x(1), x(2), \dots, x(N)$. Metoda największej wiarygodności polega na wyznaczeniu estymatorów p_s takich, aby funkcja gęstości $p_x(x)$ przyjęła jak największą wartość. Dla dyskretnej przestrzeni statystycznej (np. macierzy sygnałów EEG), po uwzględnieniu wzorów 3.1.18 oraz 3.1.19 funkcję wiarygodności, standardowo oznaczaną jako L , oblicza się poprzez iloczyn macierzy $W = (w_1, \dots, w_n)^T$ oraz wektora x w punktach n oraz wyraża się wzorem [7]:

$$L = \sum_{t=1}^T \sum_{i=1}^n \log p_i(w_i^T x(n)) + N \log |det W| \quad (3.1.20)$$

gdzie N to długość wektora x .

Drugim, po statystycznej niezależności sygnałów źródłowych, warunkiem działania algorytmu ICA jest to, że maksymalnie jeden sygnał źródłowy ma rozkład zbliżony do rozkładu Gaussa. Poniżej przedstawiono, dlaczego warunek ten jest warunkiem koniecznym do realizacji algorytmu.

Niech x_1 oraz x_2 będą nieskorelowanymi sygnałami obserwowanymi o wspólnym rozkładzie gaussowskim. Oznacza to, że ich wspólny rozkład prawdopodobieństwa może zostać zapisany jako [7]:

$$p(x_1, x_2) = \frac{1}{2\pi} \exp\left(\frac{-x_1^2 + x_2^2}{2}\right) \quad (3.1.21)$$

Niech macierz mieszająca A będzie ortogonalna. Zgodnie z formułą transformacji funkcji gęstości prawdopodobieństwa dla zmiennej losowej oraz zgodnie z warunkiem $A^{-1} = A^T$ który zachodzi

dla macierzy ortogonalnych, prawdopodobieństwo warunkowe dla x_1 oraz x_2 może zostać zapisane jako:


$$p(x_1, x_2) = \frac{1}{2\pi} \exp\left(-\frac{\|A^T x\|^2}{2}\right) |\det A^T| \quad (3.1.22)$$

Z powodu ortogonalności macierzy A zachodzi $\|A^T x\|^2 = \|x\|^2$ oraz $|\det A| = 1$. Jeżeli A jest ortogonalne, A^T również. Wzór 3.1.21 można wówczas przekształcić do postaci:

$$p(x_1, x_2) = \frac{1}{2\pi} \exp\left(-\frac{\|x\|^2}{2}\right) \quad (3.1.23)$$

Ortogonalna macierz mieszająca nie zmienia postaci funkcji gęstości prawdopodobieństwa. Rozkłady składowych niezależnych oraz zmiennych obserwowanych są identyczne, a suma dwóch lub więcej zmiennych losowych o rozkładzie Gaussa jest sama w sobie zmienną gaussowską. Oznacza to, że suma źródeł o rozkładzie Gaussa jest nie do odróżnienia od pojedynczego źródła o takim rozkładzie [185]. Macierz mieszająca nie może więc zostać określona [7, 193] i tym samym niemożliwe jest oddzielenie źródeł o rozkładzie Gaussa za pomocą modelu ICA. Zjawisko to można zaprezentować graficznie poprzez wykreślenie ortogonalnych sygnałów. Rysunek 3.1.4 pokazuje, że rozkład gęstości prawdopodobieństwa dla dwóch zmiennych gaussowskich jest w pełni (obrotowo) symetryczny. Nie zawiera żadnych informacji o kierunkach kolumn macierzy mieszającej A w związku z czym nie można jej oszacować.

Trzecim założeniem algorytmu analizy składowych niezależnych jest to, że liczba sygnałów obserwowanych musi być równa lub większa od liczby sygnałów źródłowych. Wynika to z założenia, że nieznana macierz mieszająca A jest kwadratowa. Z warunku tego wynika jedno z bardzo poważnych ograniczeń klasycznego algorytmu ICA, a mianowicie to, że odzyskanie dużej liczby źródeł jest możliwe tylko w sytuacji, kiedy sygnały obserwowane są rejestrowane z wykorzystaniem dużej liczby sensorów. Zagadnienie to zostanie dokładniej omówione w sekcji poświęconej ograniczeniom algorytmów ICA.



Rysunek 3.1.4 Wielowymiarowy rozkład dwóch sygnałów o rozkładzie Gaussa.

Źródło: <https://www.semanticscholar.org/paper/Independent-component-analysis%3A-algorithms-and-Hyv%C3%A4rinen-Oja/577d19a115f9ef6f002483fcf88adbb3b5479556/figure/6>

3.2 Podstawowe algorytmy analizy składowych niezależnych

Algorytm analizy składowych niezależnych wymaga wykonania pewnych kroków na etapie przetwarzania wstępnego, czyli na etapie poprzedzającym działanie właściwego algorytmu. Są to centrowanie oraz wybielanie sygnału [185, 192, 193]. Proces centrowania polega na odjęciu od kolejnych próbek danego sygnału jego wartości średniej. Biorąc pod uwagę n sygnałów o średniej μ , zapisanych w postaci macierzy X , krok centrowania, dla i -tego sygnału x_i może zostać przedstawiony następująco:

$$x_{iC} = x_i - \mu_i \quad (3.2.1)$$

gdzie, μ_i to średnia i -tego sygnału, a x_{iC} to i -ty wycentrowany sygnał [192].

Przeprowadzenie procesu centrowania nie jest niezbędne dla prawidłowego działania algorytmu ICA, ale jest ono najczęściej wykonywane, ponieważ pozwala znacznie uprościć dalsze kroki algorytmu [185, 193]. Wycentrowanie danych wejściowych nie wpływa w żaden sposób na wyliczenia macierzy mieszającej [193]. Ponadto, aby powrócić do pierwotnej przestrzeni sygnałów wektor średnich może zostać z powrotem dodany do komponentów otrzymanych po zastosowaniu algorytmu ICA.

Drugim krokiem stosowanym podczas przetwarzania wstępnego sygnału w algorytmach ICA jest wybielanie sygnału (ang. whitening). Ma ono na celu uzyskanie zmiennych nieskorelowanych o jednostkowej wariancji [7, 192]. Proces wybielania wymaga więc dekokorelacji macierzy sygnałów oraz ustandaryzowania ich wariancji.

Dwie zmienne s_1 oraz s_2 uznaje się za nieskorelowane, jeżeli ich kowariancja $cov(s_1, s_2)$ jest równa zero:

$$\begin{aligned} cov(s_1, s_2) &= E\{(s_1 - m_{s1}) - (s_2 - m_{s2})\} \\ &= E\{s_1 s_2 - s_1 m_{s1} + m_{s1} m_{s2}\} \\ &= E\{s_1 s_2\} - E\{s_1\}E\{s_2\} \\ &= 0 \end{aligned} \tag{3.2.2}$$


gdzie: m_{s1} oraz m_{s2} to odpowiednio średnie sygnałów s_1 oraz s_2 [185].

Brak korelacji uważany jest za słabszą formę niezależności. Oznacza to, że dwie zmienne niezależne są zawsze nieskorelowane, ale dwie zmienne nieskorelowane nie muszą być niezależne [193]. Pierwsza część powyższego zdania wynika z faktu, że jeżeli do wzoru o statystycznej niezależności zmiennych (3.1.6), podstawimy za $h_1(y_1)$ zmienną s_1 a za $h_2(y_2)$ zmienną s_2 , to równania 3.1.6 oraz 3.2.2 będą równoważne. Z drugiej strony twierdzenie, że brak korelacji nie oznacza niezależności można wyjaśnić następująco. Dla przykładu, niech y_1 oraz y_2 będą zmiennymi dyskretnymi. Niech posiadają taki rozkład, że para (y_1, y_2) może przyjąć jedną z wartości: $(0,1), (0,-1), (1,0), (-1,0)$ z prawdopodobieństwem równym $\frac{1}{4}$. Z układu par widać, że zmienne y_1 oraz y_2 nie są ze sobą skorelowane. Z drugiej strony zachodzi:

$$E\{y_1^2 y_2^2\} = 0 \neq \frac{1}{4} = E\{y_1^2\}E\{y_2^2\}, \tag{3.2.3}$$

co oznacza, że równanie 3.1.6 nie jest spełnione, a więc zmienne nie mogą być niezależne [7]. Pokazując tę sytuację bardziej obrazowo, korelacja może być dziełem przypadku. Niech za wzór posłuży wykres przedstawiony na Rysunku 3.2.1 pokazujący dwie skorelowane funkcje: liczby

japońskich samochodów osobowych sprzedawanych w USA oraz liczby samobójstw w wyniku zderzenia pojazdu silnikowego. Jak widać obie funkcje są ze sobą silnie skorelowane pomimo całkowitej niezależności.



Rysunek 3.2.1 Korelacja liczby japońskich samochodów osobowych sprzedawanych w USA oraz liczby samobójstw w wyniku zderzenia pojazdu silnikowego. Korelacja: 93.57%

Źródło: <http://www.tylervigen.com/spurious-correlations>

Uzyskanie braku korelacji jest pierwszym krokiem wybielania danych. Kolejne przekształcenie polega na uzyskaniu jednostkowej wariancji. Jeżeli przez $\tilde{x}$ oznaczony zostanie wybielony wektor, macierz kowariancji dla $\tilde{x}$ będzie równa macierzy jednostkowej:

$$E\{\tilde{x}\tilde{x}^T\} = I \quad (3.2.3)$$

Popularną metodą wybielania, pozwalającą na jednoczesne przeprowadzenie dekorrelacji macierzy sygnałów oraz standaryzacji wariancji jest rozkład macierzy kowariancji na wartości i wektory własne:

$$E\{xx^T\} = QDQ^T \quad (3.2.4)$$

gdzie Q jest macierzą ortogonalną wektorów własnych $E\{xx^T\}$, a D jest macierzą diagonalną wartości własnych $D = \text{diag}(d_1, \dots, d_n)$. Operację wybielania można wówczas zdefiniować w następujący sposób:

$$\tilde{x} = QD^{-1/2}Q^T x \quad (3.2.5)$$

gdzie $D^{-1/2}$ jest obliczana jako:

$$D^{-1/2} = \text{diag}(d_1^{-1/2}, \dots, d_n^{-1/2}) \quad (3.2.6)$$

gdzie n to liczba składowych. Wybielanie przekształca macierz mieszającą A w nową macierz $\tilde{A}$. Z podstawowego wzoru na model ICA (3.1.1) oraz wzoru (3.2.3) wynika, że:

$$\tilde{x} = QD^{-1/2}Q^TAs = \tilde{A}s \quad (3.2.7)$$

Użyteczność tego procesu polega na tym, że nowa macierz mieszająca $\tilde{A}$ na pewno jest ortogonalna:

$$E\{\tilde{x}\tilde{x}^T\} = \tilde{A}E\{ss^T\}\tilde{A}^T = \tilde{A}\tilde{A}^T = I \quad (3.2.8)$$

Wybielanie zmniejsza złożoność obliczeniową algorytmu. Zamiast estymować n^2 elementów oryginalnej macierzy A , wystarczy estymować jedynie wartości nowej ortogonalnej macierzy mieszającej $\tilde{A}$. Macierz ta posiada $n(n-1)/2$ stopni swobody. Można powiedzieć, że wybielanie rozwiązuje w połowie problem ICA. Jest to bardzo przydatny krok, ponieważ wybielanie jest prostym i wydajnym procesem, który znacznie zmniejsza złożoność obliczeniową właściwego algorytmu analizy składowych niezależnych.

3.2.1 FastICA – podejście deflacyjne

FastICA jest algorytmem iteracyjnym, zaproponowanym przez Hyvärinen oraz Oja w 1999 roku [7, 190, 205]. Jest to jeden z najbardziej popularnych algorytmów z rodziny ICA. Posiada dwie odmiany: podejście deflacyjne i podejście symetryczne. W podejściu deflacyjnym, składowe niezależne estymowane są kolejno, jedna po drugiej. Zadaniem algorytmu jest taki dobór wektora wag w , informującego o udziale kolejnych sygnałów wejściowych w aktualnie estymowanej składowej, aby projekcja w^Tx maksymalizowała niegaussowość [7, 205]. Jako miara niegaussowości wykorzystywana jest aproksymacja negentropii zaproponowana przez twórców algorytmu [7, 190]:

$$J(X) \propto [E\{G(X)\} - E\{G(V)\}]^2, \quad (3.2.1.1)$$

gdzie: X to zmienna losowa o niegaussowskim rozkładzie, zerowej średniej i jednostkowej wariancji, V to zmienna losowa o rozkładzie gaussowskim, $G(\cdot)$ jest dowolną, ale nie kwadratową

funkcją a E jest wartością oczekiwaną. Powyższa aproksymacja daje dobry kompromis pomiędzy kurtozą a negentropią. Jest szybka obliczeniowo, a jednocześnie prosta do zaimplementowania [7]. Proces estymacji pojedynczej składowej algorytmu deflacyjnego FastICA można zapisać w sposób następujący [7, 206]:

1. Wybierz n elementowy wektor inicjujący wektor wag w , gdzie n jest liczbą sygnałów wejściowych.
2. Oblicz nowe wartości współczynników wagowych:

$$w^+ = E\{Xg(w^T X)\} - E\{g'(w^T X)\}w$$

3. Znormalizuj wektor wag: $w^+ = \frac{w^+}{\|w^+\|}$
4. Wykonuj kroki 3-5, dopóki $\|w^+\| - \|w\| < \varepsilon$, gdzie: ε – to odpowiednio mała stała wartość.
5. W przypadku, gdy wyznaczana jest składowa o numerze większym niż 1, dokonaj ortonormalizacji Grama-Schmidta (korzystając z wektorów wag wyznaczonych dla wszystkich wyznaczonych wcześniej składowych) aby zapobiec zbieżności różnych wektorów wag do tego samego maksimum [7]. Ortonormalizacja Grama-Schmidta bazuje na fakcie, że gdy iloczyn skalarny dwóch kolejno wyliczonych wektorów wagowych jest możliwie bliski lub równy 1, to oznacza to, że wskazują one ten sam kierunek [192].

Kolejność w jakiej algorytm FastICA w wersji deflacyjnej odnajduje kolejne sygnały źródłowe jest ściśle powiązana z wartościami początkowymi wektora w . W podejściu deflacyjnym, niektóre składowe są więc „uprzywilejowane” i obliczane jako pierwsze.

3.2.2 FastICA – podejście symetryczne

Algorytm ten realizuje ten sam cel co algorytm deflacyjny. Różnią się one sposobem obliczania wektora wag. W podejściu symetrycznym wszystkie wektory estymowane są równolegle [7, 207]. Ortonormalizacja jest w tym przypadku osiągana za pomocą następującego wzoru:

$$W = (WW)^{-1/2}W, \quad (3.2.2.1)$$

gdzie: W to macierz wektorów wag $(w_1, \dots, w_n)^T$ dla n składowych niezależnych. Pierwiastek kwadratowy $(WW^T)^{-1/2}$ jest obliczany poprzez dekompozycję macierzy WW^T na wartości i wektory własne $WW^T = QDQ^T$:

$$(WW^T)^{-1/2} = QD^{-1/2} Q^T \quad (3.2.2.2)$$

gdzie Q jest macierzą wektorów własnych, a D jest diagonalną macierzą wartości własnych [7, 195]. W symetrycznym algorytmie FastICA najczęściej spotykanym warunkiem stopu jest warunek podany we wzorze (3.2.2.3):

$$1 - \min \left(\text{abs}(\text{diag}(W^T W_{old})) \right) < \varepsilon, \quad (3.2.2.3)$$

gdzie: ε – to odpowiednio mała stała wartość, W_{old} – to wartość macierzy zawierającej wektory wag z poprzedniej iteracji.

3.2.3 Infomax

Algorytm Infomax bazuje na ogólnej zasadzie optymalizacji sieci neuronowych oraz innych systemów przetwarzania sygnałów opisanych przez Linsker'a w 1987 [208]. Fundamentem algorytmu jest minimalizacja informacji wzajemnej. Pierwszy algorytm ICA, realizujący optymalizację opisaną przez Linsker'a został zaproponowany w 1995 przez Bell'a i Sejnowskiego [209] a następnie, w 1997 został zoptymalizowany przez Amari'ego [7, 210].

Algorytm Infomax bazuje na maksymalizacji entropii wyjściowej z sieci neuronowej o nieliniowych wyjściach [7]. Kluczową rolę przy estymacji ma wskaźnik uczenia, który nie musi być stały w czasie. Powinien być on dobierany w taki sposób, aby zachowany był kompromis pomiędzy szybkością działania algorytmu a jakością estymacji [7, 211]. Reguła aktualizacji wag w algorytmie Infomax wygląda następująco [210, 212]:

$$w_{k+1} = w_k + \mu_k [I - 2g(y_k)y_k^T]w_k, \quad (3.2.3.1)$$

gdzie: y – macierz sygnałów źródłowych ($y=Wx$), k – numer iteracji, I – macierz jednostkowa, μ_k – wskaźnik uczenia, który może być zależny od k , $g(\cdot)$ – funkcja nieliniowa. Jako nieliniowa funkcja g w klasycznym algorytmie najczęściej wykorzystywana jest funkcja [212]:

$$g(y) = \frac{1}{1+e^{-y}}, \quad (3.2.3.2)$$

lub w wersji rozszerzonej:

$$g(y) = y \pm \tanh(y), \quad (3.2.3.3)$$

Podsumowując algorytm Infomax, optymalizujący wektor wag w może zostać zapisany w następującej postaci [213]:

1. $y_k = w_k * \text{perm}(X)$
2. $g = \frac{1}{1+e^{-y_k}}$
3. $g' = g \times y_k^T$
4. $g' = I - 2 \times g'$
5. $w_{k+1} = w_k + \mu_k \times g' \times w_k$,

gdzie perm oznacza losową permutację, a μ_k to szybkość uczenia się dla k -tej iteracji metody, zwykle niższa niż $1e^{-2}$. Zbyt wysokie wartości μ_k mogą prowadzić do szybszego obliczania wektora w , ale jednocześnie mogą spowodować, że wektory wyliczone pomiędzy poszczególnymi iteracjami algorytmu mogą być zbyt odległe od siebie. Może to oznaczać pominięcie warunku stopu oraz w konsekwencji brak zbieżności algorytmu [211].

3.3 Ograniczenia klasycznego algorytmu analizy składowych niezależnych

Analiza składowych niezależnych pozwala na rozkład sygnałów obserwowanych na niezależne składowe, ale prawidłowa interpretacja tych składowych jest utrudniona z tego powodu, że ICA w swojej klasycznej postaci nie pozwala na:

- określenie wariancji składowych niezależnych,
- określenie kolejności składowych niezależnych,
- uzyskanie innej liczby składowych niezależnych niż liczba sygnałów obserwowanych.

Pierwsze z ograniczeń, czyli niemożliwość określenia wariancji składowych niezależnych, spowodowane jest tym, że zarówno składowe niezależne, jak i macierz mieszająca nie są znane. W celu zobrazowania tego ograniczenia, pomocne jest przekształcenie równania 3.1.1 do postaci sumy:

$$x = As = \sum_{j=1}^N a_j s_j \quad (3.3.1)$$

gdzie a_j to j -ty wiersz macierzy mieszającej A , a s_j to j -ta składowa niezależna. Ze względu na to, że oba te współczynniki nie są znane, równanie 3.3.1 można zapisać jako:

$$x = \sum_{j=1}^N \left(\frac{1}{\alpha_j} a_j\right) (\alpha_j s_j) \quad (3.3.2)$$

gdzie α_j to dowolny skalar. Jak widać mnożnik skalarny składowej niezależnej s_j może zostać anulowany przez podzielenie j -tej kolumny a_j przez ten sam współczynnik. W konsekwencji niemożliwe jest określenie wariancji dla składowych niezależnych. Ze względu na to, że są to zmienne losowe, przyjmuje się założenie, że każda składowa posiada jednostkową wariancję $E\{s_i^2\} = 1$. Macierz A jest adaptowana w algorytmie ICA w taki sposób, aby uwzględnić to ograniczenie. Należy zauważyć, że ograniczenie to zawiera również niemożliwość ustalenia znaku danej składowej niezależnej. Jest to spowodowane tym, że dowolną składową niezależną można pomnożyć przez -1 bez wpływu na model [7, 185, 193].


Drugie ograniczenie polega na niemożliwości ustalenia kolejności składowych niezależnych. Ponownie powodem jest to, że zarówno składowe niezależne s jak i macierz mieszająca A nie są znane. Celem algorytmu ICA, jest znalezienie macierzy W , która będzie odwrotnością macierzy A . Wartości w macierzy W inicjowane są losowo. Następnie, każdy z wierszy jest obracany w celu znalezienia komponentu niezależnego. Podczas obrotu, wartości w każdym wierszu aktualizowane są iteracyjnie, tak długo aż uda się odzyskać składowe niezależne. Niestety kolejność odzyskiwania składowych jest losowa [192]. Problem ten można w prosty sposób zademonstrować ponownie wykorzystując zmodyfikowany model ICA z równania 3.1.1:

$$x = AP^{-1}Ps \quad (3.3.3)$$


gdzie P – to macierz permutacji. Elementy Ps są oryginalnym składowymi niezależnymi s , lecz ustawionymi w innej w kolejności. Zadaniem algorytmu ICA jest znalezienie nieznanej macierzy mieszającej AP^{-1} [7, 185, 193]. W wielu przypadkach ograniczenie to nie jest istotne. Jeżeli np. przetwarzane są sygnały dźwiękowe, odzyskane składowe mogą być rozpoznane i uporządkowane przez specjalistę. W niektórych sytuacjach jednak, np. w sygnałach pochodzenia mózgowego brak uporządkowania składowych niezależnych jest kłopotliwy. Problem uwidacznia się jeszcze

bardziej, jeżeli sygnał przetwarzany jest fragmentami np. epoka po epoce. Nie można wówczas w sposób bezpośredni powiązać składowych niezależnych pomiędzy poszczególnymi epokami. Tym samym nie jest możliwe np. przeprowadzenie optymalizacji modeli klasyfikacyjnych wykorzystujących dane z wielu epok.

Ostatnim ograniczeniem algorytmów z rodziny ICA jest to, że w swojej klasycznej postaci, nie pozwala on na uzyskanie liczby składowych wynikowych różnej od liczby obserwowanych sygnałów. Rozpatrując to ograniczenie należy wspomnieć o dwóch wariantach. Wariant pierwszy pojawia się w sytuacji, gdy liczba dostępnych sensorów (rejestrujących sygnały z otoczenia) jest większa niż liczba faktycznych źródeł (Rysunek 3.3.1). Wariant ten jest określany w literaturze jako nadkompletny model ICA (ang. overcomplete ICA). Wariant drugi związany jest z sytuacją odwrotną, czyli z sytuacją, w której liczba sygnałów źródłowych jest większa niż liczba sygnałów obserwowanych (Rysunek 3.3.2) i jest on określany jako niekompletny model ICA (ang. undercomplete ICA).



Rysunek 3.3.1 Ilustracja przedstawiająca przykład niekompletnego modelu ICA, w której liczba źródeł jest większa od liczby obserwacji. Źródło: https://pdfs.semanticscholar.org/4b0b/39fcd83492a192a2f3385151575837f7047.pdf?_ga=2.151192383.722134934.1560240146-2058687032.1552914876



Rysunek 3.3.2 Ilustracja przedstawiająca przykład nadkompletnego modelu ICA, w której liczba źródeł jest mniejsza od liczby obserwacji. Źródło: https://pdfs.semanticscholar.org/4b0b/39fcda83492a192a2f3385151575837f7047.pdf?_ga=2.151192383.722134934.1560240146-2058687032.1552914876

Wariant pierwszy ($m > n$, gdzie m - liczba sygnałów obserwowanych, n - liczba źródeł) formalnie może zostać zapisany w następujący sposób:

$$\begin{aligned} x_1(t) &= a_{11}s_1(t) + a_{12}s_2(t) \\ x_2(t) &= a_{21}s_1(t) + a_{22}s_2(t) \\ x_3(t) &= a_{31}s_1(t) + a_{32}s_2(t) \end{aligned} \quad (3.3.4)$$

a_{ij} są stałymi współczynnikami. To samo równanie zapisane w postaci macierzowej wygląda następująco:

$$\begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ a_{31} & a_{32} \end{pmatrix} \begin{pmatrix} s_1 \\ s_2 \end{pmatrix}$$

Proces odzyskiwania składowych niezależnych wymaga, aby macierz separująca była kwadratowa. W tym celu (jeżeli znana jest liczba sygnałów źródłowych) należy dokonać redukcji rozmiaru do postaci:

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} s_1 \\ s_2 \end{pmatrix}$$

oraz zrealizować algorytm ICA w postaci:

$$\begin{pmatrix} s \\ s_2 \end{pmatrix} = \begin{pmatrix} w_{11} & w \\ w_{21} & w_{22} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

Sytuacja ta pozornie może wydawać się korzystna, ponieważ dostępnych jest więcej informacji niż jest to wymagane. Jednak, jak zostało pokazane powyżej, poprzez redukcję obserwacji x_3 , utracono część informacji. Teoretycznie zamiast redukować obserwację x_3 można również wykonać algorytm ICA na pełnej macierzy obserwacji uzyskując w wyniku większą liczbę składowych wyjściowych niż liczba faktycznych źródeł. Wykonanie algorytmu na większej niż potrzebna liczbie sygnałów skutkuje jednak gorszą separacją źródeł niż w sytuacji, kiedy liczba zarejestrowanych sygnałów jest dokładnie równa liczbie składowych wynikowych [185].

Wariant drugi, obejmujący sytuacje, w których liczba czujników jest mniejsza od liczby składowych niezależnych ($m < n$), można przedstawić następująco. Niech $x_1(t)$ oraz $x_2(t)$ oznaczają sygnały pochodzące z dwóch czujników, które zarejestrowały dane z trzech źródeł: $s_1(t)$, $s_2(t)$ oraz $s_3(t)$. $x_i(t)$ są wówczas ważonymi sumami sygnałów $s_i(t)$, gdzie współczynniki wagowe zależą np. od odległości pomiędzy czujnikami rejestrującymi.

$$x_1(t) = a_{11}s_1(t) + a_{12}s_2(t) + a_{13}s_3(t) \quad (3.3.5)$$

$$x_2(t) = a_{21}s_1(t) + a_{22}s_2(t) + a_{23}s_3(t)$$

Ponownie a_{ij} są stałymi współczynnikami oznaczającymi wagi mieszające. To samo równanie zapisane w postaci macierzowej wygląda następująco:

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \end{pmatrix} \begin{pmatrix} s_1 \\ s_2 \\ s_3 \end{pmatrix}$$

Proces separujący wraz z macierzą wag wyglądałby natomiast następująco:

$$\begin{pmatrix} s_1 \\ s_2 \\ s_3 \end{pmatrix} = \begin{pmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \\ w_{31} & w_{32} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

Jak można zauważyć macierz mieszająca A ma rozmiar 2×3 w związku z czym macierz separująca W musi mieć rozmiar 3×2 , nie jest więc kwadratowa. Tym samym nie jest spełniony jeden z warunków algorytmu ICA. O ile w przypadku nadkompletnej wersji modelu ICA warunek

ten nie jest bardzo restrykcyjny, ponieważ jego niespełnienie będzie skutkowało jedynie gorszą separacją składowych (a samą redukcję wymiarów można przeprowadzić, np. stosując algorytm PCA), o tyle w przypadku wersji niekompletnej brakujących danych nie ma czym uzupełnić.

Rozwiązanie wskazanego tu problemu jest szczególnie istotne w zastosowaniach, w których liczba sensorów jest ograniczona, a liczba sygnałów źródłowych duża, lecz nieznaną. Jednym z zastosowań, których szczególnie dotyczy wskazane powyżej ograniczenie algorytmów ICA jest analiza sygnałów pochodzenia mózgowego, zwłaszcza sygnałów rejestrowanych w warunkach poza laboratoryjnych, gdzie niezbędne jest stosowanie nisko-kanalowych macierzy elektrod.

3.4 Algorytmy ICA dla systemów nisko-kanalowych

Jak wynika z poprzedniego podrozdziału odzyskanie liczby sygnałów źródłowych większej aniżeli liczba sygnałów obserwowanych jest niemożliwe przy zastosowaniu klasycznych algorytmów ICA. Stąd, jeżeli celem jest odzyskanie większej liczby źródeł niż liczba sygnałów obserwowanych, konieczne jest rozszerzenie macierzy sygnałów obserwowanych poprzez wygenerowanie dodatkowych, sztucznych sygnałów. Jak dotąd zaproponowano w tej dziedzinie jedynie kilka rozwiązań [13, 145, 179, 214, 215, 216, 217, 218, 219, 220].

Jednym z pierwszych jest metoda o nazwie SCICA (ang. Single Channel ICA). Autorami metody są Davies i James [217]. Zaproponowali oni rozwiązanie jednokanałowego modelu ICA poprzez podzielenie sygnału zarejestrowanego z pojedynczego czujnika na sekwencję ciągłych bloków, a następnie wykonanie algorytmu ICA na macierzy złożonej z tych bloków.

Kolejna metoda, DE (ang. Dynamical Embedding), została zaproponowana przez Jamesa oraz Lowe'a [221]. W metodzie tej reprezentacją zapisu pojedynczego kanału jest macierz składająca się z szeregu opóźnionych wektorów pobranych z tego zapisu. Rozkład sygnału pobranego z pojedynczego kanału za pomocą metody DE może być przedstawiony następująco:

$$x_{de}(k) = [x(k\tau), \dots, x(k\tau + N - 1)]^T \quad (3.4.1)$$

gdzie: τ to opóźnienie czasowe, k to numer bloku, N to rozmiar otrzymanego wektora natomiast $(k\tau + N - 1)$ to długość oryginalnego sygnału. K elementowa macierz X_{de} która stanowi wejście

do algorytmu ICA jest tworzona w następujący sposób:

$$X_{de} = [x_{de}(1), x_{de}(2), \dots, x_{de}(K)]^T \quad (3.4.2)$$

Autorzy nie podają konkretnych wartości dla parametrów N oraz K (pisząc, że wartości te należy dobrać empirycznie), zalecają jednak, aby zachować poniższą proporcję [221]:

$$K > 2N + 1 \quad (3.4.3)$$

W przypadku gdy dostępnych jest więcej sygnałów oryginalnych, operacje 3.4.1 i 3.4.2 wykonywane są na każdym sygnale z osobna, a ostateczna macierz sygnałów wejściowych jest tworzona poprzez konkatencję macierzy X_{de} wyznaczonych dla każdego z sygnałów. Po stworzeniu macierzy wejściowej jest ona poddawana działaniu jednego z algorytmów ICA.

Kolejną metodą pozwalającą na rozwiązanie nisko-kanalowego modelu ICA jest metoda EEMD-ICA (ang. ensemble empirical mode decomposition ICA), która została opisana w [21, 22]. Metoda ta łączy zmodyfikowaną wersję algorytmu EMD (EEMD) i FastICA.

Oryginalny algorytm EMD definiuje zestaw niezależnych funkcji wewnętrznych, tzw. IMFs (ang. Intrinsic Mode Functions) uśrednionych dla danej liczby prób. Funkcje te reprezentują szybkie i wolne oscylacje. Muszą one spełniać dwa warunki. Warunek pierwszy mówi, że liczba ekstremów oraz przejść funkcji przez zero musi być równa lub różnić się co najwyżej o jeden. Drugi warunek mówi, że w dowolnym punkcie średnia wartość obwiedni zdefiniowanej przez lokalne maksima i obwiedni określonej przez lokalne minima wynosi zero [219, 222]. Aby uzyskać funkcje IMF z sygnału x stosowany jest proces przesiewania (ang. sifting). Sygnał $x(t)$ o czasie t może zostać rozłożony na funkcję IMF za pomocą kroków przedstawionych poniżej:

1. Wyznaczane są wszystkie lokalne ekstrema sygnału, które następnie są interpolowane za pomocą krzywej skleianej. Tworzona jest górna oraz dolna obwiednia sygnału, odpowiednio: $e_g(t)$ oraz $e_d(t)$.
2. Z obu obwiedni wyliczana jest średnia:

$$m_l(t) = \frac{e_g(t) + e_d(t)}{2} \quad (3.4.4)$$

3. Różnica pomiędzy oryginalnym sygnałem $x(t)$ a średnią m_l definiowana jest jako pierwszy komponent: h_1 :

$$h_1 = x(t) - m_l \quad (3.4.5)$$

4. Sprawdzane są oba warunki istnienia funkcji IMF. Jeżeli są spełnione, to sygnał h_1 jest uznawany za pierwszą funkcję IMF. W przeciwnym wypadku, powtarzane są kroki od 1 do 3.
5. Sygnał h_1 jest usuwany z oryginalnego sygnału. Różnica z tej operacji to sygnał resztkowy $r_1(t)$:

$$r_1(t) = x(t) - h_1(t) \quad (3.4.6)$$

6. Traktując $r_1(t)$ jako nowy sygnał bazowy, kroki od 1 do 5 można powtórzyć k razy otrzymując k funkcji IMF.

Proces przesiewania kończy się w sytuacji, kiedy sygnał r_k staje się funkcją monotoniczną lub stałą i nie można wyodrębnić kolejnych funkcji IMF. Dodatkowym warunkiem stopu jest wartość odchylenia standardowego pomiędzy dwoma kolejnymi funkcjami IMF:

$$SD = \sum_{t=1}^T \left\{ \frac{[h_{1(k-1)}(t) - h_{1k}(t)]^2}{h_{1(k-1)}^2(t)} \right\} \quad (3.4.7)$$

Jeżeli wartość SD jest mniejsza niż określony próg, proces jest zatrzymywany. Typowymi wartościami progowymi jest wartość pomiędzy 0.2 a 0.3 [222].

Jedną z głównych wad oryginalnego algorytmu EMD, przedstawionego powyżej, jest to, że jest on bardzo wrażliwy na zakłócenia. Dlatego wprowadzono bardziej niezawodną, zmodyfikowaną wersję algorytmu EMD, nazwaną EEMD [21, 223]. Wprowadzona modyfikacja polega na tym, że oryginalny algorytm EMD uruchamiany jest wielokrotnie, przy czym w każdej próbie algorytm EMD stosowany jest na pierwotnym sygnale z dodanym szumem, równym ułomkowi odchylenia standardowego oryginalnego sygnału [223]. Zestaw uśrednionych IMFów zwróconych przez algorytm EEMD stanowi wielokanałową reprezentację oryginalnego sygnału jednokanałowego [224]. Podobnie jak w algorytmie DE, w przypadku, kiedy rejestracja sygnału

EEG odbywała się przy wykorzystaniu większej liczby kanałów, to sygnał z każdego kanału jest z osobna poddawany działaniu algorytmu EEMD. Zestawy funkcji IMF wyznaczone dla każdego z kanałów są następnie łączone ze sobą, tworząc macierz wejściową dla algorytmu FastICA.

Ostatnie podejście, o którym warto wspomnieć, łączy w sobie algorytm ICA i dyskretną transformatę falkową - DWT (ang. Discrete Wavelet Transform) [21, 23, 24, 25, 26]. Podobnie jak we wcześniej wspomnianych metodach, również ten algorytm, o nazwie WICA (ang. wavelet ICA), składa się z dwóch części. Pierwsza część algorytmu ma na celu znalezienie wielokanałowej reprezentacji pojedynczego sygnału za pomocą dyskretnej transformacji falkowej. W [24] proponuje się użycie 3-poziomowej dekompozycji, zapewniającej czteroskładnikową reprezentację pojedynczego kanału (aproksymacja plus cztery detale). Autorzy argumentują, że taki schemat rozkładu w przybliżeniu zapewnia podział sygnału na cztery klasyczne podpasma EEG: delta, theta, alfa i beta. Podobnie jak w przypadku innych podejść, wieloskładnikowa reprezentacja uzyskana jako wynik dekompozycji falkowej jest następnie przesyłana do jednego z algorytmów ICA. Oczywiście, w przypadku, kiedy dostępnych jest więcej sygnałów, algorytm WICA jest wykonywany na każdym sygnale z osobna, a następnie aproksymacje i detale uzyskane dla każdego sygnału są konkatelowane do pojedynczej macierzy stanowiącej wejście dla algorytmu ICA.

Celem algorytmu ICA jest dekompozycja macierzy sygnałów wejściowych do macierzy oryginalnych źródeł. Model ICA, będący przykładem klasycznego rozkładu liniowego, zakłada, że sygnały wejściowe są mieszaninami sygnałów źródłowych. Dokładniej, model ten zakłada, że każdy sygnał składa się z tych samych źródeł, ale połączonych ze sobą w różnych proporcjach. Chociaż założenie to nie dotyczy wszystkich sygnałów rzeczywistych, to jest prawdziwe w większości przypadków – wiele sygnałów rejestrowanych z różnego rodzaju czujników faktycznie składa się z ważonej sumy sygnałów źródłowych.

Gdy SCICA, WICA lub EEMD-ICA rozkładają sygnał zarejestrowany z pojedynczego czujnika na komponenty, macierz wejściowa ICA składa się z sygnałów, które nie są ze sobą powiązane. Dlatego też, chociaż metody te zapewniają dodatkowe wymiary potrzebne modelowi ICA do zwrócenia większej liczby komponentów wyjściowych, to używają ICA jedynie do przekształcenia zestawu mniej lub bardziej niezależnych komponentów w inny zestaw

niezależnych komponentów. Transformacja taka bez „wzmocnienia” sygnałów źródłowych w macierzy wejściowej ICA jest znacznie mniej skuteczna niż transformacja przeprowadzona na macierzy wejściowej złożonej z mieszanin oryginalnych źródeł.

W niniejszej pracy zaproponowany jest prosty, ale skuteczny algorytm rozwiązania nisko-kanalowego modelu ICA. Ideą podejścia, nazwanego MAICA, jest utworzenie sztucznych sygnałów wejściowych poprzez zastosowanie zestawu filtrów o zerowej fazie na zarejestrowanych sygnałach EEG. Główną zaletą algorytmu MAICA jest to, że spełnia on założenie o zachowaniu mieszanin źródeł w macierzy wejściowej. Używając filtrów zero-fazowych o najmniejszych możliwych oknach, MAICA powtarza większość informacji zawartych w sygnałach z zarejestrowanych z czujników. W ten sposób nie tylko jest rozszerzany wymiar wejściowej macierzy ICA, ale również transformacja liniowa jest znacznie bardziej efektywna (co zostanie pokazane w rozdziale 6.1).

ROZDZIAŁ 4

EKSPERYMENTY WSTĘPNE


Jedno z założeń metody ICA, mówi, że liczba składowych uzyskanych na wyjściu algorytmu jest równa liczbie sygnałów wejściowych. Parafrazując to założenie, za pomocą algorytmu ICA nie można odzyskać większej liczby sygnałów źródłowych niż liczba sygnałów, która została podana na wejście algorytmu. Jeżeli więc cała informacja o systemie jest zawarta w sygnale zarejestrowanym z jednego czujnika pomiarowego, nie ma możliwości bezpośredniego rozłożenia tego sygnału za pomocą algorytmów ICA na sygnały stanowiące jego składowe. W niniejszym rozdziale zostanie omówiony szereg eksperymentów, które zostały przeprowadzone w celu znalezienia metody pozwalającej na wyeliminowanie powyższego ograniczenia metody ICA. W efekcie przeprowadzonych eksperymentów została opracowana metoda MAICA (ang. Moving Average ICA), której podstawową ideą jest wytworzenie sztucznych sygnałów, dostarczających dodatkowej przestrzeni umożliwiającej rozkład sygnałów wejściowych na liczbę składowych większą, aniżeli wymiar przestrzeni wejściowej. Opracowana metoda pozwala na skuteczne stosowanie algorytmów analizy składowych niezależnych nawet w przypadku rejestracji sygnału z jednego czujnika pomiarowego. Metoda MAICA zostanie szczegółowo opisana w rozdziałach 5 oraz 6 niniejszej pracy.

4.1 Badania prowadzone na sygnałach dźwiękowych

W ramach niniejszej rozprawy doktorskiej przeprowadzono szereg badań zmierzających do opracowania metody wstępnego przetwarzania sygnałów, dedykowanej dla nisko-kanalowych interfejsów EEG. Pierwsze dwa badania dotyczyły oceny skuteczności separacji za pomocą algorytmów ICA. W badaniach tych nie korzystano jeszcze z sygnałów EEG. Zamiast tego zastosowano sygnały dźwiękowe pozwalające w prosty sposób ocenić skuteczność metody ICA. Do osiągnięcia tego celu wykorzystano próbki śpiewu pochodzące z bazy dźwięków Wydziału Informatyki Zachodniopomorskiego Uniwersytetu Technologicznego. Baza ta zawiera nagrania śpiewów trzech ćwiczeń wykonywanych przez mężczyznę oraz kobietę w technice artykulacji legato. Ćwiczenia polegały na wyśpiewaniu co pół tonu następujących sekwencji:

- a, e, i, o, u
- do, la, a, do, la, a, do
- a, e, i, o, y

Do testów wybrane zostały 3 nagrania. Jedno z nich prezentowało głos śpiewaczki, dwa pozostałe śpiewaka. Każde nagranie zawierało inną sekwencję dźwięków. Kolejne nagrania (sygnały źródłowe) zostały oznaczone jako: *sygnal1*, *sygnal2* oraz *sygnal3*. Wykresy sygnałów źródłowych w dziedzinie czasu zaprezentowane są na Rysunku 4.1.1.



Rysunek 4.1.1 Sygnały źródłowe. Źródło: Opracowanie własne.

Na podstawie sygnałów z Rysunku 4.1.1 skonstruowano trzy nowe sygnały. Każdy nowo utworzony sygnał był mieszaniną dwóch spośród trzech sygnałów źródłowych. Mieszaniny sygnałów (Rysunek 4.1.2) nazwano odpowiednio *mix1*, *mix2* oraz *mix3*. Mieszanie nastąpiło zgodnie z wzorami:


$$mix1 = signal1 - 2 * signal2$$

$$mix2 = 0.73 * signal1 + 0.41 * signal2 \quad (4.1.1)$$

$$mix3 = 3.14 * signal3 + 1.69 * signal2$$

Jak wynika z porównania Rysunków 4.1.1 i 4.1.2 otrzymano sygnały wyraźnie różniące się przebiegiem czasowym. W celu matematycznego oszacowania różnicy między sygnałami

źródłowymi, a sygnałami zmieszanymi wykorzystano współczynnik korelacji wzajemnej (miara ta będzie wykorzystywana również do oceny stopnia podobieństwa składowych ICA oraz sygnałów źródłowych, zarówno w niniejszym eksperymencie, jak i w wielu kolejnych).



Rysunek 4.1.2 Sygnały uzyskane po przeprowadzeniu procesu mieszania zgodnie ze wzorem 4.1.1.
Źródło: Opracowanie własne.

Korelacja wzajemna jest miarą podobieństwa dwóch szeregów czasowych, z których jeden może być przesunięty w czasie. Dla szeregów czasowych a oraz b złożonych z r próbek każdy, korelacja wzajemna może zostać zapisana jako iloczyn [225, 226, 227]:

$$(a \star b)[sh] = \sum_{-\infty}^{\infty} a^*[r]b[r + sh] \quad (4.1.2)$$

gdzie a^* oznacza sprzężenie zespolone funkcji a , sh – przesunięcie pomiędzy funkcjami (mierzone liczbą próbek). W przypadku, gdy funkcje nie są skorelowane, wartość $(a \star b)$ będzie bliska zeru. W innym przypadku funkcja może osiągać dowolne wartości. Aby otrzymać wartości z przedziału $[-1,1]$ wprowadzono znormalizowaną wersję tej funkcji. Normalizacja funkcji korelacji wzajemnej, powoduje, że autokorelacja funkcji, która posiada zerowe przesunięcie w czasie wynosi 1. Określa się ją jako współczynnik korelacji Pearson'a który jest definiowany następująco [228]:

$$\rho_{a,b} = \frac{\text{cov}(a,b)}{\sigma_a \sigma_b} \quad (4.1.3)$$

gdzie: a , b to dwa sygnały, $cov(a,b)$ to kowariancja pomiędzy a oraz b , σ_a, σ_b to odchylenia standardowe odpowiednio a oraz b . Wartości unormowanego współczynnika korelacji wzajemnej mieszczą się w przedziale od -1.0 dla idealnej korelacji ujemnej do 1.0 dla idealnej korelacji dodatniej. Im wartość bliższa 0, tym mniejsza jest korelacja pomiędzy sygnałami. Jako że w prowadzonych badaniach znak korelacji nie był istotny, więc wszędzie w dalszej części pracy, gdzie jest mowa o korelacji sygnałów, analizowana jest wartość bezwzględna współczynnika zdefiniowanego wzorem 4.1.3.

Aby potwierdzić, że proces mieszania sygnałów przebiegł prawidłowo, dla każdej pary sygnał źródłowy – sygnał zmieszany, wyznaczono bezwzględną wartość współczynnika korelacji. Uzyskane wyniki przedstawiono w Tabeli 4.1.1. Jak można zauważyć każdy z sygnałów zmieszanych był podobny do dwóch sygnałów źródłowych, tych, które posłużyły do jego stworzenia. W celu dodatkowego potwierdzenia prawidłowego zmieszania sygnałów, pliki dźwiękowe zawierające mieszaniny sygnałów źródłowych odsłuchano i stwierdzono, że faktycznie w każdym nagraniu słychać dwa nakładające się głosy.


$\rho[x(t), y(t)]$	Mix1	Mix2	Mix3
s18m_e03_p26_o2_n10_d0_v.wav	0.4007	0.8344	0.0011
s20f_e05_p29_o4_n03_d0_v.wav	0.9200	0.5432	0.4678
s18m_e01_p22_o3_n11_d0_v.wav	0.0026	0.0056	0.8859

Tabela 4.1.1 Współczynnik korelacji sygnałów źródłowych oraz sygnałów uzyskanych na wyjściu algorytmu FastICA

4.1.1 Badanie 1

Na tak przygotowanych sygnałach przeprowadzono dwa badania. Celem pierwszego było oszacowanie jakości separacji sygnałów za pomocą algorytmu FastICA w wersji symetrycznej. Przygotowane mieszaniny sygnałów źródłowych wprowadzono więc na wejście algorytmu FastICA. Z uwagi na fakt, że algorytm ICA został uruchomiony na trzech sygnałach wejściowych, na wyjściu algorytmu również otrzymano trzy sygnały wynikowe, będące oszacowaniem sygnałów źródłowych. Składowe, obliczone za pomocą algorytmu FastICA, przedstawione są na Rysunku 4.1.1.1

Tabela 4.1.1.1 przedstawia współczynniki korelacji sygnałów źródłowych oraz składowych zwróconych w efekcie działania algorytmu FastICA. Jak można zaobserwować w tabeli, każda składowa osiągnęła idealną korelację dokładnie z jednym sygnałem źródłowym oraz korelację mniejszą niż 0.01 z pozostałymi sygnałami. Uzyskany wynik matematyczny potwierdzono poprzez odsłuchanie sygnałów zwróconych przez algorytm FastICA. Po odtworzeniu sygnałów zwróconych przez algorytm FastICA stwierdzono, że każdy z sygnałów zawierał pojedynczą sekwencję dźwięków nieodróżnialną od sekwencji źródłowej. Wynik uzyskany w pierwszym badaniu wskazywał więc, że algorytm FastICA pozwala na prawidłowy rozkład sygnałów zmieszanych na sygnały źródłowe.



Rysunek 4.1.1.1 Składowe obliczone za pomocą algorytmu FastICA w wersji symetrycznej.
Źródło: Opracowanie własne.

$\rho[x(t), y(t)]$	Składowa 1	Składowa 2	Składowa 3
s18m_e03_p26_o2_n10_d0_v.wav	0.0024	1.0000	0.0043
s20f_e05_p29_o4_n03_d0_v.wav	1.0000	0.0073	0.0068
s18m_e01_p22_o3_n11_d0_v.wav	0.0024	0.0005	1.0000

Tabela 4.1.1.1 Współczynniki korelacji sygnałów oryginalnych oraz składowych ICA otrzymane w badaniu pierwszym.

4.1.2 Badanie 2

W drugim badaniu do zmieszanych sygnałów dźwiękowych dodano również losowy szum z zakresu <5%; 10%> chwilowej wartości sygnału. Dodatkowo, w celu porównania jakości separacji za pomocą różnych algorytmów z rodziny ICA, w badaniu wykorzystano 5 algorytmów: Infomax, FastICA w wersji deflacyjnej, FastICA w wersji symetrycznej, Cubica oraz Kernel ICA. Tabela 4.1.2.1 przedstawia wyniki separacji dla pięciu wymienionych algorytmów.

$\rho[x(t), y(t)]$	Składowa 1	Składowa 2	Składowa 3	Składowa 4
KernelICA				
s18m_e03_p21_o3_n03_d0_v.wav	0.0009	0.0110	0.0037	0.9999
s20f_e05_p34_o3_n10_d0_v.wav	0.0005	0.0014	1.0000	0.0092
s18m_e01_p33_o2_n12_d0_v.wav	0.0026	0.9999	0.0080	0.0070
Szum	1.0000	0.0003	0.0028	0.0033
Cubica				
s18m_e03_p21_o3_n03_d0_v.wav	0.0139	0.0138	0.9998	0.0001
s20f_e05_p34_o3_n10_d0_v.wav	0.0052	0.9998	0.0193	0.0000
s18m_e01_p33_o2_n12_d0_v.wav	0.9999	0.0015	0.0099	0.0033
Szum	0.0000	0.0022	0.0002	0.5002
FastICA - podejście symetryczne				
s18m_e03_p21_o3_n03_d0_v.wav	0.9996	0.0008	0.0187	0.0188
s20f_e05_p34_o3_n10_d0_v.wav	0.0240	0.0014	0.9997	0.0083
s18m_e01_p33_o2_n12_d0_v.wav	0.0149	0.0002	0.0014	0.9999
Szum	0.0021	1.0000	0.0052	0.0092
FastICA - podejście deflacyjne				
s18m_e03_p21_o3_n03_d0_v.wav	0.9989	0.0029	0.0424	0.0187
s20f_e05_p34_o3_n10_d0_v.wav	0.0478	0.0017	0.9988	0.0045
s18m_e01_p33_o2_n12_d0_v.wav	0.0147	0.0018	0.0027	0.9999
Szum	0.0113	1.0000	0.0052	0.0026
Infomax				
s18m_e03_p21_o3_n03_d0_v.wav	0.0140	0.0318	0.0150	0.9989
s20f_e05_p34_o3_n10_d0_v.wav	0.9991	0.0244	0.0039	0.0025
s18m_e01_p33_o2_n12_d0_v.wav	0.0020	0.4674	0.4914	0.0183
Szum	0.0353	0.8824	0.8716	0.0439

Tabela 4.1.2.1 Współczynniki korelacji sygnałów oryginalnych oraz składowych ICA otrzymane w badaniu drugim.

Ideą dodania szumu było zasymulowanie artefaktów obecnych w sygnałach EEG. Badanie miało na celu sprawdzenie czy dodany szum zostanie odseparowany równie dobrze, jak sygnały dźwiękowe.

Jak widać trzy spośród pięciu wykorzystanych algorytmów (FastICA w wersji symetrycznej, FastICA w wersji deflacyjnej oraz KernelICA) pozwoliły na prawidłowe odzyskanie wszystkich sygnałów źródłowych, łącznie z dodanym sygnałem szumu. Wyniki pozostałych algorytmów były na nieco niższym poziomie. Algorytm Infomax prawidłowo odseparował szum, ale nie poradził sobie z dokładnym odseparowaniem poszczególnych sygnałów dźwiękowych. Z kolei algorytm Cubica prawidłowo odseparował sygnały oryginalne, na poziomie współczynnika korelacji około 0.9998, ale sygnał szumu nie odzyskał pierwotnej postaci. Najbardziej dokładny wynik separacji uzyskano za pomocą algorytmu KernelICA. Algorytm ten, z uwagi na ogromny narzut czasowy (czas pracy algorytmu był kilkanaście razy dłuższy niż pozostałych algorytmów), nie nadaje się jednak do stosowania w trybie rzeczywistym. Czas pracy algorytmów przedstawiony jest w Tabeli 4.1.2.2. Każdy z algorytmów został uruchomiony trzykrotnie.

	Czas(s)			
	1	2	3	Średnia
KernelICA	898.65	761.34	989.28	883.09
Cubica	0.7800	0.7800	0.7332	0.7630
FastICA - podejście symetryczne	1.9656	2.5116	1.3572	1.9448
FastICA - podejście deflacyjne	2.3244	1.9188	2.1996	2.1476
Infomax	23.3065	21.6841	21.9337	22.3081

Tabela 4.1.2.2 Czas działania algorytmów ICA (każdy algorytm był uruchomiony trzykrotnie)

Wyniki badań dotyczących separacji sygnałów dźwiękowych zostały opublikowane w dwóch publikacjach [229, 230].

Pierwsze eksperymenty przeprowadzone zostały na sygnałach dźwiękowych z uwagi na to, że efekty tych eksperymentów można było ocenić nie tylko wizualnie (na wykresach) oraz matematycznie (przy pomocy współczynnika korelacji), ale również doświadczalnie (odsluchanie plików dźwiękowych). Jako że eksperymenty te wykazały skuteczność algorytmów ICA w


procesie rozkładu mieszanin sygnałów na sygnały źródłowe, dalsze badania prowadzone już były z wykorzystaniem sygnałów EEG.

Podstawowym problemem jaki musiał zostać rozwiązany w momencie zmiany dziedziny sygnałów był problem szacowania dokładności transformacji, czyli zgodności składowych otrzymanych na wyjściu algorytmu ICA z sygnałami źródłowymi. W badaniu sygnałów śpiewu szacowanie dokładności transformacji odbywało się poprzez wyznaczenie wartości korelacji wzajemnej między sygnałami odzyskanymi, a sygnałami wzorcowymi. Takie podejście było możliwe, ponieważ sygnały wzorcowe były zadane z góry. W przypadku sygnałów EEG znane są jedynie sygnały zarejestrowane na powierzchni czaszki, które stanowią kombinację sygnałów emitowanych przez źródła podczaszkowe. Z uwagi na brak sygnałów wzorcowych, szacowanie dokładności transformacji nie mogło więc odbywać się na podstawie analizy zgodności. Z tego powodu, w kolejnych badaniach dokładność transformacji szacowano na podstawie dokładności klasyfikatora zbudowanego na podstawie zbioru sygnałów EEG. Takie rozwiązanie było możliwe, ponieważ badane zbiory EEG pochodziły w większości z sesji treningowych przeprowadzanych z interfejsami mózg-komputer, w których zarejestrowanym sygnałom EEG towarzyszyły etykiety klas informujące o zadaniach wykonywanych przez uczestnika eksperymentu.

4.2 Badania prowadzone na benchmarkowym zbiorze danych EEG

Sygnały wykorzystane w trzech kolejnych eksperymentach pochodziły z referencyjnego zbioru danych, przedstawionego na drugim konkursie BCI zorganizowanym przez Instytut Inżynierii Biomedycznej Wydziału Informatyki Medycznej Uniwersytetu Technologicznego w Graz. Zbiór ten zawierał sygnały EEG zarejestrowane w trakcie sesji treningowej pojedynczego podmiotu (25-letnia kobieta) z interfejsem mózg-komputer. Zadaniem uczestnika eksperymentu było kontrolowanie, za pomocą wyobrażenia ruchów lewej i prawej ręki, ruchów paska wyświetlanego na ekranie monitora. Wskazówki informujące o kierunku, w którym należy przesunąć pasek, wyświetlane były na ekranie w postaci strzałki wskazującej w lewą bądź prawą stronę. Kolejność kierunków była losowa. Eksperyment składał się z 280 prób, każda próba trwała 9 sekund. W trakcie pierwszych dwóch sekund na ekranie wyświetlane było jedynie czarne tło. Na koniec drugiej sekundy ($t = 2s$) generowano bodziec akustyczny. Jednocześnie wyświetlano na ekranie krzyż ogniskujący uwagę uczestnika na środku ekranu. Po upływie jednej sekundy krzyż


był usuwany z ekranu, a jego miejsce zajmowała wskazówka graficzna, informująca uczestnika, której ręki ruch powinien sobie wyobrazić. Strzałka w lewo oznaczała polecenie wyobrażenia ruchu ręki lewej, strzałka w prawo – polecenie wyobrażenia ruchu ręki prawej. Dokładny schemat czasowy eksperymentu został zaprezentowany na Rysunku 4.2.1.



Rysunek 4.2.1 Schemat eksperymentu przedstawionego na drugim konkursie BCI.

Źródło: <https://www.bbc.de/competition/ii/#datasets>.

Sygnały EEG rejestrowano w trzech bipolarnych kanałach EEG: C3, Cz i C4 (schemat montażu został zaprezentowany na Rysunku 4.2.2) z częstotliwością 128 Hz. Po zakończeniu rejestracji sygnały zostały wstępnie przefiltrowane w paśmie 0.5-30 Hz. Cały zestaw danych, zawierający dane z 280 prób, został następnie podzielony na dwa równe podzbiory - pierwszy przeznaczony był do treningu klasyfikatora, a drugi do zewnętrznego testu klasyfikatora. Ponieważ w repozytorium opublikowano pełen zestaw danych (zawierający zarówno sygnały EEG, jak i etykiety klas: 1 - lewa ręka, 2 - prawa ręka) tylko dla podzbioru treningowego, tylko ten podzbiór (140 prób) mógł zostać wykorzystany w opisanych poniżej badaniach.



Rysunek 4.2.2 Schemat montażu elektrod do rejestracji danych do eksperymentu przedstawionego na drugim konkursie BCI. Źródło: <https://www.bbc.de/competition/ii/#datasets>.

4.2.1 Badanie 3

Celem trzeciego z przeprowadzonych badań, opublikowanego w [213] było zbadanie wpływu algorytmu ICA na dokładność klasyfikacji w nisko-kanalowym interfejsie BCI. Badanie rozpoczęto od przygotowania czterech zbiorów danych. Każdy z nich składał się ze 140 prób, przy czym każda próba zawierała trzy 7-sekundowe sygnały EEG (z okresu od $t=3$ do $t=9$). Kolejne zbiory zawierały:

- sygnały oryginalne,
- sygnały przetworzone za pomocą algorytmu FastICA w wersji symetrycznej,
- sygnały przetworzone za pomocą algorytmu FastICA w wersji deflacyjnej,
- sygnały przetworzone za pomocą algorytmu Infomax.

Następnie dla każdego ze zbiorów opracowano odpowiadającą mu macierz cech. Każda cecha przedstawiała moc pasmową wyznaczoną na podstawie jednej sekundy jednego z sygnałów w jednym z 12 badanych pasm częstotliwości: paśmie alpha (8-13Hz), paśmie beta (13-30Hz), pięciu podpasmach pasma alpha (8-9Hz; 9-10Hz; 10-11Hz; 11-12Hz; 12-13Hz); oraz pięciu podpasmach pasma beta: (13-17Hz; 17-20Hz; 20-23Hz; 23-26Hz; 26-30Hz). W wyniku ekstrakcji cech uzyskano 252 cechy (7 sekund x 3 sygnały x 12 pasm). Następnie, z uwagi na bardzo wysoki rozmiar otrzymanego w ten sposób zbioru cech (252 cechy) oraz niewielką liczbę prób (140 prób) zdecydowano się przeprowadzić proces selekcji cech. W procesie tym wykorzystano algorytm genetyczny, opisany w [231]. Po przeprowadzeniu procesu selekcji otrzymano 6 zbiorów o rosnącej liczbie cech. Zbiór pierwszy zawierał tylko jedną cechę, najlepszą z punktu widzenia

klasyfikatora wykorzystanego do wyznaczenia wartości funkcji przystosowania, przetwarzanych w algorytmie genetycznym podzbiorów cech, zbiór ostatni zawierał sześć cech. W procesie klasyfikacji zastosowano liniową metodę SVM. Próg klasyfikacji został ustawiony na 0.5, a zatem wszystkie wyniki klasyfikatora większe niż 0.5 były klasyfikowane jako klasa „1” (prawa ręka), a wyniki mniejsze lub równe 0.5 - jako klasa „-1” (lewa ręka). Dokładność klasyfikatora szacowano przy wykorzystaniu 10-krotnej walidacji krzyżowej. Ostateczną miarą dokładności danego zestawu cech była średnia wartość obliczona na podstawie dokładności klasyfikacji uzyskanej dla 10 zestawów walidacyjnych.

Dla każdego z czterech zbiorów danych oraz każdego z sześciu poszukiwanych zbiorów cech uruchomiono 5-cio krotnie algorytm genetyczny. Średnie wyniki klasyfikacji uzyskane dla poszczególnej liczby cech i wszystkich zbiorów danych przedstawione są w Tabeli 4.2.1.1.

Liczba cech	Dane surowe		FastICA podejście deflacyjne		FastICA podejście symetryczne		Infomax	
	D [%]	S	D [%]	S	D [%]	S	D [%]	S
1	76.71	0.64	75.14	0.53	75.00	0.45	75.86	0.83
2	82.57	2.7	82.71	1.31	82.43	1.32	82.29	0.29
3	89.00	0.81	88.43	0.53	87.86	1.36	88.57	1.43
4	91.00	1.08	90.86	0.53	90.71	0.9	91.71	0.73
5	92.71	1.06	92.14	1.01	92.57	0.35	92.43	0.57
6	93.14	1.08	92.29	1.53	93.86	0.73	94.57	0.73
Średnia	87.52	1.23	86.93	0.91	87.07	0.85	87.57	0.76

Tabela 4.2.1.1 Średnia dokładność klasyfikacji uzyskana dla podzbiorów o różnej liczbie cech, wyznaczona dla danych surowych oraz danych przetworzonych przy wykorzystaniu trzech algorytmów ICA (D – dokładność, S – odchylenie standardowe).

Uzyskane wyniki były zaskakujące. Średnia precyzja klasyfikacji obliczona dla sygnałów wstępnie przetworzonych algorytmami ICA była równa 87.2%, co było wartością niższą niż średnia precyzja klasyfikacji obliczona dla sygnałów surowych (87.5%). Najwyższą średnią precyzję klasyfikacji dla wszystkich sześciu algorytmów genetycznych uzyskano za pomocą algorytmu Infomax (87.6%), nieco mniejszą precyzję uzyskano za pomocą algorytmu symetrycznego FastICA (87.1%), a najmniejszą precyzję uzyskano przy deflacji FastICA (86.9%). Analizując z kolei odchylenia standardowe wyników średnich można zauważyć, że wartość

odchylenia była średnio o 33% niższa w przypadku Infomax (0.8%) niż w przypadku surowych sygnałów (1.2%). Oznacza to, że algorytm Infomax dał bardziej stabilne wyniki i że są one bardziej wiarygodne niż wyniki obliczone na podstawie nieprzetworzonych sygnałów. Również dla sygnałów wstępnie przetworzonych za pomocą dwóch pozostałych algorytmów ICA wartość odchylenia standardowego była znacznie mniejsza niż w przypadku surowych danych (odchylenie standardowe obu algorytmów kształtowało się na poziomie 0.9%).

Biorąc pod uwagę odchylenie standardowe wyników należałoby wyciągnąć wniosek o praktycznej użyteczności transformacji ICA. Z drugiej strony jednak, porównanie wyników dokładności klasyfikacji wykazało niską skuteczność tej transformacji w systemie nisko-kanalowym, składających się jedynie z 3 sygnałów wejściowych (sygnały z kanałów C3, Cz, C4).

4.2.2 Badanie 4

W poprzednich badaniach użyteczność algorytmów ICA była badana na podstawie jakości odzyskanych sygnałów. Czy to na podstawie odwzorowania sygnałów oryginalnych czy dokładności klasyfikacji zwróconej przez klasyfikator. Powodowało to, że algorytm ICA był traktowany jako rodzaj „czarnej skrzynki”. W czwartym z kolei badaniu [232] podjęto próbę sprawdzenia czy zastosowanie algorytmu ICA spowoduje wzmocnienie źródeł w składowych wynikowych, w taki sposób, że źródła mózgowe zostaną wzmocnione w pewnych składowych, natomiast artefakty w innych.

Badanie ponownie przeprowadzono na danych konkursowych z drugiego konkursu BCI. Tym razem uwzględniono jednak pełną długość próby, czyli wszystkie 9 sekund. W badaniu analizowano wyniki uzyskane za pomocą tych samych algorytmów ICA, jak w badaniu 3-cim. Również metoda ekstrakcji cech była taka sama. Z uwagi na zwiększoną liczbę sekund w wyniku ekstrakcji cech uzyskano 324 cechy (9 sekund x 12 pasm x 3 kanały) dla każdego z czterech zbiorów danych (zbiór 1 - sygnały surowe; zbiór 2 – składowe FastICA podejście deflacyjne; zbiór 3 - składowe FastICA podejście symetryczne; zbiór 4 – składowe Infomax).

Następnie dla każdego ze zbiorów danych wyznaczono 7 podzbiorów cech:

- 3 podzbiory zawierające cechy wyznaczone tylko z jednego kanału/składowej ICA (kanału: C3, C4, Cz lub składowej ICA: składowa1, składowa2, składowa3),
- 3 podzbiory zawierające cechy wyznaczone z dwóch kanałów/składowych ICA (kanałów: C3-C4, C3-Cz, lub C4-Cz lub składowych ICA: składowa1-składowa2, składowa1-składowa3, składowa2-składowa3),
- 1 podzbiór zawierające cechy wyznaczone ze wszystkich trzech kanałów/składowych ICA (kanałów: C3-C4-Cz lub składowych ICA składowa1-składowa2-składowa3).

Z uwagi na niejednorodną liczbę cech w kolejnych podzbiorach (oraz niewielką liczbę danych), liczba cech została zmniejszona do 6 przy wykorzystaniu algorytmu LASSO (ang. least absolute shrinkage and selection operator) zaproponowanego przez Tibshiraniego [233]. W charakterze klasyfikatora wykorzystano ponownie liniową wersję metody SVM. Wyniki klasyfikacji dla poszczególnych algorytmów i poszczególnych podzbiorów cech zostały przedstawione w Tabeli 4.2.2.1.

Na podstawie Tabeli 4.2.2.1 trudno jest wyciągnąć jakiekolwiek wnioski odnośnie postawionego na początku badania pytania badawczego ‘Czy zastosowanie algorytmu ICA spowoduje wzmocnienie źródeł w składowych wynikowych, w taki sposób, że źródła mózgowe zostaną wzmocnione w pewnych składowych, natomiast artefakty w innych?’. Wynika to z faktu, że algorytmy ICA są niejednoznaczne w stosunku do kolejności składowych, co powoduje, że na podstawie Tabeli 4.2.2.1 nie można nawet stwierdzić, czy *składowa1* wyznaczona dla algorytmu Infomax odpowiada *składowej1* wyznaczonej dla któregośkolwiek algorytmu FastICA.

	FastICA podejście deflacyjne	FastICA podejście symetryczne	Infomax	Surowe sygnały
Składowa 1	0.78	0.72	0.75	0.74
Składowa 2	0.76	0.60	0.80	0.66
Składowa 3	0.57	0.81	0.60	0.76
Składowa 1+2	0.90	0.74	0.91	0.75
Składowa 2+3	0.72	0.76	0.77	0.87
Składowa 1+3	0.78	0.90	0.75	0.89
Składowa 1+2+3	0.90	0.89	0.90	0.89

Tabela 4.2.2.1 Dokładność klasyfikacji; w przypadku kolumny ‘Surowe sygnały’ składowa 1 oznacza kanał C3, składowa 2 – kanał Cz, natomiast składowa 3 – kanał C4.

Aby zweryfikować postawione pytanie badawcze skorelowano składowe uzyskane za pomocą poszczególnych algorytmów ICA z oryginalnymi sygnałami, a następnie porównano dokładność klasyfikacji uzyskaną dla wszystkich składowych w najwyższym stopniu skorelowanych z każdym z kanałów. Motywacją do przyjęcia takiego podejścia był fakt, że podczas ruchu bądź wyobrażenia ruchu lewą ręką aktywne są źródła korowe umieszczone w polu recepcyjnym kanału C4, natomiast podczas ruchu/wyobrażenia ruchu ręką prawą uaktywniają się źródła korowe znajdujące się w lewej korze motorycznej (pole recepcyjne kanału C3). Stąd, składowe pozwalające na uzyskanie najwyższej dokładności klasyfikacji powinny być silnie skorelowane z kanałem C3 lub C4 oraz słabo skorelowane z kanałem Cz. Tabele 4.2.2.2-4.2.2.4 przedstawiają wartości współczynnika korelacji dla każdej pary składowa-kanał.

Jak można zauważyć w Tabelach 4.2.2.2-4.2.2.4, w przypadku każdego algorytmu każda składowa mogła zostać jednoznacznie przyporządkowana do jednego z kanałów. Dodatkowo, tak jak się spodziewano, korelacja między składowymi, a kanałami C3 i C4 w każdym przypadku była bardzo wysoka (wyższa niż 0.9). Oznacza to, że składowe te przejęły większość sygnału z kanałów C3 i C4 (wysoka korelacja). Z drugiej strony korelacja dla sygnałów powiązanych z kanałem Cz jest znacznie niższa (60-80%). Wskazuje to na to, że kanał Cz został przetransformowany przez ICA dużo bardziej niż kanały C3 oraz C4. Jednym z możliwych wyjaśnień tego faktu jest to, że kanał Cz zebrał pewną ilość szumów zawieranych w pozostałych komponentach. Na pytanie o to, czy dzięki zastosowaniu algorytmu ICA źródła mózgowe zostały wzmocnione w składowych odpowiadających kanałom C3 i C4 oraz osłabione w składowych odpowiadających kanałowi Cz odpowiada Tabela 4.2.2.5, w której zaprezentowano te same wyniki klasyfikacji, co w Tabeli 4.2.2.1, ale uporządkowane według korelacji poszczególnych składowych z kolejnymi kanałami.

	C3	Cz	C4
Składowa 1	0.97759	0.61553	0.41819
Składowa 2	0.10162	0.62911	0.07574
Składowa 3	0.18436	0.4747	0.90519

Tabela 4.2.2.2 Korelacja sygnałów surowych oraz składowych ICA obliczonych za pomocą algorytmu FastICA w wersji symetrycznej.

	C3	Cz	C4
Składowa 1	0.25626	0.44363	0.9218
Składowa 2	0.9129	0.42612	0.29127
Składowa 3	0.3177	0.78842	0.25582

Tabela 4.2.2.3 Korelacja sygnałów surowych oraz składowych ICA obliczonych za pomocą algorytmu FastICA w wersji deflacyjnej.

	C3	Cz	C4
Składowa 1	0.96759	0.60171	0.3677
Składowa 2	0.23442	0.47632	0.92254
Składowa 3	0.086001	0.63513	0.10734

Tabela 4.2.2.4 Korelacja sygnałów surowych oraz składowych ICA obliczonych za pomocą algorytmu Infomax.

Jak można zaobserwować w Tabeli 4.2.2.5 w przypadku klasyfikacji na podstawie pojedynczych kanałów, najwyższą dokładność (w przypadku każdego algorytmu) uzyskano dla kanału C4, nieco gorszą dla kanału C3 a najgorszą dla kanału Cz. Biorąc pod uwagę wspomnianą wcześniej lokalizację poszczególnych kanałów, transformacja ICA nie tylko przebiegła prawidłowo, ale faktycznie spowodowała wzmocnienie źródeł mózgowych w składowych skorelowanych z kanałem C4. Wyniki uzyskane dla par sygnałów również potwierdzają powyższy wniosek. Maksymalną dokładność w każdym przypadku uzyskano dla składowych skorelowanych z kanałami C3 i C4, dodatkowo dokładność ta była nieco wyższa po zastosowaniu algorytmów ICA niż w odniesieniu do surowego sygnału. Poprawa była co prawda nieznaczna, ale wystąpiła dla wszystkich trzech algorytmów ICA.

	FastICA deflacyjny	FastICA symetryczny	Infomax	Sygnały surowe
C3	0.76	0.72	0.75	0.74
Cz	0.57	0.60	0.60	0.66
C4	0.78	0.81	0.80	0.76
C3, Cz	0.72	0.74	0.75	0.75
Cz, C4	0.78	0.76	0.77	0.87
C3, C4	0.90	0.90	0.91	0.89
C3, Cz, C4	0.90	0.89	0.90	0.89

Tabela 4.2.2.5 Dokładność klasyfikacji po skorelowaniu składowych ICA z sygnałami zarejestrowanymi w poszczególnych kanałach.

Skomentowania wymaga tu jeszcze porównanie wyników klasyfikacji dla trzech oraz dwóch sygnałów. Jak można zauważyć w Tabeli 4.2.2.5, klasyfikacja dla sygnałów C3+C4 dała co najmniej tak samo dobry efekt (w przypadku algorytmów Infomax oraz FastICA w wersji symetrycznej nawet lepszy) jak klasyfikacja dla sygnałów C3+Cz+C4. Oznaczać to może, że jedna ze składowych (odpowiadająca kanałowi Cz) zakumulowała szumy i/lub artefakty z dwóch pozostałych sygnałów i dlatego nie wnosi żadnej dodatkowej informacji do klasyfikatora. Pozwala to wysunąć wniosek, że użycie zaledwie dwóch, lecz kluczowych, kanałów C3+C4 daje tak samo dobre a często nawet lepsze wyniki klasyfikacji niż użycie zestawu z kanałem Cz. Poza wyższą dokładnością klasyfikacji, zastosowanie mniejszej liczby kanałów umożliwia redukcję złożoności obliczeniowej systemu.

4.2.3 Badanie 5

Badania 2-4 pozwoliły zapoznać się z jakością algorytmów ICA dla nisko kanalowych macierzy danych. Nie wszystkie algorytmy jednak, dawały poprawę w każdym z wymienionych przypadków. Najgorzej w zestawieniu wypadał algorytm FastICA w wersji deflacyjnej. Prawdopodobnie przyczyną tego jest kumulacja błędów podczas obliczania kolejnych składowych niezależnych. Lepiej w zestawieniach wypadał drugi z algorytmów FastICA, algorytm symetryczny, chociaż dawał nieco gorsze wyniki niż algorytm Infomax. Nie wymagał on jednak ustawiania, ani modyfikacji w trakcie działania wartości żadnych parametrów, tak jak ma to miejsce w algorytmach gradientowych, których przykładem jest Infomax. Pomimo więc, że algorytm Infomax pozwolił na uzyskanie trochę dokładniejszych wyników, w dalszych eksperymentach wykorzystywano wyłącznie algorytm FastICA w wersji symetrycznej.

Wyniki opisanego powyżej badania stały się inspiracją do kolejnego (piątego) badania [234]. W badaniu tym również wykorzystano zbiór danych z II-go konkursu BCI, ale powiększony o trzy sztucznie wygenerowane sygnały. Każdy z dodatkowych sygnałów (nazwanych $N1$, $N2$ i $N3$) miał liczbę próbek równą liczbie próbek sygnału EEG i zawierał losowy szum z przedziału $\langle -0.05, 0.05 \rangle$. W badaniu postanowiono sprawdzić, czy dodanie do zbioru sygnałów zarejestrowanych z kanałów rzeczywistych większej (niż jeden) liczby kanałów sztucznych pozwoli na bardziej skuteczne odseparowanie szumów i artefaktów od rzeczywistych źródeł

mózgowych. Innymi słowy, celem badania było sprawdzenie, czy w efekcie transformacji ICA wygenerowane sztucznie sygnały zaabsorbują szумы i artefakty z rzeczywistego sygnału EEG.

W przeciwieństwie do dwóch wcześniej opisanych badań, tym razem w procesie transformacji oryginalnego zbioru sygnałów wykorzystano tylko jeden algorytm ICA – FastICA w wersji symetrycznej. Algorytm ten uruchomiono dwukrotnie, raz dla zbioru trzech i raz dla zbioru sześciu sygnałów. Po zakończeniu algorytmu uzyskano więc trzy zbiory danych:

- zbiór Oryginalny - zbiór trzech oryginalnych sygnałów EEG, zarejestrowanych w kanałach C3, Cz i C4,
- zbiór ICA3 – zbiór trzech składowych wyznaczonych po zastosowaniu algorytmu ICA na macierzy oryginalnych sygnałów EEG,
- zbiór ICA6 – zbiór sześciu składowych wyznaczonych po zastosowaniu algorytmu ICA na macierzy złożonej z trzech oryginalnych sygnałów EEG oraz trzech sygnałów sztucznie wygenerowanych.

Podobnie jak w badaniu czwartym, składowe ze zbiorów ICA3 i ICA6 przyporządkowano do odpowiednich sygnałów wejściowych korelując je z sygnałami oryginalnymi (w przypadku drugiego zbioru) oraz z sygnałami oryginalnymi i sztucznymi (w przypadku trzeciego zbioru). Następnie dla wszystkich możliwych jedno, dwu i trzejelementowych kombinacji sygnałów z każdego z trzech zbiorów przeprowadzono proces ekstrakcji oraz selekcji cech i klasyfikacji. Otrzymane wyniki klasyfikacji zaprezentowane są w Tabeli 4.2.3.1. W przypadku zbioru ICA6 w tabeli nie podano wyników klasyfikacji dla sygnałów skorelowanych z sygnałami sztucznie wygenerowanymi z uwagi na to, że:

- dla kombinacji składających się wyłącznie z sygnałów przyporządkowanych do sygnałów $N1$, $N2$, $N3$ dokładność klasyfikacji była na poziomie błędu losowego,
- dla kombinacji składających się z sygnałów przyporządkowanych zarówno do sygnałów $N1$, $N2$, $N3$, jak i z sygnałów przyporządkowanych do sygnałów oryginalnych, dokładność klasyfikacji była identyczna, jak w przypadku kombinacji zawierającej wyłącznie odpowiednie sygnały oryginalne.

	Oryginalny	ICA3	ICA6
C3	0.74	0.72	0.74
Cz	0.66	0.60	0.65
C4	0.76	0.81	0.83
C3, Cz	0.75	0.74	0.75
Cz, C4	0.87	0.76	0.81
C3, C4	0.89	0.90	0.92
C3, Cz, C4	0.89	0.89	0.92

Tabela 4.2.3.1 Dokładność klasyfikacji uzyskana dla każdej kombinacji sygnałów odpowiadających kanałom C3, Cz i C4 dla wszystkich zestawów danych: oryginał, ICA3 i ICA6.

Z Tabeli 4.2.3.1 widać, że dokładność klasyfikacji dla zbioru opracowanego z wykorzystaniem sztucznie wygenerowanych sygnałów (zbioru ICA6) była najwyższa. Zwiększenia dokładności nie można przypisać zwiększonemu wymiarowi przestrzeni wejściowej klasyfikatora trenowanego na zbiorze ICA6, ponieważ, pomimo że liczba cech wyznaczonych na podstawie sześciu sygnałów była dwukrotnie wyższa (648 cech) niż w przypadku trzech sygnałów (324 cechy), to w procesie selekcji każdy zbiór cech redukowany był do podzbioru składającego się z tej samej liczby sześciu najbardziej istotnych cech. Jednym z możliwych wyjaśnień zwiększenia dokładności klasyfikacji jest to, że sztucznie wygenerowane sygnały faktycznie zaabsorbowały część artefaktów występujących w sygnałach oryginalnych.

Jak już wspomniano, klasyfikatory, które były budowane na zbiorach złożonych z sygnałów oryginalnych oraz sygnałów sztucznych każdorazowo charakteryzowały się identyczną dokładnością jak odpowiednie klasyfikatory trenowane jedynie na danych pochodzących z kanałów oryginalnych. Przyczynę takiego zachowania pokazuje Tabela 4.2.3.2. W tabeli tej przedstawiono zestaw sześciu cech każdorazowo wybieranych przez metodę LASSO w procesie selekcji cech dla danego zestawu sygnałów. Jak można zauważyć w tabeli, bez względu na to, ile sztucznych sygnałów było dodawanych, finalny zbiór najbardziej istotnych cech pozostawał taki sam jak w przypadku zbioru zawierającego cechy wyznaczone wyłącznie na podstawie składowych odpowiadających kanałom C3 oraz C4.

Celem opisanego badania, było sprawdzenie czy dodanie sztucznie wygenerowanego szumu do surowego sygnału EEG, przyniesie jakąś praktyczną korzyść. Ze względu na polepszenie się wyników klasyfikacji, pomysł był częściowo dobry (pomimo, że nie do końca zgodny z teorią metody składowych niezależnych, która wymaga, aby maksymalnie jeden z sygnałów wejściowych charakteryzował się rozkładem gaussowskim). Dodatkowe sygnały zaabsorbowały szum, czym przyczyniły się do poprawy wyników klasyfikacji. Poprawa dokładności klasyfikacji była jednak nieznaczna.

Kanały	Dokładność [%]	Indeksy cech					
		1	2	3	4	5	6
C3	0.74	5	112	167	491	546	598
C4	0.83	24	185	187	291	453	561
C3, C4	0.92	5	24	167	168	185	291
C3, C4, i każdy inny kanał	0.92	5	24	167	168	185	291
C3, C4, i dowolne, dwa pozostałe kanały	0.92	5	24	167	168	185	291
C3, C4, i dowolne, trzy pozostałe kanały	0.92	5	24	167	168	185	291
C3, C4, i dowolne, cztery pozostałe kanały	0.92	5	24	167	168	185	291
C3, C4, Cz, N1, N2, N3	0.92	5	24	167	168	185	291

Tabela 4.2.3.2 Zestawy najbardziej istotnych cech wybranych za pomocą metody LASSO dla różnych kombinacji sygnałów pochodzących ze zbioru danych ICA6.

4.3 Badania prowadzone na danych EEG zarejestrowanych w trakcie zaplanowanych eksperymentów badawczych

Badanie ze sztucznie wygenerowanymi sygnałami złożonymi wyłącznie z losowego szumu było pierwszym podejściem do generowania sztucznych sygnałów. Niewielka poprawa dokładności skłoniła do głębszego zastanowienia się czy podejście to jest na pewno słuszne. Stwierdzono, że być może sztuczne kanały nie powinny być czysto losowe, ponieważ, pomimo tego, że sygnały losowe są w stanie zaabsorbować część szumu występującego w oryginalnych

sygnałach, to nie są w stanie przejąć współistniejących w nich artefaktów. Postanowiono więc zmienić podejście na takie, które ułatwiłoby dodatkowym sygnałom absorbowanie artefaktów.

Zauważono, że aby dodatkowe sygnały miały możliwość przejmowania artefaktów będących składowymi sygnałów oryginalnych, powinny być podobne albo do artefaktów, albo do sygnałów źródłowych. Biorąc pod uwagę fakt, że zarówno artefakty, jak i sygnały źródłowe stanowią składowe sygnałów rejestrowanych w kanałach EEG, stwierdzono więc, że sztucznie generowane sygnały powinny częściowo powielać informację niesioną przez sygnały rejestrowane w kanałach EEG. W ten sposób jedne z nowo tworzonych sygnałów powinny przejmować poszczególne artefakty, a inne - sygnały generowane przez źródła mózgowe.

Słuszność powyższego stwierdzenia postanowiono sprawdzić w najprostszy możliwy sposób, to jest poprzez dodanie do trzech kanałów zawierających informację pochodzącą ze źródeł mózgowych, istotnych z punktu widzenia danego badania, trzech kanałów rejestrujących sygnał EEG z okolic korowych teoretycznie nieistotnych dla danego badania. W przeprowadzonym w tym celu badaniu wykorzystano dane zarejestrowane w trakcie eksperymentu przeprowadzonego w laboratorium badawczym Zespołu Neuroanaliz Wydziału Informatyki Zachodniopomorskiego Uniwersytetu Technologicznego w Szczecinie.

Eksperyment przeprowadzono na 32 letnim, zdrowym, mężczyźnie. Szczegółowy schemat eksperymentu był następujący. Uczestnik eksperymentu został umieszczony w wygodnym krześle. Naprzeciwko niego, w odległości około 100cm, znajdował się monitor, na którym wyświetlano informacje o zadaniu, które miał aktualnie wykonywać. Eksperyment został podzielony na 200 prób. Podczas każdej próby uczestnikowi pokazywano strzałkę skierowaną w lewo lub w prawo. Zadaniem badanego było wyobrazić sobie obrotowy ruch dłoni w nadgarstku ręką wskazaną przez strzałkę (strzałka w lewo - lewa ręka; strzałka w prawo - prawa ręka). Kierunki strzałek dla kolejnych prób zostały wybrane losowo. Długość próby wynosiła 10 sekund. Pomiędzy próbami nie było przerw. Eksperyment podzielono na 4 sesje, każda po 50 prób. Pomiędzy sesjami były 3 minuty przerwy. W trakcie eksperymentu rejestrowano dane EEG z sześciu monopolarnych kanałów: O1, O2, Pz, C3, Cz i C4, z wspólną referencją umieszczoną na płatku lewego ucha oraz elektrodą uziemiającą umieszczoną w położeniu Fpz. Częstotliwość

próbki wynosiła 256 Hz. Sygnał EEG był rejestrowany za pomocą wzmacniacza Discovery 20 (BrainMaster) oraz oprogramowania OpenVibe [235].

Na etapie wstępnego przetwarzania danych sygnał EEG zarejestrowany we wszystkich 6 kanałach przefiltrowano w paśmie 4-35 Hz za pomocą filtra pasmowo-przepustowego Butterworth czwartego rzędu. Następnie przygotowano 16 zestawów danych zawierających różne kombinacje kanałów. Dwa kanały, kluczowe przy rozpoznawaniu ruchu rąk - C3 i C4, były rdzeniem analizy i dlatego były obecne w każdym zestawie. Zestaw podstawowy nazwano S2 („2” oznacza dwa wejścia, „S” oznacza „sygnał”). Cztery pozostałe kanały zostały dodane do zestawu podstawowego we wszystkich możliwych kombinacjach, tworząc pozostałe 15 zestawów. Stworzono więc:

- 4 zestawy trzywejściowe (S3 Cz; S3 Pz; S3 O1; S3 O2);
- 6 zestawów czterowejściowych (S4 Cz Pz; S4 Cz O1; S4 Cz O2; S4 Pz O1; S4 Pz O2; S4 O1 O2);
- 4 zestawy pięciowejściowe (S5 Cz Pz O1; S5 Cz Pz O2; S5 Cz O1 O2; S5 Pz O1 O2);
- 1 zestaw sześciowejściowy (S6).

Gdy zestawy były gotowe, wszystkie z nich (oprócz zestawu podstawowego, który pozostał niezmienny jako zestaw referencyjny), przesyłano jeden po drugim do algorytmu FastICA. W rezultacie 15 zestawów sygnałów zostało przekształconych w 15 zestawów niezależnych komponentów zwróconych przez FastICA. Nowe zestawy nazwano zgodnie z tym samym schematem co zestawy sygnałów, z prefiksem „IC” („IC” oznacza „Independent Component”). W dalszej analizie wykorzystano 16 zestawów danych: zestaw składający się z surowych sygnałów C3 i C4 oraz 15 zestawów składających się ze składowych zwróconych przez algorytm FastICA w wersji symetrycznej.

Aktualnie opisywane badanie różniło się od poprzednich jednym bardzo ważnym elementem. We wszystkich dotychczas opisanych badaniach transformacja ICA była wykonywana na pełnym sygnale. Oznacza to, że sygnały zarejestrowane z poszczególnych prób były konkatelowane i każdorazowo tylko jedna transformacja była przeprowadzana. Takie podejście było prawidłowe, dopóki analiza była prowadzona w trybie offline na wcześniej zarejestrowanym

sygnale i dopóki badania prowadzono na zasadzie badań porównawczych, porównujących wyniki uzyskiwane przy wykorzystaniu algorytmów ICA z wynikami uzyskanymi dla sygnałów surowych. Interfejs mózg-komputer działa jednak w trybie online, co oznacza, że klasyfikacja jest prowadzona dla każdej nowo zarejestrowanej porcji danych. Tak więc kiedy eksperymenty są prowadzone z udziałem interfejsu mózg-komputer i mają na celu zastosowanie opracowanej metodologii w trybie online, wszystkie etapy przetworzenia sygnału, począwszy od przetwarzania wstępnego sygnału, kończącego się zastosowaniem transformacji ICA, aż po ekstrakcję i selekcję cech muszą być wykonywane dla każdej próby z osobna.

Począwszy od aktualnego badania, wszystkie działania były prowadzone na każdej próbie z osobna. W efekcie zmiany podejścia natknęto się na bardzo poważny problem praktyczny, który dodatkowo należało rozwiązać w trakcie prowadzonych badań. Problem wynikał z nieokreśloności modelu ICA co do kolejności składowych wynikowych. Dopóki transformacja była prowadzona na całym sygnale z osobna, kolejność składowych nie miała żadnego znaczenia, ponieważ poszczególne cechy były wyznaczane w kolejnych próbach zawsze z tych samych składowych. W momencie, kiedy transformację przeprowadzono dla każdej próby z osobna, cechy wyznaczone dla jednej próby nie miały bezpośredniego odniesienia do cech z kolejnej próby. W związku z tym proces trenowania klasyfikatora stał się niemożliwy do przeprowadzenia. Przed udzieleniem odpowiedzi na postawione wcześniej pytanie badawcze *‘czy dodatnie kanałów nieistotnych z punktu widzenia analizowanych zjawisk przyniesie poprawę dokładności klasyfikacji’* należało więc rozwiązać problem jednoznacznego uporządkowania składowych ICA w kolejnych próbach.

Aby rozwiązać opisany powyżej problem rozpoczęto poszukiwanie metody, która pozwoliłaby, wzorem wcześniej przeprowadzonych badań, powiązać (sparować) poszczególne składowe ICA z zarejestrowanymi sygnałami EEG. Jako miarę jakości parowania wykorzystano dokładność klasyfikacji. W procesie klasyfikacji ponownie wykorzystano liniowy klasyfikator SVM, na którego wejścia wprowadzono osiem cech pasmowych uznanych za najbardziej istotne z punktu widzenia metody LASSO.

W pierwszym podejściu jako miarę podobieństwa składowych ICA i surowych sygnałów EEG wykorzystano stosowany już wcześniej współczynnik korelacji. Okazało się jednak, że wyniki metody, która dawała bardzo dobre rezultaty przy długich sygnałach (161280 próbek: 9

sekund x 128 Hz x 140 prób), są zupełnie niezadowalające dla sygnałów krótkich (2560 próbek: 10 sekund x 256 Hz). Z uwagi na niewielką długość parowanych sygnałów współczynniki korelacji były tu bardzo niejednoznaczne. W niektórych próbach wskazywały wręcz na możliwość przyporządkowania jednej składowej do dwóch lub nawet większej liczby sygnałów oryginalnych. Niejednoznaczne parowanie składowych ICA z sygnałami oryginalnymi powodowało, że dokładność klasyfikacji wyznaczona dla poszczególnych kombinacji składowych była znacznie gorsza od dokładności klasyfikacji wyznaczonej dla pary surowych sygnałów C3 i C4.

Z literatury wynika, że wyobrażeniu ruchu ręki towarzyszy desynchronizacja w paśmie mu w korze motorycznej zawiadującej ruchami danej ręki (lewa ręka – prawa kora motoryczna, kanał C4; prawa ręka – lewa kora motoryczna – kanał C3) oraz następuje do ruchu desynchronizacja w paśmie beta nad korą motoryczną kontrlateralnej półkuli [6]. Biorąc wskazany fakt pod uwagę, w kolejnym podejściu spróbowano parować składowe ICA z oryginalnymi sygnałami opierając się na podobieństwie mocy obu grup sygnałów w paśmie mu i/lub beta. Dokładniej mówiąc, porównywano tu nie tyle samą moc sygnałów, co miejsce składowej/sygnału w hierarchii – np. składowa ICA o najwyższej mocy w paśmie beta była przypisywana do tego sygnału oryginalnego, który wykazywał się również najwyższą mocą w tym samym paśmie. Pomimo, że podejście to wydawało się być słuszne i w pełni zgodne z teorią, to jednak okazało się, że dokładność klasyfikacji również była niższa niż dokładność klasyfikacji przeprowadzonej na nieprzetworzonej parze sygnałów C3 i C4. Przyczyną słabych wyników był najprawdopodobniej fakt, że moc sygnałów we wskazanych pasmach wyznaczano bazując na całej próbie, bez dokładnego lokalizowania wzrostu/spadku mocy w obrębie próby.

W kolejnym podejściu wykorzystano macierz demiksującą zwracaną, wraz ze składowymi wynikowymi, przez algorytm FastICA w wersji symetrycznej. Kolejne wiersze tej macierzy informują o udziale jaki ma każdy zarejestrowany sygnał w kolejnych składowych ICA. Podczas parowania składowych ICA i sygnałów oryginalnych wykorzystano tę informację i parowano każdą składową z tym kanałem, który, zgodnie ze współczynnikami zawartymi w macierzy demiksującej, był najsilniej w niej reprezentowany. Proces parowania rozpoczynał się od wyszukania w macierzy demiksującej współczynnika o maksymalnej wartości bezwzględnej i powiązania składowej o numerze odpowiadającym numerowi wiersza tego współczynnika z

sygnałem oryginalnym o numerze odpowiadającym numerowi kolumny. W kolejnej iteracji powtarzano oba kroki dla kolejnego maksymalnego współczynnika. Procedurę powtarzano tak długo, aż sparowano wszystkie składowe ICA z wszystkimi sygnałami oryginalnymi. Opisane podejście ponownie wydawało się być całkiem uzasadnione (szczególnie, że dokładnie w taki sam sposób tworzone są mapy przedstawiające rozkład składowych ICA na powierzchni czaszki), jednak również nie spowodowało zwiększenia dokładności klasyfikacji.

Po głębszej analizie przedstawionego podejścia udało się znaleźć właściwe rozwiązanie. Składowe zwracane przez algorytmy ICA są z definicji najbardziej niezależnymi komponentami sygnałów zarejestrowanych z czujników pomiarowych. W sygnałach rejestrowanych za pomocą elektrod naczaszkowych największy wkład mają najczęściej artefakty. Tak więc, gdy proces parowania rozpoczynano od składowych ICA, które miały najwyższe bezwzględne wartości współczynników demiksujących, to wykrywano kanały, w których składowe te (najprawdopodobniej stanowiące artefakty) były najsilniej reprezentowane. W ten sposób, na początkowym etapie, prawdopodobnie parowano artefakty z kanałami, w których miały one największy udział, a następnie próbowano przeprowadzić parowanie między pozostałymi składowymi wynikowymi i oryginalnymi kanałami. W rezultacie cały proces zaczynał być silnie losowy.

Z związku z powyższym postanowiono odwrócić proces parowania. Zamiast dopasowywać kanały do najsilniejszych składowych, zaczęto dopasowywać składowe do kanałów. Dodatkowo, ograniczono liczbę przeszukiwanych kolumn w macierzy demiksującej do dwóch kolumn odpowiadających kanałom o najwyższej istotności dla badania rzeczywistych/wyobrażonych ruchów ręki, kanałom C3 oraz C4. Pozostałe kanały nie powinny zawierać informacji użytecznych w procesie rozpoznawania ruchów rąk, a zatem przyjęto, że również składowe, które nie zostały sparowane z kanałami C3 i C4, można usunąć z dalszej analizy. W tym podejściu nie szukano więc współczynnika o maksymalnej wartości w całej macierzy demiksującej, lecz jedynie w kolumnach odpowiadających dwóm wybranym kanałom. W efekcie otrzymano parę komponentów, jeden odpowiadał kanałowi C3, a drugi kanałowi C4.

Była to bardzo prosta zmiana obliczeniowa, ale zrobiła ogromną różnicę. Wyniki klasyfikacji uzyskane po przeprowadzeniu procesu parowania zgodnie z opisanym powyżej

schematem zostały przedstawione w Tabeli 4.3.1. Aby uzyskać bardziej wiarygodne wyniki, proces klasyfikacji powtórzono 5 razy na każdym z 16 przygotowanych wcześniej zestawów danych. Należy tu wyraźnie podkreślić, że w przypadku każdego z 15 zestawów o minimum trzech kanałach, algorytm FastICA w wersji symetrycznej był stosowany (z osobna w każdej próbie) na wszystkich wymienionych kanałach, lecz proces klasyfikacji prowadzony był zawsze dla dwóch składowych wynikowych sparowanych z kanałami C3 i C4.

- Jak można zaobserwować w Tabeli 4.3.1, zaproponowana metoda parowania sygnałów oryginalnych ze składowymi ICA zapewniła lepszą dokładność klasyfikacji niż bezpośrednia klasyfikacja przeprowadzona na parze sygnałów oryginalnych C3-C4.

Numer kombinacji	Kanały/ zestaw komponentów	Dokładność klasyfikacji [%]						Wzrost dokładności [%]
		Test 1	Test 2	Test 3	Test 4	Test 5	Średnia	
-	S2 (para sygnałów C3 i C4)	65	63	64	65	63	64	-
1	IC3 Cz	77	81	76	77	75	77	21
2	IC3 Pz	73	73	75	72	73	73	14
3	IC3 O2	77	75	75	77	77	76	19
4	IC3 O1	72	76	74	79	79	76	18
5	IC4 Cz Pz	78	77	75	80	77	78	21
6	IC4 Cz O2	78	75	75	76	79	77	20
7	IC4 Pz O2	71	74	72	74	71	72	13
8	IC4 Cz O1	78	80	81	74	82	79	23
9	IC4 Pz O1	70	72	73	69	74	72	12
10	IC4 O1 O2	71	75	76	74	73	74	15
11	IC5 Pz O1 O2	72	69	67	67	74	70	9
12	IC5 Cz O1 O2	79	79	70	77	74	76	18
13	IC5 Cz Pz O1	75	68	75	73	74	73	14
14	IC5 Cz Pz O2	72	76	77	77	75	75	18
15	IC6 Cz Pz O1 O2	80	78	75	77	81	78	22
	Średnia	75	75	75	75	76	75	17

Tabela 4.3.1 Dokładność klasyfikacji uzyskana dla pary kanałów C3-C4 (pierwszy wiersz) oraz 15 zestawów składowych ICA (pozostałe wiersze) w kolejnych rundach testowych; dwie ostatnie kolumny przedstawiają uśrednioną dokładność dla 5 rund testowych i wzrost dokładności po zastosowaniu algorytmu FastICA.

Wynik był stabilny, niezależnie od liczby kanałów i ich lokalizacji. Pozwala to sądzić, że:

- odpowiednie składowe zostały sparowane z kanałami C3 i C4,

dodanie dodatkowych kanałów do zestawu złożonego z kanałów najbardziej odpowiednich do rozpoznawania ruchów ręki, poprawiło jakość sygnału.

Z przeprowadzonego badania wynika, że wybrane składowe ICA odzwierciedlały tę samą aktywność mózgu, co surowe kanały C3 i C4 (każdy z tych kanałów miał najwyższy udział w odpowiadającej mu składowej), ale jednocześnie charakteryzowały się wyższym stosunkiem sygnału do szumu (wyższa dokładność klasyfikacji). Ponadto, analizując wyniki kolejnych kombinacji kanałów, należy stwierdzić, że najwyższą poprawę dokładności klasyfikacji zaobserwowano, gdy wśród kanałów dodanych do kanałów podstawowych (C3 i C4) znajdował się kanał Cz (poza zestawem nr 13). Ze względu na lokalizację kanału Cz (bardzo blisko kanałów C3 i C4) ta obserwacja może oznaczać, że jedna ze składowych ICA przechwyciła artefakty współlistniejące w tych trzech kanałach, w wyniku czego składowe odpowiadające kanałom C3 i C4 były lepszej jakości. Opracowana metoda parowania sygnałów wraz z wynikami została opublikowana w [234].

Podstawowy cel badania, którym było wstępne sprawdzenie czy dodanie dodatkowych kanałów powielających przynajmniej część informacji pozwoli na odzyskanie sygnałów o wyższym współczynniku SNR (współczynnik sygnału do szumu) został więc osiągnięty. Otwartym pozostało jednak pytanie w jaki sposób dostarczyć do algorytmu dodatkowe sygnały wejściowe powielające informację zawartą w sygnałach oryginalnych, ale bez konieczności rejestracji sygnału EEG z dodatkowych kanałów. W odpowiedzi na to pytanie opracowano metodę MAICA, opisaną w kolejnym podrozdziale.

ROZDZIAŁ 5

METODA MAICA

Zaproponowana w niniejszej pracy metoda MAICA (ang. Moving Average ICA) pozwala na wygenerowanie sztucznych sygnałów poprzez wielokrotne poddawanie sygnału zarejestrowanego przez czujniki pomiarowe procesowi filtracji dolnoprzepustowej filtrem zero-fazowym. Parametry oraz liczba kolejnych filtrów są wyznaczane przez algorytm na podstawie zarejestrowanego sygnału lub zestawu sygnałów. Alternatywnie mogą być również podawane przez użytkownika. Dokładny opis działania metody został przedstawiony w niniejszym rozdziale.


5.1 Algorytm MAICA

Algorytm MAICA na wejściu przyjmuje e -elementowy zbiór D , którego kolejnymi elementami są dwuwymiarowe macierze X zawierające sygnały rejestrowane w określonym czasie z czujników pomiarowych. Macierz X może zawierać od 1 do ch sygnałów, przy czym jeden sygnał reprezentuje dane pobrane z jednego czujnika pomiarowego (np. jednego kanału EEG). Każdy z sygnałów pomiarowych stanowi złożenie wielu (nieznanych) sygnałów źródłowych:


$$\begin{aligned} x_1 &= A_{11}s_1 + A_{12}s_2 + \dots + A_{1m}s_m \\ x_2 &= A_{21}s_1 + A_{22}s_2 + \dots + A_{2m}s_m \\ &\dots \\ x_{ch} &= A_{ch1}s_1 + A_{ch2}s_2 + \dots + A_{chm}s_m \end{aligned} \quad , \quad (5.1.1)$$

gdzie: x_i – sygnał zarejestrowany przez i -ty czujnik pomiarowy ($i = 1 \dots ch$), s_g – pojedynczy sygnał źródłowy ($g = 1 \dots m$), A_{ig} – element mieszający.

Zbiór danych stanowi pierwszy, obligatoryjny, element wejściowy algorytmu. Kolejnym elementem podawanym na wejście algorytmu jest wektor v o długości p , zawierający dodatnie liczby całkowite różne od siebie. Wartości umieszczone w wektorze v przedstawiają parametry filtrów wygładzających, za pomocą których, dla danej macierzy X , tworzona jest macierz sygnałów przefiltrowanych Y . Parametr ten jest opcjonalny, co oznacza, że w przypadku, kiedy optymalne wartości wektora v nie są znane, algorytm automatycznie obliczy je na podstawie pierwszej macierzy danych zawartej w zbiorze D .




Rysunek 5.1.1 Schemat blokowy przedstawiający lewą gałąź algorytmu metody MAICA.
Źródło: opracowanie własne.



Rysunek 5.1.2 Schemat blokowy przedstawiający prawą gałąź algorytmu metody MAICA.
Źródło: opracowanie własne.

Po wyznaczeniu wartości wektora v lub pobraniu ich od użytkownika rozpoczyna się właściwy algorytm, polegający na poddawaniu kolejnych sygnałów zarejestrowanych przez czujniki pomiarowe (x_i) wielokrotnemu procesowi filtracji dolnoprzepustowej za pomocą filtra typu FIR (ang. Finite Impulse Response, filtr o skończonej odpowiedzi impulsowej), przy czym parametry kolejnych filtrów są pobierane z wektora v . Filtr wykorzystany w algorytmie jest filtrem zero-fazowym, czyli filtrem bez przesunięcia fazowego. W dalszej części pracy filtr ten będzie oznaczany jako H .

Standardowy filtr dolnoprzepustowy typu FIR jest filtrem z liniową fazą. Filtry takie opóźniają wszystkie składowe sygnału w jednakowym stopniu. Sygnał wyjściowy jest więc opóźnioną wersją sygnału wejściowego (Rysunek 5.1.3a). W filtrze zero-fazowym przesunięcie fazowe jest równe zero ($\alpha = 0$). Zastosowanie takiego filtru powoduje więc, że otrzymany sygnał wyjściowy jest zgodny w fazie z sygnałem wejściowym (Rysunek 5.1.3b).



Rysunek 5.1.3 Zasada działania filtra dolnoprzepustowego typu FIR; a) filtr z przesunięciem fazowym; b) filtr zero-fazowy. Źródło: opracowanie własne.

Filtr z przesunięciem fazowym nie mógł zostać zastosowany w proponowanej metodzie, ponieważ przesunięcie fazowe występujące między sygnałem oryginalnym, a jego kolejnymi filtracjami powodowałoby zbytnią niezależność sygnałów w macierzy G , która stanowi wejście właściwego algorytmu ICA. Kolejne filtracje sygnału (zwłaszcza te o wyższych wartościach współczynnika wygładzenia) nie zawierałyby już tych samych składowych źródłowych, co uniemożliwiłoby prawidłową separację źródeł składających się na sygnały rejestrowane z czujników pomiarowych.

Odpowiedź częstotliwościowa filtra $H(z)$ jest dana jako $H(e^{j\omega})$, a przesunięcie fazowe jako: $\varphi_H(\omega) = \arg(H(e^{j\omega}))$. Oznacza to, że faza składowej częstotliwościowej ω jest przesunięta o kąt $\varphi_H(\omega)$ w czasie, podczas zastosowania filtra na sygnale wejściowym o długości q i n -tej próbie [236, 237]:

$$y(n) = h(0)x(n) + h(1)x(n-1) + \dots + h(n)x(0), \quad (5.1.2)$$

$$n = 0, 1, \dots, q-1$$

Z symetrii wynika, że jeśli filtr jest stosowany na tym samym sygnale wejściowym, ale w odwrotnym kierunku, tj. zgodnie z:

$$y_{rev}(n) = h(0)x(n) + h(1)x(n+1) + \dots + h(q-1-n)x(q-1), \quad (5.1.3)$$

$$n = q-1, q-2, \dots, 0,$$

to faza składowej częstotliwościowej ω jest przesunięta o kąt $-\varphi_H(\omega)$, natomiast amplituda odpowiedzi częstotliwościowej jest taka sama jak w przypadku implementacji z przesunięciem w przód (5.1.3). Wynika z tego, że filtrowanie zero-fazowe można osiągnąć przez dwukrotne uruchomienie filtra $H(z)$: najpierw z przesunięciem w tył na sygnale wejściowym, a następnie, w drugiej iteracji z przesunięciem w przód na sygnale wcześniej przefiltrowanym w tył. W rezultacie otrzymana zostaje dwustopniowa procedura filtracji, którą, dla danego sygnału U o długości q , można opisać następująco:

1. wykonaj filtrowanie z przesunięciem w tył zgodnie z wzorem (5.1.3) w celu uzyskania przefiltrowanego sygnału $y_{rev}(n), n = 0, 1, \dots, q-1$,

2. a następnie wykonaj filtrację w przesunięciem w przód na sygnale $\{y_{rev}(n)\}$

$$y(n) = h(0)y_{rev}(n) + h(1)y_{rev}(n-1) + \dots + h(n)y_{rev}(0), n = 0, 1, \dots, q-1 \quad (5.1.4)$$

Proces filtracji każdego sygnału wchodzącego w skład macierzy X w metodzie MAICA jest wykonywany wielokrotnie, zgodnie z ustalonym wektorem parametrów kolejnych filtrów, wektorem v . Zbiór wszystkich wielokrotnie przefiltrowanych sygnałów źródłowych z macierzy X stanowi macierz Y . Z uwagi na to, że macierz Y ma liczbę kolumn równą liczbie kolumn macierzy X , możliwe jest złączenie tych dwóch macierzy we wspólną macierz G .

Macierz G jest podawana na wejście dowolnie wybranego algorytmu ICA, którego zadaniem jest estymacja zarówno nieznanej macierzy mieszającej A , jak i nieznanego wektora sygnałów źródłowych S , nazywanego wektorem składowych wynikowych. Wyznaczone składowe wynikowe stanowią ostateczny wynik algorytmu. Ocena ich jakości zależy od konkretnego zastosowania. W przypadku sygnału EEG, o wysokiej lub niskiej jakości składowych można wnioskować np. na podstawie dokładności klasyfikacji przeprowadzonej na wartościach cech wyekstrahowanych ze składowych zaklasyfikowanych jako składowe pochodzenia mózgowego. Z kolei, w przypadku analizy sygnałów dźwiękowych lub obrazów, o jakości składowych wynikowych można wnioskować na podstawie analizy empirycznej, badając np. czystość odseparowanych dźwięków. Jeżeli jakość składowych jest zadowalająca, algorytm kończy działanie. Jeżeli wyniki nie są zadowalające, należy wrócić do etapu doboru parametrów filtra wygładzającego.

5.2 Wyznaczenie wektora parametrów filtrów wygładzających

W zastosowaniach rzeczywistych, sytuacje, w których wektor współczynników filtra wygładzającego (wektor v) jest znany z góry praktycznie nie występują. Najczęściej nawet dokładna liczba sygnałów źródłowych wymagana do ustalenia optymalnej liczby zastosowanych filtrów jest niemożliwa do ustalenia. Jest to spowodowane występowaniem różnego rodzaju zakłóceń właściwych sygnałów źródłowych. Stąd, w sytuacjach rzeczywistych, zarówno optymalna liczba filtrów, jak i ich współczynniki, muszą zostać dobrane eksperymentalnie. Dobierając liczbę oraz współczynniki filtrów dla danego zagadnienia rzeczywistego trzeba pamiętać o dwóch istotnych regułach:

- sygnały przefiltrowane muszą być w wysokim stopniu skorelowane z sygnałami pobranymi z czujników pomiarowych; jeżeli warunek ten nie zostanie spełniony, to nie będą one zawierały tych samych komponentów co sygnały oryginalne, a więc stosowanie algorytmów ICA straci sens; z kolei im silniejsza będzie korelacja sygnałów przefiltrowanych, tym więcej będzie można ich stworzyć, a więc potencjalnie tym więcej źródeł będzie można odzyskać.
- z drugiej strony korelacja sygnałów przefiltrowanych i oryginalnych (a także korelacja między sygnałami poddanymi filtracji za pomocą kolejnych filtrów) nie może być

maksymalna, ponieważ uniemożliwi to matematyczne wyznaczenie macierzy odwrotnej A^{-1} do macierzy miksującej A w zastosowanym algorytmie ICA.

Biorąc pod uwagę powyższe reguły zaproponowano algorytm postępowania pozwalający na automatyzację procesu doboru liczby i współczynników filtrów wygładzających. Z uwagi na to, że parametry kolejnych filtrów powinny być dobierane w taki sposób, aby przefiltrowane sygnały były skorelowane w określonym stopniu z macierzą oryginalnych sygnałów X w algorytmie, decyzja o dodaniu kolejnych filtrów jest podejmowana na podstawie stopnia korelacji sygnałów. Jako miarę korelacji wykorzystano wartość bezwzględną współczynnika korelacji, danego wzorem 4.1.3.

Parametry kolejnych filtrów, stanowiące elementy wektora v , dobierane są w taki sposób, żeby każdy sygnał po filtracji filtrem o parametrze j był skorelowany z sygnałem przefiltrowanym filtrem o parametrze $j-1$ co najwyżej w stopniu $P1$ oraz żeby był skorelowany z sygnałem oryginalnym co najmniej w stopniu $P2$. Wartości $P1, P2$ stanowią parametry metody. Ich zalecane wartości, pozwalające na uzyskanie dobrej separacji źródeł w przypadku wielu zbiorów sygnałów EEG, są równe $P1 = 0.97$ i $P2 = 0.4$. Wartości te nie są bardzo restrykcyjne. Jak zostanie pokazane w kolejnym rozdziale, metoda MAICA działa równie dobrze wówczas, gdy zarówno korelacja wyznaczona między poszczególnymi sygnałami przefiltrowanymi oraz sygnałami oryginalnymi, jak i korelacja wyznaczona dla par sygnałów otrzymanych po filtracji znacząco odbiega od podanych powyżej wartości domyślnych.

Algorytm doboru parametrów filtrów wygładzających ma dwa oddzielne warunki zatrzymania. Pierwszy odpowiada pierwszej wspomnianej powyżej zasadzie „podobieństwa” - podobieństwo między każdym nowym wektorem wejściowym, utworzonym w procesie filtrowania, a odpowiadającym mu oryginalnym sygnałem z wektora x powinno być tak wysokie, jak to możliwe. Drugi warunek weryfikuje korelację wzajemną składowych wyjściowych zwracanych przez ICA. Zgodnie z tym warunkiem procedura doboru parametrów wektora v kończy się, gdy którekolwiek dwie składowe ICA są silnie skorelowane między sobą. Wysoka wzajemna korelacja składowych wynikowych zwykle oznacza, że zastosowany algorytm ICA nie jest w stanie odzyskać więcej niezależnych składowych i zamiast tego zaczyna odzyskiwać

kombinacje składowych oszacowanych wcześniej. Innymi słowy, wysoka korelacja dwóch składowych wyjściowych wskazuje, że liczba filtrów jest zbyt wysoka i procedura generowania nowych sygnałów wejściowych powinna zostać zatrzymana. Poziom korelacji, którego przekroczenie powoduje zakończenie algorytmu, jest trzecim parametrem metody, parametrem $P3$. Dla zbiorów EEG jego zalecana wartości to $P3 = 0.6$.

Wartości wektora v obliczane są na podstawie dowolnego sygnału pochodzącego z jednej próby z badanego zbioru prób (zbiór D). Takie uproszczenie algorytmu jest możliwe, ponieważ pomimo tego, że przebieg sygnałów może znacząco różnić się w kolejnych próbach (oraz w kolejnych kanałach), charakterystyki sygnałów mające kluczowe znaczenie podczas ustalania wektora współczynników filtrów wygładzających, takie jak: długość sygnału oraz zakres jego zmienności są z reguły bardzo podobne w przekroju prób. Oczywiście w rzeczywistości mogą wystąpić sytuacje, kiedy zmienność sygnałów w kolejnych próbach będzie znacząco różna. W takim przypadku zastosowanie powyższego uproszczenia nie będzie możliwe, lecz konieczne będzie ustalenie wektora wygładzeń z osobna dla każdej próby, co zwiększy czasochłonność algorytmu. W przypadku analizy sygnału EEG najczęściej wystarczające jest ustalenie wektora współczynników filtrów na podstawie pierwszej próby, a następnie zastosowanie go, zgodnie z opisanym algorytmem, we wszystkich e próbach.

Algorytm doboru optymalnej długości wektora v oraz jego wartości można zapisać jako zestaw działań przedstawionych w postaci pseudokodu na Rysunku 5.1.2 oraz opisanych poniżej:

- a) Pobierz pierwszą próbę ze zbioru D ; $X=D\{1\}$.
- b) Zainicjalizuj współczynnik filtra wygładzającego $c=1$; utwórz pusty wektor v do przechowywania finalnych współczynników filtra wygładzającego oraz pusty wektor t (przechowujący ostatni przefiltrowany sygnał); ustal współczynniki korelacji: $P1$ (maksymalna korelacja między sygnałami utworzonymi poprzez zastosowanie filtrów o kolejnych współczynnikach z wektora v), $P2$ (minimalna korelacja sygnałów po filtracji z sygnałem oryginalnym) i $P3$ (maksymalna korelacja dwóch dowolnych składowych wyjściowych); przypisz pierwszy wiersz z macierzy X do zmiennej r ($r = x_1$) oraz zainicjalizuj macierz G macierzą X , $G=X$.

- c) Zastosuj filtrację z użyciem filtra H o parametrze c na sygnale r . Przetworzony sygnał zapisz jako w .
- d) Sprawdź korelację sygnału w oraz sygnału r . Jeżeli korelacja jest mniejsza lub równa $P1$ oraz większa lub równa $P2$ idź do punktu e). Jeżeli korelacja jest większa od $P1$ zwiększ c o 1 oraz wróć do punktu c). Jeżeli korelacja jest mniejsza od $P2$ idź do punktu h).
- e) Sprawdź korelację między sygnałem w a sygnałem t . Jeżeli korelacja jest mniejsza lub równa $P1$, przypisz $t=w$ oraz $i=1$ i idź do punktu f). W przeciwnym wypadku zwiększ c o 1 oraz wróć do punktu c).
- f) Dodaj współczynnik c do wektora v . Przeprowadź filtrację za pomocą filtra c na i -tym sygnale z macierzy X . Przetworzony sygnał dodaj do macierzy G . Macierz G podaj na wejście algorytmu ICA. Oblicz składowe wynikowe (liczba składowych wynikowych jest równa $ch + \text{długość } r * ch$), wynik zapisz jako macierz S .
- g) Sprawdź korelację pomiędzy wszystkimi parami składowych wynikowych znajdujących się w macierzy S . Jeżeli dwie różne składowe są do siebie podobne w stopniu większym niż $P3$, usuń współczynnik c z wektora v i idź do punktu h). W przeciwnym wypadku sprawdź czy i jest mniejsze od liczby wierszy w macierzy X . Jeżeli tak, zwiększ i o 1 i idź do f) jeżeli nie zwiększ c o 1 i idź do punktu d).
- h) Zwróć wektor v i zakończ działanie algorytmu.

W zaprezentowanym algorytmie odstęp między kolejnymi sprawdzanymi współczynnikami filtra wygładzającego wynosi 1. W celu przyspieszenia algorytmu, zwłaszcza w przypadku długich sygnałów (zawierających miliony i więcej próbek) możliwe jest oczywiście zdefiniowanie innej wartości kroku między kolejnymi współczynnikami filtra. Wartość kroku może być również traktowana jako dodatkowy parametr k ustalany na starcie algorytmu. Wartość tego parametru powinna być niższa dla krótkich sygnałów o dużej zmienności (filtrowanie sygnałów o dużej zmienności znacząco wpływa na ich przebieg), a wyższa dla wolnozmiennych długich sygnałów.

```

P1=0.97; P2 =0.4; P3=0.6;
v=[]; t = [];G=[]; r=X(1)

dla c=1 do długość(x1)
    w= użyj filtra h o średnim rozmiarze okna c na x1
    jeżeli wbz(ρ(r, w))>P1
        kontynuuj
    koniec
    jeżeli wbz (ρ (w, t))> P2
        kontynuuj;
    w przeciwnym wypadku
        zwróć v;
    koniec
    t = w;
    dla i=1 do ch
        G = [G użyj filtra h of długość c na x(i)];
        S = wykonaj ICA na macierzy G
        jeżeli wbz(ρ (którekolwiek z dwóch S)) > P3
            usuń ostatni wiersz macierzy G
            zwróć v;
        w przeciwnym wypadku
            v=[v c];
        koniec
    koniec
koniec

```

Rysunek 5.2.1 Algorytm doboru parametrów procesu filtrowania; algorytm zwraca wektor L (wektor rozmiarów okien kolejnych filtrów).

Z przeprowadzonych eksperymentów praktycznych wynika, że dobrym kompromisem między efektywnością algorytmu, a jego dokładnością jest ustawienie wartości parametru k w taki

sposób, aby współczynnik korelacji wyznaczony dla pierwszej porównywanej pary sygnałów mieścił się w przedziale $\langle P1-3\%, P1 \rangle$. We wszystkich prowadzonych dotąd eksperymentach z rzeczywistymi sygnałami EEG współczynnik k był ustawiony na wartość 2, dając bardzo dobre rezultaty. Przy eksperymentach ze sztucznie generowanymi sygnałami sinusoidalnymi, wartość współczynnika k ustawiono na 10, ze względu na dużą niższą zmienność tych sygnałów.

ROZDZIAŁ 6

WERYFIKACJA DZIAŁANIA METODY MAICA

W niniejszym rozdziale przedstawione zostaną eksperymenty praktyczne ilustrujące odporność i ograniczenia metody MAICA oraz jej działanie dla różnych wartości parametrów. We wszystkich eksperymentach proces filtracji został przeprowadzony z wykorzystaniem wbudowanej funkcji środowiska Matlab – funkcji *filtfilt()*, która stanowi programową implementację filtru zero fazowego. Funkcja ta wykonuje cyfrowe filtrowanie sygnału za pomocą przetworzenia go w obu kierunkach. W pierwszej kolejności filtrowanie zachodzi w przód, następnie kierunek filtrowania jest odwracany i sygnał ponownie przechodzi przez filtr – zgodnie z algorytmem zaprezentowanym w podrozdziale 5.2. Do wyznaczenia wskaźnik podobieństwa pomiędzy dwoma sygnałami wykorzystano inną wbudowaną funkcję pakietu Matlab – funkcję *xcorr* [227]. Przy implementacji algorytmu MAICA wykorzystano własną implementację algorytmu FastICA w wersji symetrycznej.

Aby w pełni przedstawić potencjał metody MAICA, zastosowano ją w 3 systemach o odmiennych cechach:

- System 1 - sztuczny system złożony z 10 sygnałów sinusoidalnych (dane z jednej próby);
- System 2 - sygnał EEG zarejestrowany z 64 kanałów (pojedynczy ciągły sygnał z jednej 2-minutowej sesji, składającej się z kilku prób);
- System 3 - sygnał EEG zarejestrowany z 2 kanałów od 5 uczestników (dane z wielu prób).

6.1 System 1 – sygnały sinusoidalne

Aby wstępnie zweryfikować metodę MAICA, stworzono sztuczną macierz złożoną z 10 przebiegów sinusoidalnych $y_1 \dots y_{10}$ o tej samej długości (1000 próbek), ale o różnej częstotliwości podstawowej (Tabela 6.1.1).

$y_1 = \sin(320\pi)$	$y_2 = \sin(200\pi)$	$y_3 = \sin(9\pi)$	$y_4 = \sin(100\pi)$	$y_5 = \sin(400\pi)$
$y_6 = \sin(2\pi)$	$y_7 = \sin(120\pi)$	$y_8 = \sin(300\pi)$	$y_9 = \sin(250\pi)$	$y_{10} = \sin(60\pi)$

Tabela 6.1.1 Źródłowe sygnały sinusoidalne

Sinusoidy z Tabeli 6.1.1 zmieszano razem, tworząc dwie liniowe kombinacje sygnałów oryginalnych. Pierwsza kombinacja zawierała 100% pierwszych 5 sinusoid i 10% ostatnich 5 sinusoid, druga kombinacja zawierała 10% pierwszych 5 sinusoid i 100% ostatnich 5 sinusoid:


$$\begin{aligned} M1 &= 100\%(y_1 + y_2 + y_3 + y_4 + y_5) + 10\%(y_6 + y_7 + y_8 + y_9 + y_{10}) \\ M2 &= 10\%(y_1 + y_2 + y_3 + y_4 + y_5) + 100\%(y_6 + y_7 + y_8 + y_9 + y_{10}) \end{aligned} \quad (6.1.1)$$

Następnie mieszaniny $M1$ i $M2$ poddano trzykrotnie działaniu algorytmu MAICA, dla trzech różnych wartości parametrów $P1$, $P2$ i $P3$. W pierwszym eksperymencie parametry ustawiono na domyślne wartości zaproponowane przez autorów ($P1=0.97$, $P2=0.4$ i $P3=0.6$). W drugim eksperymencie zmniejszono wartość parametru $P2$ oraz zwiększono wartość parametru $P3$, aby zasymulować sytuację, w której zostanie odzyskanych mniej składowych wynikowych niż liczba rzeczywistych sygnałów źródłowych ($P2=0.2$, $P3=0.99$). Wreszcie, w ostatnim eksperymencie zwiększono wartość parametru $P2$ oraz zmniejszono wartość parametru $P3$, aby pokazać wyniki działania algorytmu w sytuacji, kiedy zostanie uzyskana większa liczba składowych wynikowych niż rzeczywista liczba sygnałów źródłowych ($P2=0.7$, $P3=0.2$).


Rysunek 6.1.1 przedstawia oryginalny zestaw 10 sinusoid wykorzystanych do weryfikacji algorytmu MAICA. Po połączeniu sinusoid w proporcjach określonych w (6.1.1) uzyskano dwie liniowe kombinacje sygnałów (pokazane na Rysunku 6.1.2). Zadaniem algorytmu MAICA było przyjęcie tych dwóch kombinacji jako danych wejściowych i zwrócenie komponentów wyjściowych, które zostały następnie porównane z rzeczywistymi sygnałami źródłowymi, czyli oryginalnymi sinusoidami.

Najpierw uruchomiono algorytm MAICA z domyślnym zestawem parametrów ($P2=0.6$, $P1=0.97$ i $P3=0.4$). Składowe zwrócone przez MAICA przedstawiono na Rysunku 6.1.3. Jak można zauważyć na rysunku, algorytm nie tylko odzyskał prawidłową liczbę sygnałów źródłowych, ale także zwrócił składowe, które były bardzo podobne do źródłowych sinusoid z Rysunku 6.1.1. Aby zbadać siłę podobieństwa, wyznaczono współczynnik korelacji między


wszystkimi możliwymi parami: składowa MAICA – oryginalna sinusoida. Następnie każdą składową sparowano z tym sygnałem źródłowym, w przypadku, którego uzyskano najwyższą korelację. Tabela 6.1.2 przedstawia pary składowa ICA - sinusoida źródłowa wraz z wartościami współczynnika korelacji. Jak można zauważyć, korelacja między sygnałami źródłowymi i składowymi ICA, uzyskanymi po zastosowaniu algorytmu MAICA jest bardzo wysoka (0.99-1).



Rysunek 6.1.1 Oryginalne sygnały sinusoidalne. Źródło: opracowanie własne.



Rysunek 6.1.2 Liniowa kombinacja źródeł sinusoidalnych przedstawionych na Rysunku 6.1.1 w proporcjach przedstawionych we Wzorze: 6.1.1. Źródło: opracowanie własne.



Rysunek 6.1.3 Zestaw składowych zwróconych przez algorytm MAICA (ICA1, ICA2, ..., ICA10) uruchomiony z domyślnymi parametrami: $P2=0.6$, $P1=0.97$, i $P3=0.4$. Źródło: opracowanie własne.

Sygnal źródłowy	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9	y_{10}
Składowa wynikowa	ICA5	ICA9	ICA2	ICA8	ICA10	ICA1	ICA6	ICA7	ICA4	ICA3
Korelacja	0.99	0.99	0.99	0.99	1	1	1	1	1	0.99


Tabela 6.1.2 Korelacja pomiędzy składowymi zwróconymi przez algorytm MAICA oraz sinusoidami źródłowymi (w tabeli przedstawiono tylko pary sygnałów o najwyższej korelacji).

Domyślne parametry metody MAICA posiadają dość duży margines błędu. Nawet jeśli zostaną znacznie zmienione, algorytm nadal będzie działał poprawnie. Oczywiście parametrów nie można wybierać całkowicie arbitralnie - należy zachować zasady przedstawione w podrozdziale 5.2. Gdy reguły zostaną zbyt mocno naruszone, algorytm zwróci większą lub mniejszą liczbę składowych niż liczba prawdziwych źródeł. Rysunki 6.1.4 i 6.1.5 przedstawiają zestawy składowych wynikowych zwrócone przez algorytm FastICA po ustawieniu parametrów algorytmu MAICA na zbyt wysokich/niskich poziomach.

W pierwszym przypadku (Rysunek 6.1.4) parametry ustawiono na: $P2=0.7$, $P1=0.97$ i $P3=0.2$. Ponieważ złagodzono warunki zatrzymania algorytmu, zwrócił on więcej komponentów niż oryginalnych źródeł. Jednak jak można zauważyć w Tabeli 6.1.3, przedstawiającej korelację między parami składowa ICA – sinusoida źródłowa, nawet przy tak wysokim naruszeniu domyślnych parametrów algorytmu, większość sygnałów źródłowych została odzyskana z bardzo dużą dokładnością.

Sygnał źródłowy	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9	y_{10}
Składowa wynikowa	ICA11	ICA13	ICA9	ICA6	ICA1	ICA3	ICA7	ICA8	ICA12	ICA5
Korelacja	0.99	0.6	0.98	0.99	0.85	0.99	0.99	0.64	0.85	0.99


Tabela 6.1.3 Korelacja pomiędzy składowymi zwróconymi przez algorytm MAICA oraz sinusoidami źródłowymi (parametry algorytmu: $P2=0.7$, $P1=0.97$ i $P3=0.2$).



Rysunek 6.1.4 Zestaw składowych zwróconych przez algorytm MAICA (ICA1, ICA2, ..., ICA14) uruchomiony z parametrami: $P2=0.7$, $P1=0.97$, i $P3=0.2$. Źródło: opracowanie własne.

Drugi przypadek (Rysunek 6.1.5, Tabela 6.1.4), z bardziej restrykcyjnymi warunkami zatrzymania algorytmu ($P2=0.2$, $P1=0.97$ i $P3=0.99$) był znacznie trudniejszy do rozwiązania dla algorytmu MAICA. Algorytm nie miał bowiem wystarczającej liczby komponentów do

zaprezentowania wszystkich oryginalnych źródeł, zwrócił tylko dwa komponenty wysoce skorelowane z sygnałami źródłowymi (ICA3 – y_5 i IC5 – y_8) oraz 4 składowe, które były mieszaninami innych źródeł (ICA1, ICA2, ICA4, i ICA6).



Rysunek 6.1.5 Zestaw składowych zwróconych przez algorytm MAICA (ICA1, ICA2,..., ICA6) uruchomiony z parametrami: $P2 = 0.2$, $PI = 0.97$ i $P3 = 0.99$. Źródło: opracowanie własne.

Sygnał źródłowy	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9	y_{10}
Składowa wynikowa	-	ICA4	ICA2	-	ICA3	ICA1	-	ICA5	ICA6	-
Korelacja	-	0.75	0.8	-	0.93	0.72	-	0.95	0.8	-

Tabela 6.1.4 Korelacja pomiędzy składowymi zwróconymi przez algorytm MAICA oraz sinusoidami źródłowymi (parametry algorytmu: $P2 = 0.2$, $PI = 0.97$ i $P3 = 0.99$).


W kolejnym etapie badań kombinacje $M1$ i $M2$ wprowadzono na wejścia czterech referencyjnych algorytmów DE, SCICA, EEMD-ICA oraz WICA, opisanych w podrozdziale 3.4.

Pierwsza z wykorzystanych metod, metoda DE, przyjmuje dwa parametry, liczbę opóźnień każdego z sygnałów wejściowych (parametr d) oraz długość opóźnienia mierzona liczbą próbek (parametr s). Zastosowanie tej metody wymagało zbudowania macierzy wejściowej złożonej z zestawu mieszanin $M1$ i $M2$ opóźnionych w czasie. Początkowo, w celu odzyskania dokładnie

takiej samej liczby składowych, jak liczba sygnałów źródłowych, liczbę generowanych opóźnień sygnałów $M1$ i $M2$ ustawiono na 4. W ten sposób macierz wejściowa, na której zastosowano algorytm FastICA składała się z 10 sygnałów (sygnały $M1$ i $M2$ oraz cztery opóźnienia sygnału $M1$ i cztery opóźnienia sygnału $M2$). Niestety, pomimo wypróbowania 26 różnych ustawień parametru s ($s = 2: 2: 50$), nie uzyskano pełnej separacji. Najlepszy wynik, uzyskany dla $s = 30$, przedstawiono na Rysunku 6.1.6 oraz w Tabeli 6.1.5. Jak można zauważyć w Tabeli 6.1.5 odzyskano tylko trzy sygnały źródłowe z korelacją równą ponad 90%. Ponadto dwie składowe źródłowe zostały sparowane z dwoma, zamiast z jednym sygnałem źródłowym (ICA5 z y_2 i y_5 oraz ICA9 z y_7 i y_9). W związku z tym próbowano zwiększyć liczbę składowych wynikowych, zmieniając wartość parametru d ($d = 2: 2: 50$), dla zadanej wartości s ($s = 2$). Tym razem udało się odzyskać pięć składowych skorelowanych z sygnałami źródłowymi w stopniu wyższym niż 90% (Rysunek 6.1.7, Tabela 6.1.6), ale przy znacznie większej liczbie opóźnień ($d = 42$). Przy tych parametrach algorytm ICA musiał zostać wykonany na 86 (zamiast 10) sygnałach wejściowych, co znacznie wydłużyło czas obliczeń.

Sygnał źródłowy	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9	y_{10}
Składowa wynikowa	ICA8	ICA5	ICA7	ICA1	ICA5	ICA10	ICA9	ICA4	ICA9	ICA6
Korelacja	0.65	0.63	0.97	0.99	0.62	0.78	0.48	0.9	0.72	0.78


Tabela 6.1.5 Korelacja pomiędzy składowymi zwróconymi przez metodę DE dla parametrów: $s=30$, $d=4$ (10 sygnałów na wejściu do algorytmu FastICA).



Rysunek 6.1.6 Zestaw składowych zwróconych przez metodę DE, $s = 30$, $d = 4$ (10 sygnałów na wejściu algorytmu FastICA). Źródło: opracowanie własne.

Sygnał źródłowy	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9	y_{10}
Składowa wynikowa	ICA9	ICA33	ICA66	ICA62	ICA43	ICA65	ICA24	ICA17	ICA69	ICA56
Korelacja	0.99	0.81	0.99	0.96	0.96	0.98	0.75	0.8	0.89	0.88

Tabela 6.1.6 Korelacja pomiędzy składowymi zwróconymi przez metodę DE dla parametrów: $s=2$, $d=46$ (86 sygnałów na wejściu do algorytmu FastICA).



Rysunek 6.1.7 Zestaw komponentów zwróconych przez metodę DE: $s=2$, $d=46$ (86 sygnałów na wejściu do algorytmu FastICA). Źródło: opracowanie własne.

Kolejnym badanym algorytmem był algorytm SCICA. Algorytm ten przyjmuje tylko jeden parametr, którym jest liczba bloków na jaką zostaje podzielony każdy z oryginalnie zarejestrowanych sygnałów (tu: sygnały $M1$ i $M2$). W efekcie podziału sygnału na bloki powstaje sekwencja rozłącznych bloków o takiej samej długości. W przypadku, kiedy ostatni blok zawiera


mniejszą liczbę próbek niż bloki pozostałe, jest on usuwany z macierzy. Macierz utworzona z sygnałów z poszczególnych bloków jest następnie poddawana transformacji ICA.

Algorytm zbadano dla różnej liczby bloków, od 5 do 20. Najlepsze wyniki uzyskano dla 5 bloków. Zwiększanie liczby bloków powodowało, że składowe wynikowe były mniej podobne do oryginalnych sygnałów sinusowych. Było to prawdopodobnie spowodowane tym, że każdy kolejny blok skracał sygnał, co powodowało, że informacja o niskich częstotliwościach występujących w sygnale była bezpowrotnie tracona. Najlepszy wynik, uzyskany dla 10 sygnałów w macierzy wejściowej ICA (2 mieszanki sinusoidalne rozłożone na 5 bloków każda), przedstawiony został na Rysunku 6.1.8 oraz w Tabeli 6.1.7. Z Tabeli 6.1.7 wynika, że tylko jeden sygnał sinusoidalny został odzyskany z podobieństwem większym niż 90% - y_3 .


Sygnał źródłowy	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9	y_{10}
Składowa wynikowa	ICA3	ICA6	ICA3	ICA8	ICA4	ICA4	ICA5	ICA6	ICA10	ICA8
Korelacja	0.23	0.37	0.93	0.61	0.70	0.17	0.60	0.49	0.48	0.34

Tabela 6.1.7 Korelacja pomiędzy składowymi zwróconymi przez metodę SCICA dla liczby bloków równej 5 (10 sygnałów na wejściu do algorytmu FastICA).

Kolejnym algorytmem poddanym badaniu był algorytm EEMD-ICA. Algorytm uruchomiono wielokrotnie dla różnej liczby funkcji IMF (od 4 do 20) oraz różnego poziomu szumu (od 20% do 40%) dodawanego do sygnału wejściowego przed rozłożeniem go na funkcje IMF. Najlepsze wyniki uzyskano dla czterech funkcji IMF i przy 20%-wym zaszumieniu sygnałów wejściowych $M1$ i $M2$. Składowe wynikowe zwrócone po zastosowaniu algorytmu FastICA na macierzy złożonej z sygnałów $M1$ i $M2$ oraz 8 funkcji IMF (po 4 funkcje dla każdego sygnału) przedstawione są na Rysunku 6.1.9. Po przeprowadzeniu procesu parowania składowych wynikowych z oryginalnymi sinusoidami okazało się, że 3 składowe wynikowe były podobne do oryginalnych sygnałów w stopniu większym niż 90% oraz dodatkowo dwie w stopniu większym niż 80% (Tabela 6.1.8).



Rysunek 6.1.8 Zestaw składowych zwróconych przez metodę SCICA dla liczby bloków równej 5 (10 sygnałów na wejściu algorytmu FastICA). Źródło: opracowanie własne.



Rysunek 6.1.9 Zestaw składowych zwróconych przez metodę EEMD-ICA dla 4 funkcji IMF oraz 20%-wego poziomu szumu (10 sygnałów na wejściu algorytmu FastICA). Źródło: opracowanie własne.

Sygnał źródłowy	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9	y_{10}
Składowa wynikowa	ICA10	ICA2	ICA5	ICA7	ICA9	ICA10	ICA3	ICA6	ICA10	ICA4
Korelacja	0.18	0.70	0.57	0.93	0.67	0.11	0.98	0.99	0.85	0.90


Tabela 6.1.8 Korelacja pomiędzy składowymi zwróconymi przez metodę EEMD-ICA dla 4 funkcji IMF oraz 20%-wego poziomu szumu (10 sygnałów na wejściu do algorytmu FastICA).

Ostatnim z badanych algorytmów referencyjnych był algorytm WICA. W algorytmie tym dodatkowe sygnały wejściowe generowane są w efekcie przeprowadzenia na każdym z zarejestrowanych sygnałów dyskretnej transformaty falkowej - DWT (ang. Discrete Wavelet Transform). Ponownie działanie algorytmu przetestowano dla wielu różnych ustawień parametrów algorytmu. W badaniu testowano zarówno różne rodziny falek (Daubechies, Coiflets, Symlets, and Biorthogonal), jak i różną liczbę poziomów dekompozycji (od 3 do 10). Najlepsze wyniki uzyskano dla 4 poziomej dekompozycji z wykorzystaniem falki Symlet17. Zastosowanie 4 poziomej dekompozycji falkowej oznaczało, że macierz wejściowa algorytmu ICA składała się z 10 sygnałów ($M1$ i $M2$ oraz 8 sygnałów uzyskanych w efekcie przeprowadzenia transformaty falkowej na obu sygnałach). Szczegółowe wyniki zostały przedstawione na Rysunku 6.1.10 oraz w Tabeli 6.1.9. Jak można zauważyć w Tabeli 6.1.9, cztery sygnały oryginalne zostały odzyskane z ponad 90% dokładnością, a trzy kolejne – z dokładnością 70% i więcej. Składowych y_{10} oraz y_1 nie udało się jednak odzyskać niemal w ogóle.

Sygnał źródłowy	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9	y_{10}
Składowa wynikowa	ICA5	ICA7	ICA2	ICA6	ICA4	ICA8	ICA9	ICA1	ICA3	ICA5
Korelacja	0.06	0.69	0.96	0.76	0.98	0.95	0.75	0.70	0.99	0.18

Tabela 6.1.9 Korelacja pomiędzy składowymi zwróconymi przez metodę WICA przy 4 stopniowej dekompozycji (10 sygnałów na wejściu do algorytmu FastICA).

Ostatnia tabela w tym podrozdziale (Tabela 6.1.10) przedstawia podsumowanie wyników uzyskanych dla wszystkich pięciu przetestowanych metod. Kolejne kolumny tabeli zawierają nazwę metody, zestaw parametrów zapewniających najlepsze wyniki separacji, liczbę źródeł odzyskanych z korelacją równą lub wyższą niż 90% oraz czas obliczeń potrzebny do wykonania algorytmu. Wszystkie obliczenia przeprowadzono na komputerze o następujących parametrach: procesor Intel CORE i7-6700HQ 2,60 GHz, 16 GB pamięci RAM, Windows 10, x64.



Rysunek 6.1.10 Zestaw składowych zwróconych przez metodę WICA dla 4 poziomej dekompozycji (10 sygnałów na wejściu algorytmu FastICA). Źródło: opracowanie własne.

Metoda	Parametry	Korelacja $\geq 90\%$	Czas działania [s]
MAICA	P2 = 0.6, P1= 0.97, P3= 0.4	10	0.3987
DE	s=2, d=46	5	14.2895
SCICA	Liczba bloków=5	1	0.6738
EMD-ICA	Liczba funkcji IMF=4, szum=20%	4	0.3873
WICA	Simlet17, 4-poziomy dekompozycji	4	0.6443


Tabela 6.1.10 Podsumowanie wyników uzyskanych za pomocą wszystkich 5 metod.

6.2 System 2 – pojedynczy ciągle sygnał EEG

W drugim etapie badania wykorzystano plik *s001r03.edf*, pochodzący z referencyjnej bazy danych EEG Motor Movement/Imagery Dataset [238] zlokalizowanej w zasobach PhysioBank [239]. Plik ten zawierał sygnały EEG zarejestrowane podczas jednej ciągłej 2-minutowej sesji, w trakcie której uczestnik eksperymentu wykonywał zadania motoryczne, zgodnie ze wskazówkami wyświetlanymi na ekranie. Zadania polegały na otwieraniu i zamykaniu wskazanej pięści tak długo jak wskazówka pozostawała wyświetlona na ekranie. Dane EEG zostały zarejestrowane z 64 elektrod umieszczonych zgodnie z Międzynarodowym Systemem 10-20. Częstotliwość próbkowania wynosiła 160 Hz. Podstawową różnicę między systemem opisywanym w niniejszym podrozdziale, a systemem opisanym w punkcie 6.1 stanowiła całkowita nieznajomość rzeczywistych sygnałów źródłowych. Z tego powodu weryfikacja poprawności działania algorytmu MAICA nie mogła odbyć się tak, jak w poprzednim badaniu poprzez porównanie składowych wynikowych z sygnałami oryginalnymi.

Celem przeprowadzonego badania było sprawdzenie czy algorytm MAICA zastosowany do danych zarejestrowanych w konfiguracji nisko-kanalowej zwróci te same artefakty, co klasyczna implementacja algorytmu ICA zastosowana do danych zarejestrowanych w konfiguracji wielokanalowej. Badanie rozpoczęto od wykonania klasycznej wersji algorytmu FastICA w wersji symetrycznej na całym 64-kanalowym zbiorze danych. Następnie wizualnie sprowadzono zestaw 64 składowych wyjściowych zwróconych przez algorytm FastICA i zidentyfikowano najbardziej oczywiste składowe-artefakty. Składowe te zostały później wykorzystane jako wektory wzorcowe dla składowych zwróconych przez algorytm MAICA. W następnym kroku uruchomiony został algorytm MAICA na podzbiorze danych złożonym z sygnałów zarejestrowanych jedynie z pięciu kanałów (Fz, Cz, Oz, T7, T8). Fragment zapisu EEG zarejestrowany z wybranych kanałów (Fz,

Cz, Oz, T7, T8) przedstawiono na Rysunku 6.2.1. W celu lepszej wizualizacji na wykresie przedstawiono jedynie 15-sekundowy wycinek badanych sygnałów (od 10 do 25 sekundy).




Rysunek 6.2.1 Fragment sygnału EEG zarejestrowanego w pięciu wybranych kanałach (Oz, Cz, Fpz, T8, T7).
Źródło: opracowanie własne.

Wartości dwóch z trzech parametrów algorytmu pozostawiono na poziomie domyślnym ($P2=0.6$, a $P3=0.4$). Parametr ostatni, $P1$, został nieznacznie zmieniony (z 0.97 na 0.98), ponieważ sygnały EEG charakteryzowały się znacznie większą zmiennością czasową oraz były znacznie dłuższe (19200 próbek) niż sinusoidy. Algorytm zwrócił wektor v zawierający parametry dla 11 filtrów wygładzających, $v = [3, 7, 15, 28, 49, 79, 118, 171, 229, 289, 355]$. Filtry o parametrach z wektora v zastosowano następnie na każdym z pięciu wybranych kanałów, otrzymując 60-kanalową macierz wejściową (5 oryginalnych sygnałów EEG i ich 55 przefiltrowanych wersji). Macierz ta została wprowadzona do algorytmu FactICA, który zwrócił 60 niezależnych składowych wyjściowych.

Aby wstępnie potwierdzić poprawność składowych uzyskanych po zastosowaniu algorytmu MAICA, składowe wyjściowe zostały sparowane z oryginalnymi sygnałami EEG. Proces parowania przeprowadzono w dwóch etapach. W pierwszym etapie obliczono korelację między każdą składową wyjściową a każdym kanałem oryginalnym za pomocą współczynnika korelacji wzajemnej. W wyniku uzyskano macierz korelacji. W drugim etapie każdą składową

wyjściową przypisano do tego kanału, dla którego uzyskano maksymalną wartość współczynnika korelacji. Rysunek 6.2.2 przedstawia sześć wybranych par (4 pary o wysokiej oraz 2 pary o niskiej korelacji).




Rysunek 6.2.2 Składowe wyjściowe zwrócone przez algorytm FastICA (po zastosowaniu algorytmu MAICA) w połączeniu z oryginalnymi sygnałami; przedstawiono sześć wybranych par (4 o wysokiej i 2 o niskiej korelacji). Źródło: opracowanie własne.

Należy tu podkreślić, że wysoką korelację można zaobserwować nie tylko dla składowych sparowanych z kanałami, które zostały umieszczone w macierzy wejściowej algorytmu MAICA (Fpz, T8), ale także dla składowych odpowiadających kanałom, które nie zostały bezpośrednio podane na wejście algorytmu (Iz, Af8).

Parowanie między składowymi wynikowymi uzyskanymi po zastosowaniu algorytmu MAICA i oryginalnymi sygnałami było pierwszym z dwóch, które przeprowadzono w celu weryfikacji poprawności składowych wygenerowanych przez algorytm MAICA. Drugie parowanie przeprowadzono między składowymi wyjściowymi zwróconymi przez FastICA dla zestawu 64 oryginalnych sygnałów i 60 składowych uzyskanych po zastosowaniu MAICA. Niektóre, losowo, wybrane pary przedstawiono na Rysunku 6.2.3. Jak można zauważyć, pomimo tego, że korelacja między parami składowymi zwróconych przez oba algorytmy jest mniejsza niż na Rysunku 6.2.2, przebiegi obu składowych z poszczególnych par mają bardzo podobny kształt.


Dwa kolejne Rysunki 6.2.4 i 6.2.5 przedstawiają pięć najbardziej charakterystycznych składowych wynikowych zwróconych przez algorytm FastICA dla zestawu 64 oryginalnych kanałów (Rysunek 6.2.4) oraz pięć najbardziej charakterystycznych składowych dla zestawu 60 sygnałów utworzonych za pomocą algorytmu MAICA (Rysunek 6.2.5). Jak można zauważyć, oba zestawy zawierają składowe, które można przypisać niektórym dobrze znanym artefaktom. Na przykład:

- 1) składowe ICA51_fastica i ICA37_maica prawdopodobnie wychwyciły szum linii energetycznej;
- 2) składowe ICA21_fastica, ICA57_maica i ICA13_maica przypominają artefakty EOG (dobrze widoczne w kanale Fpz z Rysunku 6.2.1);
- 3) składowe ICA9_fastica, ICA14_fastica, ICA53_maica i ICA3_maica przechwyciły rytmiczny artefakt, prawdopodobnie artefakt EKG.




Rysunek 6.2.3 Składowe wynikowe zwrócone przez algorytm FastICA (po zastosowaniu MAICA) połączone ze składowymi wynikowymi zwróconymi przez algorytm FastICA zastosowany bezpośrednio na 64 oryginalnych sygnałach; przedstawiono 5 losowo wybranych par. Źródło: opracowanie własne.

Porównując oba wykresy, można powiedzieć, że chociaż wspomniane artefakty są widoczne w obu zestawach składowych, są one znacznie bardziej widoczne w zestawie sygnałów wygenerowanych przy pomocy algorytmu MAICA.



Rysunek 6.2.4 Najbardziej charakterystyczne składowe wyjściowe zwrócone przez algorytm FastICA dla zestawu 64 oryginalnych sygnałów. Źródło: opracowanie własne.



Rysunek 6.2.5 Najbardziej charakterystyczne składowe wyjściowe zwrócone przez algorytm FastICA dla zestawu 60 sygnałów utworzonych za pomocą algorytmu MAICA. Źródło: opracowanie własne.

6.3 System 3 – dane EEG z wielu prób

Celem ostatniego etapu weryfikacji działania algorytmu MAICA było ustalenie czy algorytm ten przyniesie korzyści praktyczne po zastosowaniu go w procesie klasyfikacji danych EEG w czasie rzeczywistym. Tym razem w badaniu wykorzystano zestaw danych EEG zarejestrowanych w laboratorium Zespołu Neuroanaliz Wydziału Informatyki Zachodniopomorskiego Uniwersytetu Technologicznego w Szczecinie w trakcie eksperymentu przeprowadzonego z interfejsem mózg-komputer opartym na wyobrażeniu ruchu rąk. Eksperyment przeprowadzono na pięciu osobach (3 mężczyzn, 2 kobiety, średni wiek 26.4 lat, zakres 22-32 lata). Wszyscy badani byli praworęczni. Żaden z badanych nie miał wcześniejszych doświadczeń z BCI i żaden nie zgłosił żadnych zaburzeń psychicznych. Przed rozpoczęciem eksperymentu uzyskano pisemną zgodę od wszystkich uczestników.

Szczegółowy schemat eksperymentu z jednym uczestnikiem był identyczny jak w przypadku badania opisanego w podrozdziale 4.3. Tak jak we wspomnianym badaniu eksperyment został podzielony na 200 10-sekundowych prób. Podczas każdej próby pacjentowi przedstawiano strzałkę skierowaną w lewo lub w prawo. Zadanie badanego polegało na wyobrażeniu sobie obrotu nadgarstka ręką wskazaną przez strzałkę. Kierunki strzałek dla kolejnych prób zostały wybrane losowo. Eksperyment podzielono na 4 sesje, każda po 50 prób. Próby w obrębie jednej sesji występowały jedna po drugiej (bez przerwy), natomiast po każdej sesji zaplanowano 5-cio minutową przerwę. Stąd cały eksperyment z jednym podmiotem trwał około 45 minut.

Dane EEG rejestrowano z dwóch kanałów monopolarnych przy częstotliwości próbkowania 256 Hz. Elektrody przymocowano do skóry głowy pacjenta w pozycjach C3 i C4, zgodnie z Międzynarodowym Systemem 10-20 [240]. Elektrode referencyjną umieszczono na lewym wyrostku sutkowatym, natomiast elektrodę uziemiającą w pozycji Fpz. Sygnał EEG został pozyskany za pomocą wzmacniacza Discovery 20 (BrainMaster) i zarejestrowany za pomocą oprogramowania OpenVibe [235]. Dane EEG wstępnie przefiltrowano w paśmie 1 - 30 Hz za pomocą filtra Butterwortha czwartego rzędu.

Aby dowiedzieć się, czy MAICA zwiększy dokładność klasyfikacji prowadzonej w czasie rzeczywistym w trybie online, przygotowano dwa zestawy danych. Pierwszy składał się z 2-

kanalowych danych EEG (zarejestrowanych podczas pierwszych trzech sesji), drugi był tego samego rozmiaru, ale zawierał kanały zrekonstruowane ze składowych zwróconych przez MAICA. Jak przedstawiono w rozdziale 4, składowe niezależne zwrócone przez algorytm MAICA nie mogą być bezpośrednio wykorzystane w procesie klasyfikacji z uwagi na to, że algorytmy ICA zwracają nieuporządkowany zestaw składowych. Wielokrotne uruchomienie algorytmu ICA nawet na tym samym zestawie sygnałów skutkuje najczęściej zupełnie przypadkową (i różną) kolejnością składowych wynikowych. Oznacza to, że zwykle nie ma bezpośredniego dopasowania między składowymi wynikowymi znalezionymi w różnych próbach.

Do przeprowadzenia prawidłowego treningu klasyfikatora konieczne więc było uporządkowanie składowych wynikowych. Najprostszym (i jednocześnie najczęściej stosowanym przy analizie EEG) rozwiązaniem była rekonstrukcja pierwotnych kanałów ze składowych wynikowych. Oczywiście rekonstrukcja kanałów przy wykorzystaniu wszystkich składowych wynikowych nie miałaby sensu, ponieważ prowadziłaby do uzyskania sygnałów identycznych z oryginalnymi sygnałami C3 i C4. Dlatego przed rozpoczęciem procesu rekonstrukcji należało wykryć i usunąć „najgorsze” składowe z każdej próby. Standardowo zadanie to jest wykonywane poprzez manualną analizę poszczególnych składowych wynikowych i odrzucenie tych składowych, które najprawdopodobniej stanowią artefakty współlistniejące z rzeczywistymi źródłami w sygnale EEG. Takie postępowanie jest możliwe w przypadku analizy sygnału w trybie offline, nie jest natomiast możliwe do zastosowania w trybie online. Oczywiście są metody pozwalające na automatyczną redukcję artefaktów spośród zestawu składowych niezależnych (omówione w rozdziale 2 niniejszej rozprawy), ale zwykle pracują one dobrze jedynie na sygnałach znacznie dłuższych niż sygnały analizowane w badaniu (2560 próbek: 10 sekund x 256 Hz).

Z uwagi na powyższe, opracowano autorską procedurę automatycznego wykrywania i odrzucania składowych o najniższej istotności. Zaproponowana procedura rozpoczyna się od uruchomienia algorytmu MAICA niezależnie na każdym z kanałów. Następnie wyznaczana jest korelacja między składowymi wynikowymi otrzymanymi dla obu kanałów i odrzucane są te pary składowych, które spełniają dwa warunki:

- 1) są wysoce skorelowane ze sobą (współczynnik korelacji wzajemnej przekracza 90%),
- 2) mają podobny wpływ na oba kanały (odpowiadające im współczynniki w macierzy mieszającej różnią się o co najwyżej 10%).

Podejście takie było motywowane dwoma faktami.

- 1) Po pierwsze, tak wysoka korelacja dwóch składowych wyodrębnionych z różnych kanałów prawdopodobnie oznacza, że reprezentują one to samo źródło.
- 2) Po drugie, jeśli źródło to jest mniej więcej równo reprezentowane zarówno w kanałach C3 jak i C4, raczej nie odpowiada bieżącej aktywności mózgu związanej z zadaniem wyobrażenia ruchu prawej lub lewej ręki.

Procedura opisana powyżej została zastosowana w celu usunięcia najmniej istotnych składowych z każdej epoki. Każdorazowo po usunięciu najmniej istotnych składowych dokonywano rekonstrukcji kanałów C3 i C4 wykorzystując pozostałe składowe.

Opisane powyżej dwa zestawy danych (zestaw 1 – zestaw oryginalnych sygnałów z kanałów C3 i C4; zestaw 2 – zestaw sygnałów C3 i C4 zrekonstruowanych na podstawie nieodrzuconych składowych wynikowych algorytmu MAICA) zostały przetworzone zgodnie z dwustopniowym cyklem przetwarzania: ekstrakcja cech - klasyfikacja. Ponieważ w procesie klasyfikacji zastosowano 10-krotną walidację krzyżową, oba etapy przeprowadzono w 10-iteracyjnej pętli, osobno dla każdego z 10 zestawów testowych. Macierz cech składała się z 8 cech (po cztery cechy dla każdego kanału) przedstawiających moc pasmową w jednym z czterech pasm częstotliwości: klasycznym paśmie alfa (8–13 Hz) i trzech podpasma pasma beta: 13–18 Hz, 18–24 Hz i 24–30 Hz. W procesie klasyfikacji wykorzystany został liniowy klasyfikator SVM. W każdej z 10 iteracji pętli walidacyjnej klasyfikator był uczony na 135 próbach i walidowany na 15 pozostałych. Miernikiem jakości klasyfikatora była uśredniona dokładność wyznaczona z 10 zbiorów walidacyjnych.

Dla każdego uczestnika badania zbudowano więc dwa klasyfikatory. Trening klasyfikatorów został przeprowadzony podczas przerwy między trzecią i czwartą sesją na danych zarejestrowanych w pierwszych trzech sesjach. W ostatniej sesji oba klasyfikatory zostały użyte w trybie online do sprawdzenia ich jakości na nowo pozyskanych danych. W każdej próbie klasa wyznaczana przez jeden (losowo wybrany) klasyfikator była prezentowana uczestnikowi (jako

informacja zwrotna informująca uczestnika o tym jak dobrze wykonał postawione przed nim zadanie) w postaci małej niebieskiej strzałki wyświetlanej tuż nad strzałką wskazującą aktualny kierunek. Uśredniony wynik z 50 prób testowych stanowił miarę efektywności klasyfikatora.

Zgodnie z opisaną powyżej procedurą, przed rozpoczęciem procesu uczenia klasyfikatora dane zarejestrowane w każdej ze 150 analizowanych prób zostały wprowadzone na wejście algorytmu MAICA. Z uwagi na to, że wszystkie próby zostały zarejestrowane z tego samego systemu (co oznacza, że złożoność każdej próby była mniej więcej taka sama), parametry filtrów wygładzających wykorzystanych do generowania kolejnych sygnałów wejściowych wyznaczono na podstawie pierwszej próby i zastosowano we wszystkich kolejnych próbach. Algorytm szukania parametrów filtrów wygładzających został uruchomiony z domyślnymi wartościami parametrów ($P2 = 0.4$, $P1 = 0.97$ i $P3 = 0.4$). Oczywiście, jako że w każdej próbie algorytm MAICA był uruchamiany dwukrotnie (najpierw dla kanału C3, a następnie dla kanału C4), dla każdego podmiotu otrzymano dwa osobne wektory współczynników filtra wygładzającego, jeden dla kanału C3 i jeden dla kanału C4. Wektory wyznaczone dla kolejnych podmiotów zostały przedstawione w Tabeli 6.3.1.

Podmiot	Kanał	Długość filtra
P1	C3	4 7 10 13 17 22 27 31
	C4	4 7 10 14 18 23 28 32 36
P2	C3	5 9 13 18 24 29 34 39
	C4	5 9 13 18 23 28 33 38
P3	C3	5 10 16 22 27 32 36 40 44
	C4	5 9 14 19 25 30 35 39 43 47 51 55 59 63 68 73 78 83
P4	C3	4 7 10 13 17 21 26 30
	C4	4 7 10 13 17 22 27 32 36
P5	C3	5 8 11 14 17 21 26 30 34
	C4	5 8 12 15 19 24 29 33 37

Tabela 6.3.1 Wektory parametrów filtrów wygładzających wyznaczone za pomocą metody MAICA dla każdego podmiotu oraz kanału.

Tabela 6.3.1 pokazuje, że zarówno liczba filtrów, jak i rozmiar okna kolejnych filtrów, były bardzo podobne dla obu kanałów dla prawie wszystkich badanych podmiotów. Tak wysokie podobieństwo oznacza, że złożoność analizowanego systemu nie uległa istotnej zmianie pomiędzy

badanymi podmiotami. Jedynie wektor uzyskany dla kanału C4 podmiotu P3 znacząco odbiegał od pozostałych wektorów i zawierał więcej filtrów niż pozostałe kanały. Po przeprowadzeniu dokładnej analizy sygnału zarejestrowanego w kanale C4 okazało się, że niewystarczająco dokładny montaż elektrody C4 spowodował pojawienie się w sygnale artefaktu wolno-falowego (trendu). W efekcie filtry o szerszym oknie czasowym generowały sygnały o wystarczająco wysokiej korelacji z oryginalnym sygnałem C4, stąd więcej filtrów zostało zwróconych przez algorytm.

Po zdefiniowaniu parametrów filtrów przeprowadzono pozostałe etapy opisanej powyżej procedury otrzymując w efekcie dwa klasyfikatory dla każdego z badanych podmiotów. Klasyfikator pierwszy był trenowany na oryginalnych sygnałach zarejestrowanych z kanałów C3 i C4 (C_classic), klasyfikator drugi był trenowany na sygnałach zrekonstruowanych z wybranych składowych wyników algorytmu MAICA (C_MAICA). Wyniki klasyfikacji dla obu sesji, treningowo-walidacyjnej oraz testowej, przedstawiono w Tabeli 6.3.2. Dwie pierwsze kolumny opisujące każdą sesję przedstawiają dokładność klasyfikacji dla klasyfikatora C_classic (1. kolumna) i klasyfikatora C_MAICA (2. kolumna). W trzeciej kolumnie podano liczbę prób, które zostały poprawione w wyniku zastosowania zaproponowanego podejścia do usuwania najmniej istotnych składowych. Ostatnia kolumna w każdej grupie przedstawia względny wzrost dokładności klasyfikacji po zastosowaniu algorytmu MAICA.

Podmiot	Sesja treningowo-walidacyjna				Sesja testowa			
	C_classic [%]	C_MAICA [%]	Liczba skoryg. prób	Wrost dokład. klas. [%]	C_classic [%]	C_MAICA [%]	Liczba skoryg. prób	Wrost dokład. klas. [%]
P1	76.00%	76.00%	30	0.0	70.00%	74.00%	13	5.7
P2	78.00%	80.70%	36	3.5	64.00%	80.00%	13	25.0
P3	83.30%	84.70%	28	1.7	80.00%	84.00%	9	5.0
P4	66.00%	68.00%	56	3.0	66.00%	70.00%	13	6.1
P5	74.70%	76.00%	34	1.7	82.00%	86.00%	19	4.9
	75.60%	77.10%	36.8	2.0	72.40%	78.80%	13.4	8.8

Tabela 6.3.2 Dokładność klasyfikacji uzyskana dla poszczególnych podmiotów po zastosowaniu klasyfikatora C_classic oraz C_MAICA w sesji treningowo-walidacyjnej oraz testowej.

Analizując dokładność klasyfikacji z i bez wstępnego przetwarzania MAICA można zauważyć, że chociaż wzrost dokładności był niewielki w przypadku danych walidacyjnych (średnio 2%), to w przypadku danych testowych wyniósł już prawie 9% (średnia dla 5 podmiotów). Dokładność klasyfikacji wyznaczona dla każdego podmiotu wzrosła co najmniej o około 5%, osiągając najwyższą wartość 25% dla podmiotu *P2*. Tak wysoki wzrost dokładności klasyfikacji uzyskany w przypadku danych, które nie były znane podczas etapu uczenia klasyfikatora jest bardzo ważną cechą proponowanego podejścia. Pomimo tego, że kiedy rozpoczynano eksperyment, nie przewidywano takiego zachowania, wydaje się ono całkiem rozsądne i dość łatwe do wyjaśnienia. Poprzez rozkład sygnału z każdej nowej próby na indywidualny zestaw składowych, MAICA (w połączeniu z zaproponowanym podejściem do usuwania składowych najmniej istotnych dla danego zadania) była w stanie wyodrębnić składowe o niskiej istotności, nawet jeżeli były one inne niż te występujące w próbach zawartych w zestawie uczącym.

Jak można również zauważyć w Tabeli 6.3.2, jedynie około 25% prób w obu zestawach zostało skorygowanych po zastosowaniu MAICA. Wartość ta była nieco wyższa w przypadku zestawu testowego (26%) w porównaniu z zestawem walidacyjnym (24%). Trudno jest zaobserwować korelację między liczbą poprawionych prób a dokładnością klasyfikacji. Zasadniczo, w przypadku danych walidacyjnych, im więcej prób zostało skorygowanych, tym większy wzrost dokładności uzyskano (jedynie dla podmiotu *P1* nie zaobserwowano wzrostu dokładności niezależnie od korekty 30 prób). W przypadku sesji testowej brak jest zauważalnej korelacji między dokładnością klasyfikacji, a liczbą skorygowanych prób.

W przypadku przetwarzania sygnału w trybie online bardzo istotny jest czas niezbędny do przetworzenia sygnału z danej próby. Zastosowanie algorytmu MAICA (wraz z proponowanym podejściem do usuwania składowych) jedynie nieznacznie wydłuża czas przetwarzania sygnałów zarejestrowanych w danej próbie. Tabela 6.3.3 przedstawia czas potrzebny na wykonanie całego cyklu przetwarzania BCI dla jednej próby bez (*C_classic* [ms]) i z wstępnym przetwarzaniem MAICA (*C_MAICA* [ms]). Proces obliczeniowy został uruchomiony na komputerze o następujących parametrach: Procesor: Intel CORE i7-6700HQ CPU @ 2,60 GHz, 16 GB pamięci RAM, Windows 10 x64.

Podmiot	C_classic [ms]	C_MFICA [ms]	Różnica [ms]
P1	14.869220	20.688880	5.819660
P2	13.486405	19.220645	5.734240
P3	30.542290	36.273030	5.730740
P4	14.818445	20.547605	5.729160
P5	18.101060	23.835120	5.734060
Średnia:	18.363484	24.113056	5.749572

Tabela 6.3.3 Czas przetwarzania potrzebny do przeprowadzenia klasyfikacji jednej próby z zastosowaniem algorytmu MAICA oraz bez niego.

Jak można zauważyć w ostatniej kolumnie Tabeli 6.3.3, przedstawiającej różnicę między czasem przetwarzania z oraz bez uruchomienia algorytmu MAICA dodatkowy czas potrzebny na obliczenia MAICA był bardzo krótki (mniej niż 6 ms) i stabilny dla poszczególnych podmiotów.

6.4 Wnioski końcowe

Każdy z trzech systemów przedstawionych w niniejszym rozdziale ilustruje korzyść z zastosowania algorytmu MAICA. Pierwszy system (składający się z dwóch kombinacji 10 sinusoid źródłowych) udowodnił, że proponowana metoda zwiększenia wymiaru macierzy sygnałów wejściowych pozwala na uzyskanie większej liczby składowych na wyjściu algorytmu ICA, niż liczba sygnałów dostępnych pierwotnie. Jak pokazano w podrozdziale 6.1, gdy w analizie zastosowano domyślne wartości parametrów MAICA, rozkład mieszanin $M1$ i $M2$ na sygnały źródłowe był prawie idealny. Odzyskano nie tylko wszystkie 10 sygnałów sinusoidalnych (Rysunek 6.1.3), ale także korelacja między składowymi wyjściowymi ICA i wejściowymi sinusoidami była niezwykle wysoka (99–100%, Tabela 6.1.2).

Dodatkowo, porównanie sygnałów źródłowych odzyskanych po zastosowaniu algorytmu MAICA z sygnałami źródłowymi odzyskanymi za pomocą metod referencyjnych (DE, SCICA, EEMD-ICA oraz WICA) wykazało, że zaproponowana metoda zwraca składowe charakteryzujące się wyższą korelacją z sygnałami źródłowymi. Pomimo wypróbowania wielu różnych zestawów parametrów dla każdej z metod referencyjnych, nie udało się odzyskać wszystkich sinusoid źródłowych z tak samo wysoką korelacją, jak w przypadku metody MAICA (Tabela 6.1.2). Spośród czterech metod użytych do porównania, najlepszy zestaw komponentów uzyskano przy zastosowaniu metody DE (dla zestawu wejściowego złożonego z dwóch oryginalnych mieszanin

sinusoidalnych i ich 42 opóźnień). W sytuacji, kiedy uruchomiono algorytm ICA na tak dużym zestawie komponentów wejściowych, udało się odzyskać 10 komponentów wyjściowych wykazujących dość wysoką korelację ze źródłami (75%–99%). Możliwym jest, że wykorzystanie metody DE z odpowiednio dużym zestawem opóźnień pozwoliłoby na odzyskanie sygnałów źródłowych z dokładnością porównywalną do tej która została uzyskana przy pomocy metody MAICA, jednak z powodu ograniczonej długości sygnału (1000 próbek) stosowanie wyższej liczby opóźnień byłoby niewłaściwe, ponieważ wymagałoby zbytniego skrócenia analizowanego sygnału.

Metoda DE potencjalnie mogłaby więc zwrócić składowe wynikowe o wysokiej korelacji z sygnałami źródłowymi, jednak z uwagi na wymaganą do tego celu dużą liczbę składowych wejściowych proces rozkładu sygnału trwałby znacznie dłużej. Problem z metodą DE nie polega więc na dokładności rozkładu, ale raczej na czasie przetwarzania. Gdy porówna się ten czynnik dla obu metod, MAICA okazuje się być znacznie szybsza. Chociaż ilość czasu potrzebna do wygenerowania dodatkowego sztucznego elementu wejściowego (poprzez zastosowanie filtra średniej ruchomej lub opóźnienie sygnału mieszanego) jest nieistotna, czas potrzebny algorytmowi ICA na znalezienie macierzy miksującej znacznie wzrasta z każdym dodatkowym wejściem. Kiedy porównano czas obliczeń obu metod, algorytm DE był 35 razy wolniejszy niż MAICA. Nie stanowi to oczywiście problemu podczas przetwarzania offline, ale znacząco utrudnia analizę sygnału w trybie online.

Kolejnym faktem, o którym należy wspomnieć porównując metody MAICA z metodą DE, jest to, że w przypadku metody MAICA po transformacji powrotnej z przestrzeni komponentów wyjściowych do przestrzeni wejściowej (na przykład po usunięciu komponentów zidentyfikowanych jako artefakty) uzyskiwane są sygnały o takiej samej długości jak sygnały oryginalne. W przypadku metody DE sygnały uzyskiwane po powrocie do przestrzeni wejściowej są natomiast zawsze skrócone. Jest to wynikiem tego, że poprzez zastosowanie opóźnionych sygnałów ograniczana jest długość macierzy sygnałów wprowadzanej do ICA, a zatem składniki zwracane przez ICA są również krótsze niż początkowe mieszaniny zarejestrowane z czujników.

W badaniu prowadzonym z wykorzystaniem 64-kanalowej macierzy rzeczywistych sygnałów EEG wykazano, że składowe zwrócone przez ICA po zastosowaniu zestawu filtrów o

zerowej fazie są poprawne nie tylko dla sztucznie utworzonego systemu matematycznego, ale także dla prawdziwego wielowymiarowego zestawu danych. Jak wykazano w podrozdziale 6.2, MAICA uruchomiona na zestawie jedynie pięciu kanałów oryginalnych zwróciła zestaw sygnałów, wśród których znajdowały się składowe-artefaktowe analogiczne do składowych-artefaktowych zwróconych przez klasyczny algorytm ICA uruchomiony na pełnym zestawie 64 kanałów (Rysunki 6.2.2 i 6.2.3). Co więcej, składowe-artefaktowe zwrócone przez MAICA były łatwiej rozpoznawalne niż te zwrócone przez klasyczny algorytm ICA.

Ostatni system (klasyfikacja wyobrażenia ruchu) został wykorzystany do wykazania, że MAICA może z powodzeniem pracować w trybie online. Cel ten udało się osiągnąć, ponieważ opóźnienie powstałe w wyniku: 1) przygotowania dwóch zestawów filtrowanych sygnałów (dla C3 i C4), 2) zastosowania ICA do każdego z dwóch zestawów oraz 3) odrzucenia prawdopodobnych artefaktów wyniosło mniej niż 6 ms dla każdej próby (Tabela 6.3.3). Ten niewielki wzrost czasu przetwarzania nie spowodował zauważalnych opóźnień w procesie klasyfikacji.

Zasadniczo MAICA może być stosowane do wszystkich rodzajów sygnałów, w przypadku których można zastosować klasyczny algorytm ICA. Innymi słowy, jeśli można zastosować ICA do macierzy sygnałów, można również wykorzystać MAICA do rozszerzenia tej macierzy, aby ułatwić odzyskanie poszczególnych sygnałów źródłowych. Jednak oprócz pytania o „możliwość” istnieje również pytanie o „zasadność” takiego rozwiązania. Istnieją dwa przypadki, w których zastosowanie MAICA jest nieuzasadnione i oba zależą od wielkości macierzy sygnałów wejściowych:

- 1) macierz wejściowa składa się z bardzo krótkich sygnałów – w tym przypadku prawdopodobnie nie zostaną utworzone żadne filtry, a zatem nie zostanie uzyskany zysk z zastosowania MAICA;
- 2) macierz wejściowa składa się z dziesiątek sygnałów – ponieważ ICA działa dobrze z danymi wielowymiarowymi, aplikacja MAICA prawdopodobnie tylko zwiększy złożoność obliczeń.

ZAKOŃCZENIE

Celem niniejszej rozprawy było: *opracowanie metody przetwarzania wstępnego nisko-kanalowych sygnałów EEG, korzystającej z idei połączenia rzeczywistych kanałów EEG z kanałami sztucznie wygenerowanymi*. Cel ten udało się osiągnąć. Algorytm MAICA może być z powodzeniem stosowany do znajdowania komponentów sygnału, nawet w przypadku konfiguracji jedno-kanalowej oraz przy ściśle narzuconych ograniczeniach czasowych.

W pracy pokazano, że zaproponowane podejście do rozwiązania nieokreślonego modelu ICA umożliwia dekompozycję nisko-kanalowego sygnału na zestaw elementów o wysokim wymiarze. Trzy badania przedstawione w rozdziale szóstym pokazują, że istnieje duże prawdopodobieństwo, że przynajmniej niektóre komponenty z tego zestawu są równoważne prawdziwym źródłom sygnału rejestrowanego z czujników. W przykładzie z sinusami wszystkie 10 komponentów wyjściowych było prawie identycznych jak funkcje sinusoidalne wykorzystane w przygotowanych dwóch mieszaninach wejściowych. Ponadto, w badaniu nr. 2 pokazano, że gdy tylko 5 z 64 zarejestrowanych sygnałów EEG zostało wprowadzonych do algorytmu MFICA, wykryte artefakty były nie tylko podobne do tych zwróconych przez klasyczny algorytm ICA zastosowany na wszystkich 64 kanałach, ale były również znacznie bardziej czytelne. Przykład badania drugiego bezpośrednio potwierdza tezę, że MAICA jest w stanie dekomponować niskokanalowy sygnał EEG na komponenty w taki sam sposób, jak ICA dla sygnału wielokanalowego. Wreszcie ostatni etap eksperymentu ujawnił dwie dodatkowe zalety proponowanej metody - krótki czas przetwarzania (narzut czasowy związany z użyciem MAICA był bardzo krótki, mniejszy niż 6ms) oraz stabilność parametrów zestawu filtrów. Obie zalety są bardzo ważne, ponieważ pozwalają na wykorzystanie algorytmu do klasyfikacji aktywności mózgu w czasie rzeczywistym. Dodatkowo, dzięki stabilności parametrów zestawu filtrów, parametry te można obliczyć tylko raz przed rozpoczęciem klasyfikacji w trybie online, a następnie można je stosować do kolejno rejestrowanych prób.

Z przeprowadzonych badań wynika, że hipoteza niniejszej rozprawy, sformułowana następująco: *Zaproponowana w rozprawie metoda wstępnego przetwarzania nisko-kanalowych sygnałów EEG pozwala na uzyskanie składowych wyników charakteryzujących się wyższym*

podobieństwem do rzeczywistych (bądź przewidywanych) sygnałów źródłowych oraz pozwalających na uzyskanie wyższej dokładności klasyfikacji, aniżeli metody referencyjne. Jednocześnie z uwagi na niski narzut czasowy metoda ta może być z powodzeniem stosowana w interfejsach mózg-komputer pracujących w trybie online została udowodniona. Odnosząc się bardziej szczegółowo do poszczególnych fraz zawartych w hipotezie można powiedzieć, że:

1. *Fraza mówiąca o tym, że metoda MAICA pozwala na uzyskanie składowych wynikowych charakteryzujących się wyższym podobieństwem do rzeczywistych (bądź przewidywanych) sygnałów źródłowych została zweryfikowana w eksperymencie 1 i 2 (rozdział 6).*
2. *Fraza mówiąca o tym, że składowe wynikowe uzyskane po zastosowaniu algorytmu MAICA pozwalają na uzyskanie wyższej dokładności klasyfikacji, aniżeli metody referencyjne została zweryfikowana w eksperymencie 3 (rozdział 6).*
3. *Fraza mówiąca o tym, że z uwagi na niski narzut czasowy metoda ta może być z powodzeniem stosowana w interfejsach mózg-komputer pracujących w trybie online została zweryfikowana w eksperymencie 3 (rozdział 6).*

W pracy można wyróżnić następujące elementy wkładu własnego:

1. Opracowanie oraz implementacja metody MAICA, pozwalającej na wygenerowanie zestawu sztucznych sygnałów na podstawie nisko-kanałowej macierzy sygnałów rzeczywistych zarejestrowanych z czujników pomiarowych. Jak pokazano w pracy, opracowana metoda działa bez dostarczenia jakiegokolwiek informacji o procesie mieszania sygnałów źródłowych.
2. Wykazanie skuteczności działania metody MAICA w trzech systemach o różnych charakterystykach.
3. Opracowanie oraz implementacja metody pozwalającej na parowanie składowych niezależnych z zarejestrowanymi sygnałami EEG. Zaproponowane rozwiązanie bazuje na macierzy demiksującej zwracanej przez algorytm ICA.
4. Opracowanie oraz implementacja procedury automatycznego wykrywania i odrzucania składowych o najniższej istotności.

Pewną niedogodnością zaproponowanej metody jest konieczność ustalenia wartości trzech parametrów wejściowych $P1$, $P2$ oraz $P3$ określających minimalne/maksymalne poziomy

korelacji pomiędzy sygnałami analizowanymi na wejściu i wyjściu algorytmu ICA. Wprawdzie użycie domyślnych wartości tych parametrów pozwala uzyskać bardzo dobre rezultaty rozkładu (nawet przy dużych zmianach ich wartości, generowane wyniki są nadal wartościowe), to jednak występowanie parametrów powoduje, że metoda MAICA nie jest metodą w pełni automatyczną i uniwersalną. Stąd dalsze kierunki prac autora niniejszej rozprawy będą zmierzały właśnie do opracowania sposobu bardziej uniwersalnej metody doboru parametrów filtrów. Dodatkowo, w dalszych badaniach przewiduje się przeprowadzenie analizy użyteczności algorytmu MAICA dla różnej liczby sygnałów o różnej długości. Planowane jest również wprowadzenie zmian w zaproponowanej metodzie parowania sygnałów. Korzystając z techniki parowania bazującej na macierzy demiksującej, można by podjąć próbę automatycznej detekcji i usuwania artefaktów. Metoda ta mogłaby opierać się na charakterystyce artefaktu oraz kanale, w którym powinien być on widoczny.

BIBLIOGRAFIA

- [1] Friman, O.; Volosyak, I.; Graser, A. Multiple Channel Detection of Steady-State Visual Evoked Potentials for Brain-Computer Interfaces. *IEEE Transactions on Biomedical Engineering* 2007, 54 (4), 742–750. <https://doi.org/10.1109/TBME.2006.889160>.
- [2] Aviyente, S.; Bernat, E. M.; Malone, S. M.; Iacono, W. G. Analysis of Event Related Potentials Using PCA and Matching Pursuit on the Time-Frequency Plane. In *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*; 2006; pp 2454–2457. <https://doi.org/10.1109/IEMBS.2006.259590>.
- [3] Luo, G.; Chen, G.; Tian, L.; Qin, K.; Qian, S.-E. Minimum Noise Fraction versus Principal Component Analysis as a Preprocessing Step for Hyperspectral Imagery Denoising. *Canadian Journal of Remote Sensing* 2016, 42 (2), 106–116. <https://doi.org/10.1080/07038992.2016.1160772>.
- [4] Kukharev G., Forczmański P.: Data dimensionality reduction for face recognition. *Machine Graphics and Vision*, Vol. 13, No. 1/2, 2004
- [5] Enshaeifar, S.; Took, C. C.; Park, C.; Mandic, D. P. Quaternion Common Spatial Patterns. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2017, 25 (8), 1278–1286. <https://doi.org/10.1109/TNSRE.2016.2625039>
- [6] Kim, Y.; Ryu, J.; Kim, K. K.; Took, C. C.; Mandic, D. P.; Park, C. Motor Imagery Classification Using Mu and Beta Rhythms of EEG with Strong Uncorrelating Transform Based Complex Common Spatial Patterns. *Comput Intell Neurosci* 2016, 2016, 1489692. <https://doi.org/10.1155/2016/1489692>
- [7] Hyvärinen, A.; Oja, E. Independent Component Analysis: Algorithms and Applications. *Neural Netw* 2000, 13 (4–5), 411–430. [https://doi.org/10.1016/s0893-6080\(00\)00026-5](https://doi.org/10.1016/s0893-6080(00)00026-5).
- [8] Oja, E.; Yuan, Z. The FastICA Algorithm Revisited: Convergence Analysis. *IEEE Transactions on Neural Networks* 2006, 17, 1370–1381. https://doi.org/10.1007/978-3-642-41320-9_1.
- [9] Srinivasulu, A.; Reddy, M. S. Artifacts Removing From EEG Signals by ICA Algorithms, *IOSR Journal of Electrical and Electronics Engineering (IOSRJEEE)*, 2012. <https://doi.org/10.9790/1676-0241116>.
- [10] Kim, C. S.; Sun, J.; Liu, D.; Wang, Q.; Paek, S. G. Removal of Ocular Artifacts Using ICA and Adaptive Filter for Motor Imagery-Based BCI. *IEEE/CAA Journal of Automatica Sinica* 2017, 1–8. <https://doi.org/10.1109/JAS.2017.7510370>.
- [11] Augustyniak, P., Maniewski, R., Tadeusiewicz, R. Localization of Noise Sources in a Multilead Electrophysiological Record. In *Recent Developments and Achievements in Biocybernetics and Biomedical Engineering*; Eds.; Advances in Intelligent Systems and

- Computing; Springer International Publishing: Cham, 2018; pp 56–67. https://doi.org/10.1007/978-3-319-66905-2_5.
- [12] Vigário, R. N. Extraction of Ocular Artefacts from EEG Using Independent Component Analysis. *Electroencephalogr Clin Neurophysiol* 1997, 103 (3), 395–404. [https://doi.org/10.1016/s0013-4694\(97\)00042-8](https://doi.org/10.1016/s0013-4694(97)00042-8).
- [13] Jung, T.-P.; Humphries, C.; Lee, T.-W.; Makeig, S.; McKeown, M. J.; Iragui, V.; Sejnowski, T. J. Extended ICA Removes Artifacts from Electroencephalographic Recordings. In *Advances in Neural Information Processing Systems 10*; Jordan, M. I., Kearns, M. J., Solla, S. A., Eds.; MIT Press, 1998; pp 894–900.
- [14] Weidong Z.; Gotman, J. Removal of EMG and ECG Artifacts from EEG Based on Wavelet Transform and ICA. In *The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*; 2004; Vol. 1, pp 392–395. <https://doi.org/10.1109/IEMBS.2004.1403176>.
- [15] Zhaojun Xue; Jia Li; Song Li; Baikun Wan. Using ICA to Remove Eye Blink and Power Line Artifacts in EEG. In *First International Conference on Innovative Computing, Information and Control - Volume I (ICICIC'06)*; 2006; Vol. 3, pp 107–110. <https://doi.org/10.1109/ICICIC.2006.543>.
- [16] Delorme, A.; Palmer, J.; Onton, J.; Oostenveld, R.; Makeig, S. Independent EEG Sources Are Dipolar. *PLoS ONE* 2012, 7 (2), e30135. <https://doi.org/10.1371/journal.pone.0030135>.
- [17] Woon, W. L.; Lowe, D. Can We Learn Anything from Single-Channel Unaveraged MEG Data? *Neural Comput & Applic* 2004, 13 (4), 360–368. <https://doi.org/10.1007/s00521-004-0432-1>.
- [18] Davies, M. E.; James, C. J. Source Separation Using Single Channel ICA. *Signal Processing* 2007, 87 (8), 1819–1832. <https://doi.org/10.1016/j.sigpro.2007.01.011>.
- [19] James, C. J.; Gibson, O. J. Temporally Constrained ICA: An Application to Artifact Rejection in Electromagnetic Brain Signal Analysis. *IEEE Trans Biomed Eng* 2003, 50 (9), 1108–1116. <https://doi.org/10.1109/TBME.2003.816076>.
- [20] James, C. J.; Gibson, O.; Davies, M. On the Analysis of Single versus Multiple Channels of Electromagnetic Brain Signals. *Artif Intell Med* 2006, 37 (2), 131–143. <https://doi.org/10.1016/j.artmed.2006.03.003>.
- [21] Mijović, B.; De Vos, M.; Gligorijević, I.; Taelman, J.; Van Huffel, S. Source Separation from Single-Channel Recordings by Combining Empirical-Mode Decomposition and Independent Component Analysis. *IEEE Trans Biomed Eng* 2010, 57 (9), 2188–2196. <https://doi.org/10.1109/TBME.2010.2051440>.
- [22] Taelman, J.; Mijovic, B.; Huffel, S. V.; Devuyst, S.; Dutoit, T. ECG Artifact Removal from Surface EMG Signals by Combining Empirical Mode Decomposition and Independent Component Analysis. In *BIOSIGNALS*; 2011. <https://doi.org/10.5220/0003136804210424>.

- [23] (198) Inuso, G.; La Foresta, F.; Mammone, N.; Morabito, F. C. Wavelet-ICA Methodology for Efficient Artifact Removal from Electroencephalographic Recordings. In *2007 International Joint Conference on Neural Networks*; 2007; pp 1524–1529. <https://doi.org/10.1109/IJCNN.2007.4371184>.
- [24] Mammone, N.; La Foresta, F.; Morabito, F. C. Automatic Artifact Rejection From Multichannel Scalp EEG by Wavelet ICA. *IEEE Sensors Journal* 2012, 12 (3), 533–542. <https://doi.org/10.1109/JSEN.2011.2115236>.
- [25] (193) Mahajan, R.; Morshed, B. I. Unsupervised Eye Blink Artifact Denoising of EEG Data with Modified Multiscale Sample Entropy, Kurtosis, and Wavelet-ICA. *IEEE J Biomed Health Inform* 2015, 19 (1), 158–165. <https://doi.org/10.1109/JBHI.2014.2333010>.
- [26] (140) Azzerboni, B.; Carpentieri, M.; La Foresta, F.; Morabito, F. C. Neural-ICA and Wavelet Transform for Artifacts Removal in Surface EMG. In *2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541)*; 2004; Vol. 4, pp 3223–3228 vol.4. <https://doi.org/10.1109/IJCNN.2004.1381194>.
- [27] <https://encyklopedia.pwn.pl/haslo/informatyka;3914698.html>, online, dostęp: 23.10.2019
- [28] Osinska V., „Wizualizacja i wyszukiwanie dokumentów”. SBP, *Science Visualisation*, 10.13140/RG.2.1.4179.7847, s: 63., 2010
- [29] Pearce J., The Neurology of Erasistratus. *Journal of Neurological Disorders*. 01. 10.4172/2329-6895.1000111, 2013
- [30] Feindel, W. Thomas Willis (1621-1675)—The Founder of Neurology. *Can Med Assoc J* 1962, 87 (6), 289–296.
- [31] (150) Sabbatini, R. M. E. Phrenology: The History of Brain Localization. *Brain and Mind* 1997, 1.
- [32] Żernicki, B., Mózg, *Wszechnica Polskiej Akademii Nauk*, 1983
- [33] Kumar, J. S.; Bhuvaneswari, P. Analysis of Electroencephalography (EEG) Signals and Its Categorization—A Study. *Procedia Engineering* 2012, 38, 2525–2536. <https://doi.org/10.1016/j.proeng.2012.06.298>.
- [34] Teplan, M., Fundamentals of EEG measurement. Measurement Science Review, *Slovak Academy of Sciences*, Institute of Measurement Science, 2002
- [35] Kułak, W.; Sobaniec, W. Historia odkrycia EEG. *Neurol. Dziec.* 2006, 15 (29), 53–56.
- [36] Bosak, M., Atlas elektroencefalografii, *Wydawnictwo Uniwersytetu Jagiellońskiego*, 2017
- [37] Rösler, F. From Single-Channel Recordings to Brain-Mapping Devices: The Impact of Electroencephalography on Experimental Psychology. *Hist Psychol* 2005, 8 (1), 95–117.

- [38] Szuflitowska, B. Aspekty techniczne rejestracji oraz analizy sygnałów elektroencefalograficznych. *Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej* 2018, Nr 59. <https://doi.org/10.32016/1.59.41>.
- [39] Wang, C.-S. Design of a 32-Channel EEG System for Brain Control Interface Applications. In *Journal of biomedicine & biotechnology*; 2012. <https://doi.org/10.1155/2012/274939>.
- [40] Lopez-Gordo, M. A.; Sanchez-Morillo, D.; Pelayo Valle, F. Dry EEG Electrodes. *Sensors (Basel)* 2014, 14 (7), 12847–12870. <https://doi.org/10.3390/s140712847>.
- [41] Stanisławczyk, A.; Zyss, T.; Sawicki, B. Układ 10-20 Lokalizacji Elektrod EEG Czyli Gdzie Tkwi Pewien Błąd Koncepcyjny. *Acta Universitatis Lodzensis. Folia Biologica et Oecologica* 2006, 03.
- [42] Chang S. Nam, A. Nijholt, F. Lotte, Brain–Computer Interfaces *Handbook: Technological and Theoretical Advances*, CRC Press, 2018
- [43] Arman, S. I.; Ahmed, A.; Syed, A. Cost-Effective EEG Signal Acquisition and Recording System; 2012. <https://doi.org/10.7763/ijbbb.2012.v2.121>.
- [44] Alotaiby, T. N.; El-Samie, F. E. A.; Alshebeili, S. A.; Ahmad, I. A Review of Channel Selection Algorithms for EEG Signal Processing. *EURASIP Journal on Advances in Signal Processing* 2015, 2015, 1–21. <https://doi.org/10.1186/s13634-015-0251-9>.
- [45] Vaid, S.; Singh, P.; Kaur, C. EEG Signal Analysis for BCI Interface: A Review. In *2015 Fifth International Conference on Advanced Computing Communication Technologies*; 2015; pp 143–147. <https://doi.org/10.1109/ACCT.2015.72>.
- [46] Usakli A., Improvement of EEG Signal Acquisition: An Electrical Aspect for State of the Art of Front End, *Computational intelligence and neuroscience*. 2010. 630649. 10.1155/2010/630649, 2010
- [47] Stern, J. M., Atlas of EEG Patterns, *Wolters Kluwer Health*, 2005
- [48] Kane, N.; Acharya, J.; Benickzy, S.; Caboclo, L.; Finnigan, S.; Kaplan, P. W.; Shibasaki, H.; Pressler, R.; van Putten, M. J. A. M. A Revised Glossary of Terms Most Commonly Used by Clinical Electroencephalographers and Updated Proposal for the Report Format of the EEG Findings. Revision 2017. *Clin Neurophysiol Pract* 2017, 2, 170–185. <https://doi.org/10.1016/j.cnp.2017.07.002>.
- [49] Sullivan, T. J.; Deiss, S. R.; Tzyy-Ping Jung; Cauwenberghs, G. A Brain-Machine Interface Using Dry-Contact, Low-Noise EEG Sensors. In *2008 IEEE International Symposium on Circuits and Systems*; 2008; pp 1986–1989. <https://doi.org/10.1109/ISCAS.2008.4541835>.
- [50] Corsi-Cabrera, M.; Angel Guevara, M.; Ramos-Loyo, J. Patterns of Covariant Power and Coherent EEG Activity during Rest in Young Adults. *Int. J. Neurosci.* 2008, 118 (6), 821–837. <https://doi.org/10.1080/00207450701750448>.

- [51] Niedermeyer, E.; Silva, F. H. L. da. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*; Lippincott Williams & Wilkins, 2005.
- [52] Rana, K. D.; Vaina, L. M. Functional Roles of 10 Hz Alpha-Band Power Modulating Engagement and Disengagement of Cortical Networks in a Complex Visual Motion Task. *PLoS One* 2014, 9 (10). <https://doi.org/10.1371/journal.pone.0107715>.
- [53] Johnson, R. Milavetz, G. Identifying Periods of Drowsy Driving Using EEG Timothy Brown, *Ph.D., Pharm.* 2013 Sep; 57: 99–108, 2013
- [54] Malar, E. Gauthaam, M. Kalaikamal, M. Muthukrishnan, S., The EEG Based Driver Safety System, *IACSIT International Journal of Engineering and Technology*, vol. 4, no. 3, (2012), pp. 340-343
- [55] Gharagozlou, F.; Nasl Saraji, G.; Mazloumi, A.; Nahvi, A.; Motie Nasrabadi, A.; Rahimi Foroushani, A.; Arab Kheradmand, A.; Ashouri, M.; Samavati, M. Detecting Driver Mental Fatigue Based on EEG Alpha Power Changes during Simulated Driving. *Iran. J. Public Health* 2015, 44 (12), 1693–1700.
- [56] Klimecki, O. M.; Leiberg, S.; Lamm, C.; Singer, T. Functional Neural Plasticity and Associated Changes in Positive Affect after Compassion Training. *Cereb. Cortex* 2013, 23 (7), 1552–1561. <https://doi.org/10.1093/cercor/bhs142>.
- [57] Baumeister, J.; Barthel, T.; Geiss, K. R.; Weiss, M. Influence of Phosphatidylserine on Cognitive Performance and Cortical Activity after Induced Stress. *Nutr Neurosci* 2008, 11 (3), 103–110. <https://doi.org/10.1179/147683008X301478>.
- [58] Günay, S. Y.; Hocaoglu, E.; Patoglu, V.; Çetin, M. Classification of Motor Task Execution Speed from EEG Data. *2016 24th Signal Processing and Communication Application Conference (SIU)* 2016, 2257–2260. https://doi.org/10.1007/978-3-642-41320-9_1.
- [59] Baker, S. N. Oscillatory Interactions between Sensorimotor Cortex and the Periphery. *Curr. Opin. Neurobiol.* 2007, 17 (6), 649–655. <https://doi.org/10.1016/j.conb.2008.01.007>.
- [60] Zhang, Y.; Chen, Y.; Bressler, S. L.; Ding, M. Response Preparation and Inhibition: The Role of the Cortical Sensorimotor Beta Rhythm. *Neuroscience* 2008, 156 (1), 238–246. <https://doi.org/10.1016/j.neuroscience.2008.06.061>.
- [61] Markiewicz, R. The Use of EEG Biofeedback/Neurofeedback in Psychiatric Rehabilitation. *Psychiatr. Pol.* 2017, 51 (6), 1095–1106. <https://doi.org/10.12740/PP/68919>.
- [62] Coben, R.; Evans, J. R. Neurofeedback and Neuromodulation Techniques and Applications; 2011. https://doi.org/10.1007/978-3-642-41320-9_1.
- [63] Loo, S. K.; Makeig, S. Clinical Utility of EEG in Attention-Deficit/Hyperactivity Disorder: A Research Update. *Neurotherapeutics* 2012, 9 (3), 569–587. <https://doi.org/10.1007/s13311-012-0131-z>.

- [64] McLin, D. E.; Miasnikov, A. A.; Weinberger, N. M. CS-Specific Gamma, Theta, and Alpha EEG Activity Detected in Stimulus Generalization Following Induction of Behavioral Memory by Stimulation of the Nucleus Basalis. *Neurobiol Learn Mem* 2003, 79 (2), 152–176. [https://doi.org/10.1016/s1074-7427\(02\)00009-6](https://doi.org/10.1016/s1074-7427(02)00009-6).
- [65] Colrain, I. M.; Turlington, S.; Baker, F. C. Impact of Alcoholism on Sleep Architecture and EEG Power Spectra in Men and Women. *Sleep* 2009, 32 (10), 1341–1352. <https://doi.org/10.1093/sleep/32.10.1341>.
- [66] Klimesch, W. Memory Processes, Brain Oscillations and EEG Synchronization. *International journal of psychophysiology : official journal of the International Organization of Psychophysiology* 1996, 24 (1–2), 61–100. https://doi.org/10.1007/978-3-642-41320-9_1.
- [67] (189) O’Keefe, J.; Burgess, N. Theta Activity, Virtual Navigation and the Human Hippocampus. *Trends in Cognitive Sciences* 1999, 3, 403–406. https://doi.org/10.1007/978-3-642-41320-9_1.
- [68] Mizuhara, H. Wang, L. Kobayashi, K. Yamaguchi, Y. A long-range cortical network emerging with theta oscillation in a mental task, *Neuroreport* 2004, 15. 1233-8. 10.1097/01.wnr.0000126755.09715.b3,
- [69] Shou, G.; Ding, L. Frontal Theta EEG Dynamics in a Real-World Air Traffic Control Task. *Conf Proc IEEE Eng Med Biol Soc* 2013, 2013, 5594–5597. <https://doi.org/10.1109/EMBC.2013.6610818>.
- [70] Kahana, M. J.; Sekuler, R.; Caplan, J. B.; Kirschen, M.; Madsen, J. R. Human Theta Oscillations Exhibit Task Dependence during Virtual Maze Navigation. *Nature* 1999, 399 (6738), 781–784. <https://doi.org/10.1038/21645>.
- [71] Onton, J.; Delorme, A.; Makeig, S. Frontal Midline EEG Dynamics during Working Memory. *Neuroimage* 2005, 27 (2), 341–356. <https://doi.org/10.1016/j.neuroimage.2005.04.014>.
- [72] Abhang, P. A.; Gawali, B.; Mehrotra, S. C. Technical Aspects of Brain Rhythms and Speech Parameters; 2016. https://doi.org/10.1007/978-3-642-41320-9_1.
- [73] Amo, C.; de Santiago, L.; Barea, R.; López-Dorado, A.; Boquete, L. Analysis of Gamma-Band Activity from Human EEG Using Empirical Mode Decomposition. *Sensors (Basel)* 2017, 17 (5). <https://doi.org/10.3390/s17050989>.
- [74] Dimigen, O.; Valsecchi, M.; Sommer, W.; Kliegl, R. Human Microsaccade-Related Visual Brain Responses. *J. Neurosci.* 2009, 29 (39), 12321–12331. <https://doi.org/10.1523/JNEUROSCI.0911-09.2009>.
- [75] Bin, N.-R.; Song, H.; Wu, C.; Lau, M.; Sugita, S.; Eubanks, J. H.; Zhang, L. Continuous Monitoring via Tethered Electroencephalography of Spontaneous Recurrent Seizures in Mice. *Front Behav Neurosci* 2017, 11, 172. <https://doi.org/10.3389/fnbeh.2017.00172>.

- [76] Al-Fahoum, A. S.; Al-Fraihat, A. A. Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains. *ISRN Neurosci* 2014, 2014, 730218. <https://doi.org/10.1155/2014/730218>.
- [77] Manshoori, N.; Maleki, M.; Kayikçioglu, T. Frequency Analysis of EEG Signal during Watching 2D & 3D Movies Based on PLSR Classifier: A Comparison of Methods. 2017 *25th Signal Processing and Communications Applications Conference (SIU)* 2017, 1–4. https://doi.org/10.1007/978-3-642-41320-9_1
- [78] Segrave, R. A.; Cooper, N. R.; Thomson, R. H.; Croft, R. J.; Sheppard, D. M.; Fitzgerald, P. B. Individualized Alpha Activity and Frontal Asymmetry in Major Depression. *Clin EEG Neurosci* 2011, 42 (1), 45–52. <https://doi.org/10.1177/155005941104200110>.
- [79] Zhao, G.; Zhang, Y.; Ge, Y. Frontal EEG Asymmetry and Middle Line Power Difference in Discrete Emotions. *Front Behav Neurosci* 2018, 12, 225. <https://doi.org/10.3389/fnbeh.2018.00225>.
- [80] Ekpu, V. U.; Brown, A. K. The Economic Impact of Smoking and of Reducing Smoking Prevalence: Review of Evidence. *Tob Use Insights* 2015, 8, 1–35. <https://doi.org/10.4137/TUI.S15628>.
- [81] Gonzales, K.; Roeber, J.; Kanny, D.; Tran, A.; Saiki, C.; Johnson, H.; Yeoman, K.; Safranek, T.; Creppage, K.; Lepp, A.; et al. Alcohol-Attributable Deaths and Years of Potential Life Lost--11 States, 2006-2010. *MMWR Morb. Mortal. Wkly. Rep.* 2014, 63 (10), 213–216.
- [82] Eksi, Z. E.; Akgul, A.; Bozkurt, M. R. The Classification of EEG Signals Recorded in Drunk and Non-Drunk People; *Int J Comput Appl*, 2013. https://doi.org/10.1007/978-3-642-41320-9_1.
- [83] Wu Di; Chen Zhihua; Feng Ruifang; Li Guangyu; Luan Tian. Notice of Retraction: Study on Human Brain after Consuming Alcohol Based on EEG Signal. In *2010 3rd International Conference on Computer Science and Information Technology*; 2010; Vol. 5, pp 406–409. <https://doi.org/10.1109/ICCSIT.2010.5564084>.
- [84] Hanafiah, Z. M.; Taib, M. N.; Hamid, N. H. A. EEG Pattern of Smokers for Theta, Alpha and Beta Band Frequencies. *2010 IEEE Student Conference on Research and Development (SCoReD)* 2010, 320–323. https://doi.org/10.1007/978-3-642-41320-9_1.
- [85] Ko, L.-W.; Wei, C.-S.; Chen, S.-A.; Lin, C.-J. EEG-Based Motion Sickness Estimation Using Principal Component Regression. In *ICONIP*; 2011. https://doi.org/10.1007/978-3-642-41320-9_1.
- [86] Murugesan, M.; Sukanesh, R. Towards Detection of Brain Tumor in *Electroencephalogram Signals Using Support Vector Machines*; 2009. https://doi.org/10.1007/978-3-642-41320-9_1.

- [87] Samant, I. S.; Kanungo, G. K.; Mishra, S. K. Desired EEG Signals For Detecting Brain Tumor Using LMS Algorithm And *Feedforward Network*; 2012. https://doi.org/10.1007/978-3-642-41320-9_1.
- [88] Wang, L.; Xue, W.; Li, Y.; Luo, M.-L.; Huang, J.; Cui, W.-G.; Huang, C. Automatic Epileptic Seizure Detection in EEG Signals Using Multi-Domain Feature Extraction and Nonlinear Analysis. *Entropy* 2017, 19, 222. https://doi.org/10.1007/978-3-642-41320-9_1.
- [89] Elliott, J. C.; Gibbs, S. D. J. The Dyslexia Debate; 2012. https://doi.org/10.1007/978-3-642-41320-9_1.
- [90] Ozernov-Palchik, O.; Gaab, N. Tackling the “Dyslexia Paradox”: Reading Brain and Behavior for Early Markers of Developmental Dyslexia. *Wiley Interdiscip Rev Cogn Sci* 2016, 7 (2), 156–176. <https://doi.org/10.1002/wcs.1383>.
- [91] Perera, H.; Shiratuddin, M. F.; Wong, K. W. Review of EEG-Based Pattern Classification Frameworks for Dyslexia. *Brain Inform* 2018, 5 (2), 4. <https://doi.org/10.1186/s40708-018-0079-9>.
- [92] Klimesch, W.; Doppelmayr, M.; Wimmer, H.; Schwaiger, J.; Röhm, D.; Gruber, W.; Hutzler, F. Theta Band Power Changes in Normal and Dyslexic Children. *Clin Neurophysiol* 2001, 112 (7), 1174–1185. [https://doi.org/10.1016/s1388-2457\(01\)00545-4](https://doi.org/10.1016/s1388-2457(01)00545-4).
- [93] Koehler, S.; Lauer, P.; Schreppel, T.; Jacob, C.; Heine, M.; Boreatti-Hümmer, A.; Fallgatter, A. J.; Herrmann, M. J. Increased EEG Power Density in Alpha and Theta Bands in Adult ADHD Patients. *J Neural Transm (Vienna)* 2009, 116 (1), 97–104. <https://doi.org/10.1007/s00702-008-0157-x>.
- [94] Saad, J. F.; Kohn, M. R.; Clarke, S.; Lagopoulos, J.; Hermens, D. F. Is the Theta/Beta EEG Marker for ADHD Inherently Flawed? *J Atten Disord* 2018, 22 (9), 815–826. <https://doi.org/10.1177/1087054715578270>.
- [95] Alchalabi, A. E.; Shirmohammadi, S.; Eddin, A. N.; Elsharnouby, M. FOCUS: Detecting ADHD Patients by an EEG-Based Serious Game. *IEEE Transactions on Instrumentation and Measurement* 2018, 67, 1512–1520. https://doi.org/10.1007/978-3-642-41320-9_1.
- [96] Tan, H. G.; Kong, K. H.; Shee, C. Y.; Wang, C. C.; Guan, C. T.; Ang, W. T. Post-Acute Stroke Patients Use Brain-Computer Interface to Activate Electrical Stimulation. *Conf Proc IEEE Eng Med Biol Soc* 2010, 2010, 4234–4237. <https://doi.org/10.1109/IEMBS.2010.5627381>.
- [97] Birbaumer, N.; Ruiz, S.; Sitaram, R. Learned Regulation of Brain Metabolism. *Trends in Cognitive Sciences* 2013, 17, 295–302. https://doi.org/10.1007/978-3-642-41320-9_1.
- [98] Ruiz, S.; Buyukturkoglu, K.; Rana, M.; Birbaumer, N.; Sitaram, R. Real-Time fMRI Brain Computer Interfaces: Self-Regulation of Single Brain Regions to Networks. *Biol Psychol* 2014, 95, 4–20. <https://doi.org/10.1016/j.biopsycho.2013.04.010>.

- [99] Bertolucci, F.; Lamola, G.; Fanciullacci, C.; Artoni, F.; Panarese, A.; Micera, S.; Chisari, C. EEG Predicts Upper Limb Motor Improvement after Robotic Rehabilitation in *Chronic Stroke Patients*; 2018. https://doi.org/10.1007/978-3-642-41320-9_1.
- [100] Fok, S.; Schwartz, R.; Wronkiewicz, M.; Holmes, C.; Zhang, J.; Somers, T.; Bundy, D.; Leuthardt, E. An EEG-Based Brain Computer Interface for Rehabilitation and Restoration of Hand Control Following Stroke Using Ipsilateral Cortical Physiology. *Conf Proc IEEE Eng Med Biol Soc* 2011, 2011, 6277–6280. <https://doi.org/10.1109/IEMBS.2011.6091549>.
- [101] Wolpaw, J. R.; Birbaumer, N.; McFarland, D. J.; Pfurtscheller, G.; Vaughan, T. M. Brain-Computer Interfaces for Communication and Control. *Clin Neurophysiol* 2002, 113 (6), 767–791. [https://doi.org/10.1016/s1388-2457\(02\)00057-3](https://doi.org/10.1016/s1388-2457(02)00057-3).
- [102] Nafea, M.; Hisham, A. B.; Abdul-Kadir, N. A.; harun, F. K. C. Brainwave-Controlled System for Smart Home Applications. *2018 2nd International Conference on BioSignal Analysis, Processing and Systems (ICBAPS)* 2018, 75–80. https://doi.org/10.1007/978-3-642-41320-9_1.
- [103] Cheng, M.; Gao, X.; Gao, S.; Xu, D. Design and Implementation of a Brain-Computer Interface with High Transfer Rates. *IEEE Trans Biomed Eng* 2002, 49 (10), 1181–1186. <https://doi.org/10.1109/tbme.2002.803536>.
- [104] Guger, C.; Holzner, C.; Groenegrass, C.; Edlinger, G.; Slater, M. Brain Computer Interface for Virtual Reality Control. In *ESANN*; 2009. https://doi.org/10.1007/978-3-642-41320-9_1.
- [105] Mayaud, L.; Filipe, S.; Petegnief, L.; Rochecouste, O.; Congedo, M.; Robust Braincomputer interface for virtual Keyboard (RoBIK): project results. *IRBM, Elsevier Masson*, 2013, 34 (2), pp.131-138.
- [106] Corley, J.; Heaton, D.; Gray, J.; Carver, J. C.; Smith, R. BRAIN-COMPUTER INTERFACE VIRTUAL KEYBOARD FOR ACCESSIBILITY; 2012. https://doi.org/10.1007/978-3-642-41320-9_1.
- [107] Rahul, Y.; Sharma, R. K.; Paul, N. S. A REVIEW ON EEG CONTROL SMART WHEEL CHAIR, *International Journal of Advanced Research in Computer Science*; 2017. https://doi.org/10.1007/978-3-642-41320-9_1.
- [108] Vliet, M. van; Robben, A.; Chumerin, N.; Manyakov, N. V.; Combaz, A.; Hulle, M. M. V. Designing a Brain-Computer Interface Controlled Video-Game Using Consumer Grade EEG Hardware. *2012 ISSNIP Biosignals and Biorobotics Conference: Biosignals and Robotics for Better and Safer Living (BRC)* 2011, 1–6. https://doi.org/10.1007/978-3-642-41320-9_1.
- [109] Marchand, A.; Hennig-Thurau, T. Value Creation in the Video Game Industry: Industry Economics, Consumer Benefits, and Research Opportunities. *Journal of Interactive Marketing* 2013, 27 (3), 141–157. <https://doi.org/10.1016/j.intmar.2013.05.001>.
- [110] Khong, A.; Jiangnan, L.; Thomas, K. P.; Vinod, A. P. BCI Based Multi-Player 3-D Game Control Using EEG for Enhancing Attention and Memory. *2014 IEEE International*

- Conference on Systems, Man, and Cybernetics (SMC)* 2014, 1847–1852. https://doi.org/10.1007/978-3-642-41320-9_1.
- [111] Vecchiato, G.; Babiloni, F.; Astolfi, L.; Toppi, J.; Cherubino, P.; Dai, J.; Kong, W.; Wei, D. Enhance of Theta EEG Spectral Activity Related to the Memorization of Commercial Advertisings in Chinese and Italian Subjects. *2011 4th International Conference on Biomedical Engineering and Informatics (BMEI)* 2011, 3, 1491–1494. https://doi.org/10.1007/978-3-642-41320-9_1.
- [112] Ohme, R. K.; Reykowska, D.; Wiener, D.; Choromanska, A. Analysis of Neurophysiological Reactions to Advertising Stimuli by Means of EEG and Galvanic Skin Response Measures.; 2009. https://doi.org/10.1007/978-3-642-41320-9_1.
- [113] Stallings, W; Brown L. Computer security: Principles and practice-third edition, *William Stallings*, 2015
- [114] Sohankar, J.; Sadeghi, K.; Banerjee, A.; Gupta, S. K. S. E-BIAS: A Pervasive EEG-Based Identification and Authentication System. In *Q2SWinet@MSWiM*; 2015. https://doi.org/10.1007/978-3-642-41320-9_1.
- [115] Chuang, J. C.-I.; Nguyen, H.; Wang, C.; Johnson, B. I Think, Therefore I Am: Usability and Security of Authentication Using Brainwaves. In *Financial Cryptography Workshops*; 2013. <https://doi.org/10.5120/ijca2017914621>.
- [116] Cheron, G.; Petit, G.; Cheron, J.; Leroy, A.; Cebolla, A.; Cevallos, C.; Petieau, M.; Hoellinger, T.; Zarka, D.; Clarinval, A.-M.; et al. Brain Oscillations in Sport: Toward EEG Biomarkers of Performance. *Front Psychol* 2016, 7, 246. <https://doi.org/10.3389/fpsyg.2016.00246>.
- [117] Ghani, F.; Sultan, H.; Anwar, D.; Farooq, O.; Khan, Y. U. Classification of Wrist Movements Using EEG Signals; 2013. <https://doi.org/10.5120/ijca2017914621>.
- [118] Qi, W. EOG Artifacts Removal in EEG Measurements for Affective Interaction with Brain Computer Interface. *2012 Eighth International Conference on Intelligent Information Hiding and Multimedia Signal Processing* 2012, 471–475. <https://doi.org/10.5120/ijca2017914621>.
- [119] Maiorana, E.; Casals, J. S. i; Campisi, P. EEG Signal Preprocessing for Biometric Recognition. *Machine Vision and Applications* 2016, 27, 1351–1360. <https://doi.org/10.5120/ijca2017914621>.
- [120] Wu, D.; King, J.; Chuang, C.; Lin, C.; Jung, T. Spatial Filtering for EEG-Based Regression Problems in Brain-Computer Interface (BCI), *DataNova* 2017
- [121] Yang, B.; He, L.; Wang, Q.; Song, C.; Zhang, Y. A Preprocessing Method of EEG Based on EMD-ICA in BCI. In *Life System Modeling and Simulation*; Ma, S., Jia, L., Li, X., Wang, L., Zhou, H., Sun, X., Eds.; Communications in Computer and Information Science; Springer: Berlin, Heidelberg, 2014; pp 1–12. https://doi.org/10.1007/978-3-662-45283-7_1.

- [122]Radüntz, T.; Scouten, J.; Hochmuth, O.; Meffert, B. EEG Artifact Elimination by Extraction of ICA-Component Features Using Image Processing Algorithms. *J. Neurosci. Methods* 2015, 243, 84–93. <https://doi.org/10.1016/j.jneumeth.2015.01.030>.
- [123]Guruwareddy, A.; Narava, S. Artifact Removal from EEG Signals; EEG Signals. *International Journal of Computer Applications*. 77. 17-19. 10.5120/13543-1175. 2013. <https://doi.org/10.5120/13543-1175>.
- [124]Goh, S. K.; Abbass, H. A.; Tan, K. C.; Mamun, A. A.; Wang, C.; Guan, C. Automatic EEG Artifact Removal Techniques by Detecting Influential Independent Components. *IEEE Transactions on Emerging Topics in Computational Intelligence* 2017, 1, 270–279. <https://doi.org/10.5120/ijca2017914621>.
- [125]Elsayed, N.; Zaghloul, Z. S.; Bayoumi, M. A. Brain Computer Interface: EEG Signal Preprocessing Issues and Solutions; 2017. <https://doi.org/10.5120/ijca2017914621>.
- [126]Barua, S.; Begum, S. A Review on Machine Learning Algorithms in Handling EEG Artifacts; 2014. https://doi.org/10.1007/978-3-642-41320-9_1.
- [127]Fatourech, M.; Bashashati, A.; Ward, R. K.; Birch, G. E. EMG and EOG Artifacts in Brain Computer Interface Systems: A Survey. *Clinical Neurophysiology* 2007, 118, 480–494. https://doi.org/10.1007/978-3-642-41320-9_1.
- [128]Yang, B.; He, L.; Lin, L.; Wang, Q. Fast Removal of Ocular Artifacts from Electroencephalogram Signals Using Spatial Constraint Independent Component Analysis Based Recursive Least Squares in Brain-Computer Interface. *Frontiers of Information Technology & Electronic Engineering* 2015, 16, 486–496. <https://doi.org/10.1631/FITEE.1400299>.
- [129]Mannan, M. M. N.; Kamran, M. A.; Jeong, M. Y. Identification and Removal of Physiological Artifacts From Electroencephalogram Signals: A Review. *IEEE Access* 2018, 6, 30630–30652. https://doi.org/10.1007/978-3-642-41320-9_1.
- [130]Britton, J. W.; Frey, L. C.; Hopp, J. L.; Korb, P.; Koubeissi, M. Z.; Lievens, W. E.; Pestana-Knight, E. M.; St. Louis, E. K. *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants*; St. Louis, E. K., Frey, L. C., Eds.; American Epilepsy Society: Chicago, 2016.
- [131]Stone, D. B.; Tamburro, G.; Fiedler, P.; Haueisen, J.; Comani, S. Automatic Removal of Physiological Artifacts in EEG: The Optimized Fingerprint Method for Sports Science Applications. *Front. Hum. Neurosci.* 2018, 12. <https://doi.org/10.3389/fnhum.2018.00096>.
- [132]Tandle, A.; Jog, N.; D' Cunha, P.; Chheta, M. Classification of Artefacts in EEG Signal Recordings and EOG Artefact Removal Using EOG Subtraction. *Communications on Applied Electronics* 4 (1), 12–19.
- [133]McMenamin, B. W.; Shackman, A. J.; Maxwell, J. S.; Greischar, L. L.; Davidson, R. J. Validation of Regression-Based Myogenic Correction Techniques for Scalp and Source-

- Localized EEG. *Psychophysiology* 2009, 46 (3), 578–592. https://doi.org/10.1007/978-3-642-41320-9_1.
- [134] Yong, X.; Ward, R.; Birch, G. E. Facial EMG Contamination of EEG Signals: Characteristics and Effects of Spatial Filtering. *2008 3rd International Symposium on Communications, Control and Signal Processing* 2008, 729–734. https://doi.org/10.1007/978-3-642-41320-9_1.
- [135] Goncharova, I. I.; McFarland, D. J.; Vaughan, T. M.; Wolpaw, J. R. EMG Contamination of EEG: Spectral and Topographical Characteristics. *Clinical Neurophysiology* 2003, 114, 1580–1593. https://doi.org/10.1007/978-3-642-41320-9_1.
- [136] Whitham, E. M.; Pope, K. J.; Fitzgibbon, S. P.; Lewis, T. W.; Willoughby, J. O. Scalp Electrical Recording during Paralysis: Quantitative Evidence That EEG Frequencies above 20Hz Are Contaminated by EMG. *Clinical Neurophysiology* 2007, 118, 1877–1888. https://doi.org/10.1007/978-3-642-41320-9_1.
- [137] Urigüen, J. A.; García-Zapirain, B. EEG Artifact Removal-State-of-the-Art and Guidelines. *Journal of neural engineering* 2015, 12 (3), 031001. https://doi.org/10.1007/978-3-642-41320-9_1.
- [138] Cuong, N. K.; Ha, V. Q.; Hường, N. T. T.; Khoa, T. Q. D.; Tam, N. H. M.; Linh, H. Q.; Toi, V. V. Removing Noise and Artifacts from EEG Using Adaptive Noise Cancelator and Blind Source Separation; 2010. https://doi.org/10.1007/978-3-642-41320-9_1.
- [139] Ghanbari, A. A.; Kousarrizi, M. R. N.; Teshnehlal, M.; Aliyari, M. An Evolutionary Artifact Rejection Method For Brain Computer Interface Using ICA; 2013. https://doi.org/10.1007/978-3-642-41320-9_1.
- [140] Islam, M. K.; Rastegarnia, A.; Yang, Z. D. Methods for Artifact Detection and Removal from Scalp EEG: A Review. *Neurophysiologie Clinique/Clinical Neurophysiology* 2016, 46, 287–305. https://doi.org/10.1007/978-3-642-41320-9_1.
- [141] Nonte, M. W.; Hairston, W. D.; Gordon, S. M. Comparing EEG Artifact Detection Methods for Real-World BCI. In *HCI*; 2016. https://doi.org/10.1007/978-3-642-41320-9_1.
- [142] Levi, T.; Bonifazi, P.; Massobrio, P.; Chiappalone, M. Editorial: Closed-Loop Systems for Next-Generation Neuroprostheses. In *Front. Neurosci.*; 2018. https://doi.org/10.1007/978-3-642-41320-9_1.
- [143] Spuler, M.; Walter, A.; Rosenstiel, W.; Bogdan, M. Spatial Filtering Based on Canonical Correlation Analysis for Classification of Evoked or Event-Related Potentials in EEG Data. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2014, 22, 1097–1103. https://doi.org/10.1007/978-3-642-41320-9_1.
- [144] Sun, L.; Rieger, J.; Hinrichs, H. Maximum Noise Fraction (MNF) Transformation to Remove Ballistocardiographic Artifacts in EEG Signals Recorded during FMRI Scanning. *Neuroimage* 2009, 46 (1), 144–153. <https://doi.org/10.1016/j.neuroimage.2009.01.059>.

- [145]Maddirala, A. K.; Shaik, R. A. Separation of Sources From Single-Channel EEG Signals Using Independent Component Analysis. *IEEE Transactions on Instrumentation and Measurement* 2018, 67, 382–393. https://doi.org/10.1007/978-3-642-41320-9_1.
- [146]Yong, X.; Ward, R. K.; Birch, G. E. Artifact Removal in EEG Using Morphological Component Analysis. *2009 IEEE International Conference on Acoustics, Speech and Signal Processing* 2009, 345–348. https://doi.org/10.1007/978-3-642-41320-9_1.
- [147]Mouriño, J.; Millan, J. del R.; Cincotti, F.; Chiappa, S.; Jané, R.; Babiloni, F. Spatial Filtering in the Training Process of a Brain Computer Interface. *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society* 2001, 1, 639–642 vol.1. https://doi.org/10.1007/978-3-642-41320-9_1.
- [148](199) Binias, B.; Palus, H. Windowed Local Area Average Reference Filter for Increasing the Spatial Resolution of EEG Signals. *2016 21st International Conference on Methods and Models in Automation and Robotics (MMAR)* 2016, 403–408. https://doi.org/10.1007/978-3-642-41320-9_1.
- [149]Alhaddad, M. J. Common Average Reference (CAR) Improves P300 Speller; 2012. https://doi.org/10.1007/978-3-642-41320-9_1.
- [150]Essl, M. M.; Rappelsberger, P. EEG Coherence and Reference Signals: Experimental Results and Mathematical Explanations. *Medical and Biological Engineering and Computing* 1998, 36, 399–406. https://doi.org/10.1007/978-3-642-41320-9_1.
- [151]Xinyu, L.; Hong, W.; Shan, L.; Yan, C.; Li, S. Z. Adaptive Common Average Reference for in Vivo Multichannel Local Field Potentials. *Biomedical Engineering Letters* 2017, 7, 7–15. https://doi.org/10.1007/978-3-642-41320-9_1.
- [152]Daly, I.; Scherer, R.; Billinger, M.; Muller-Putz, G. R. FORCe: Fully Online and Automated Artifact Removal for Brain-Computer Interfacing. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2015, 23, 725–736. https://doi.org/10.1007/978-3-642-41320-9_1.
- [153]Nicolaou, N.; Nasuto, S. J. Automatic Artefact Removal from Event-Related Potentials via Clustering. *The Journal of VLSI Signal Processing Systems for Signal, Image, and Video Technology* 2007, 48, 173–183. https://doi.org/10.1007/978-3-642-41320-9_1.
- [154]Nolan, H.; Whelan, R.; Reilly, R. B. FASTER: Fully Automated Statistical Thresholding for EEG Artifact Rejection. *Journal of Neuroscience Methods* 2010, 192, 152–162. https://doi.org/10.1007/978-3-642-41320-9_1.
- [155]Mognon, A.; Jovicich, J.; Bruzzone, L.; Buiatti, M. ADJUST: An Automatic EEG Artifact Detector Based on the Joint Use of Spatial and Temporal Features. *Psychophysiology* 2011, 48 (2), 229–240. https://doi.org/10.1007/978-3-642-41320-9_1.

- [156] Jas, M.; Engemann, D. A.; Bekhti, Y.; Raimondo, F.; Gramfort, A. Autoreject: Automated Artifact Rejection for MEG and EEG Data. *Neuroimage* 2017, 159, 417–429. <https://doi.org/10.1016/j.neuroimage.2017.06.030>.
- [157] Tarrant, J.; Viczko, J.; Cope, H. Virtual Reality for Anxiety Reduction Demonstrated by Quantitative EEG: A Pilot Study. In *Front. Psychol.*; 2018. https://doi.org/10.1007/978-3-642-41320-9_1.
- [158] Nicolaou, N.; Nasuto, S. J. Robustness of Mutual Information to Inter-Subject Variability for Automatic Artefact Removal from EEG. *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference* 2005, 5991–5994. https://doi.org/10.1007/978-3-642-41320-9_1.
- [159] Mojena, R. Hierarchical Grouping Methods and Stopping Rules: An Evaluation. *Comput. J.* 1977, 20, 359–363. https://doi.org/10.1007/978-3-642-41320-9_1.
- [160] Lotte, F.; Miranda E.. A Tutorial on EEG Signal Processing Techniques for Mental State Recognition in Brain-Computer Interfaces, *Guide to Brain-Computer Music Interfacing* pp 133-161 (2015).
- [161] Ramoser, H.; Müller-Gerking, J.; Pfurtscheller, G. Optimal Spatial Filtering of Single Trial EEG during Imagined Hand Movement. *IEEE transactions on rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* 2000, 8 (4), 441–446. https://doi.org/10.1007/978-3-642-41320-9_1.
- [162] Xygonakis, I.; Athanasiou, A.; Pandria, N.; Kugiumtzis, D.; Bamidis, P. D. Decoding Motor Imagery through Common Spatial Pattern Filters at the EEG Source Space. In *Comp. Int. and Neurosc.*; 2018. https://doi.org/10.1007/978-3-642-41320-9_1.
- [163] Wang, Y.; Gao, S.; Gao, X. Common Spatial Pattern Method for Channel Selelction in Motor Imagery Based Brain-Computer Interface. *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference* 2005, 5392–5395. https://doi.org/10.1007/978-3-642-41320-9_1.
- [164] Purvi, G.; Raviraj, J.; Mriganka, S.; Hema, M. A Common Spatial Pattern Approach for Classification of Mental Counting and Motor Execution, *EEG: 10th International Conference, IHCI 2018*, 2018, Allahabad, India, December 7–9, 2018, Proceedings. 10.1007/978-3-030-04021-5_3.
- [165] Graimann, B.; Allison, B. Z.; Pfurtscheller, G. Brain-Computer Interfaces: Revolutionizing Human-Computer Interaction; 2013. https://doi.org/10.1007/978-3-642-41320-9_1.
- [166] Blankertz, B.; Losch, F.; Krauledat, M.; Dornhege, G.; Curio, G.; Müller, K.-R. The Berlin Brain-Computer Interface: Accurate Performance from First-Session in BCI-Naive Subjects. *IEEE Transactions on Biomedical Engineering* 2008, 55, 2452–2462. https://doi.org/10.1007/978-3-642-41320-9_1.
- [167] Gan, H.; Guangquan, L.; Meng, J.; Dingguo, Z.; Xiangyang, Z. Model based generalization analysis of common spatial pattern in brain computer interfaces. 2010. *Cognitive neurodynamics*. 4. 217-23. 10.1007/s11571-010-9117-x.

- [168] Lu, H.; Plataniotis, K. N.; Venetsanopoulos, A. N. Regularized Common Spatial Patterns with Generic Learning for EEG Signal Classification. *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* 2009, 6599–6602. https://doi.org/10.1007/978-3-642-41320-9_1.
- [169] Kai Keng Ang; Zheng Yang Chin; Haihong Zhang; Cuntai Guan. Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. In *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*; 2008; pp 2390–2397. <https://doi.org/10.1109/IJCNN.2008.4634130>.
- [170] Lei, X.; Yang, P.; Xu, P.; Liu, T.; Yao, D. Common Spatial Pattern Ensemble Classifier and Its Application in Brain-Computer Interface; 2009. https://doi.org/10.1007/978-3-642-41320-9_1.
- [171] Ge, S. M.; Wang, R.; Yu, D. Classification of Four-Class Motor Imagery Employing Single-Channel Electroencephalography. In *PloS one*; 2014. https://doi.org/10.1007/978-3-642-41320-9_1.
- [172] Osiak, Z. Historia Teorii Względności – Ciekawe Wyniki Po 1955 (In Polish); History of Relativity – Interesting Results After 1955 (In Polish); 2018. https://doi.org/10.1007/978-3-642-41320-9_1.
- [173] Offner, F. The EEG as Potential Mapping: The Value of the Average Monopolar Reference. *Electroencephalography and clinical neurophysiology* 1950, 2 (2), 213–214. https://doi.org/10.1007/978-3-642-41320-9_1.
- [174] McFarland, D. J.; McCane, L. M.; David, S. V.; Wolpaw, J. R. Spatial Filter Selection for EEG-Based Communication. *Electroencephalography and clinical neurophysiology* 1997, 103 (3), 386–394. https://doi.org/10.1007/978-3-642-41320-9_1.
- [175] Sidharth, M.; Sarkar, Uttam, S.; Subhash, T.; Sanjoy, D.; Devi, S.; Reshma, S.; Sasmita, P.; Menalsh. L.. Principal Component Analysis, 2017, *International Journal of Livestock Research*. 1. 10.5455/ijlr.20170415115235
- [176] Peterson, D. A.; Knight, J. N.; Kirby, M. J.; Anderson, C. W.; Thaut, M. H. Feature Selection and Blind Source Separation in an EEG-Based Brain-Computer Interface. *EURASIP Journal on Advances in Signal Processing* 2005, 2005, 1–13. https://doi.org/10.1007/978-3-642-41320-9_1.
- [177] (166) Knight, J. N. Signal Fraction Analysis and Artifact Removal in Eeg Submitted By; 2003. https://doi.org/10.1007/978-3-642-41320-9_1.
- [178] Tu, T. M.; Shyu, H. C.; Lee, C. H., A Visual Disk Approach for Determining Data Dimensionality in Hyperspectral Imagery, submitted to *IEEE Trans. on Geoscience and Remote Sensing*
- [179] Zhang, Z.; Li, H.; Mandic, D. P. Blind Source Separation and Artefact Cancellation for Single Channel Bioelectrical Signal. *2016 IEEE 13th International Conference on Wearable*

- and Implantable Body Sensor Networks (BSN)* 2016, 177–182. https://doi.org/10.1007/978-3-642-41320-9_1.
- [180] Wolter, M.; Metody analizy wielu zmiennych w fizyce wysokich energii. Recenzent: Malecki P., 2012, ISBN 978-83-934248-2-5
- [181] Park, H.-M.; Oh, S.-H.; Lee, S. Y. A Modified Infomax Algorithm for Blind Signal Separation. *Neurocomputing* 2006, 70, 229–240. https://doi.org/10.1007/978-3-642-41320-9_1.
- [182] Stone, J. V. Independent Component Analysis: An Introduction. *Trends in Cognitive Sciences* 2002, 6 (2), 59–64. [https://doi.org/10.1016/S1364-6613\(00\)01813-1](https://doi.org/10.1016/S1364-6613(00)01813-1).
- [183] Mutihac, R.; Hulle, M. M. V. Comparison of Principal Component Analysis and Independent Component Analysis for Blind Source Separation; 2004, *Romanian Reports in Physics*, https://doi.org/10.1007/978-3-642-41320-9_1.
- [184] Hyvärinen, A. Independent Component Analysis: Recent Advances. In *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences*; 2013. https://doi.org/10.1007/978-3-642-41320-9_1.
- [185] Naik, G.R., Introduction: Independent Component Analysis, Submitted: August 10th 2012, Reviewed: August 13th 2012, Published: October 10th 2012, DOI: 10.5772/52324
- [186] Choi, S.; Cichecki, A. Blind Source Separation and Independent Component Analysis : A Review; 2004. *Neural Inf. Process. Lett. Rev.* 6. https://doi.org/10.1007/978-3-642-41320-9_1.
- [187] Starck, J.-L.; Elad, M.; Donoho, D. L. Redundant Multiscale Transforms and Their Application for Morphological Component Separation; 2004. https://doi.org/10.1007/978-3-642-41320-9_1.
- [188] Starck, J.-L.; Moudden, Y.; Bobin, J.; Elad, M.; Donoho, D. L. Morphological Component Analysis. In *SPIE Optics + Photonics*; 2005. <https://doi.org/10.1117/12.615237>.
- [189] Mahapatra, A. G.; Singh, B.; Wagatsuma, H.; Horio, K. Epilepsy EEG Classification Using Morphological Component Analysis. *EURASIP Journal on Advances in Signal Processing* 2018, 2018, 1–12. https://doi.org/10.1007/978-3-642-41320-9_1.
- [190] Langlois, D.; Chartier, S.; Gosselin, D. An Introduction to Independent Component Analysis: InfoMax and FastICA Algorithms; 2010. https://doi.org/10.1007/978-3-642-41320-9_1.
- [191] Héroult, J.; Jutten, C. Space or Time Adaptive Signal Processing by Neural Network Models; 1987. https://doi.org/10.1007/978-3-642-41320-9_1.
- [192] Tharwat, A. Independent Component Analysis: An Introduction. *Applied Computing and Informatics* 2018. <https://doi.org/10.1016/j.aci.2018.08.006>.

- [193] Hyvärinen, A.; Karhunen, J.; Oja, E. *Independent Component Analysis*; John Wiley & Sons, 2004.
- [194] Comon, P. Independent Component Analysis, A New Concept? *Signal Processing* 1994, 36, 287–314. https://doi.org/10.1007/978-3-642-41320-9_1.
- [195] Fan C., Wang B., Ju H. A New FastICA Algorithm with Symmetric Orthogonalization. *IEEE*. 2006, s. 2058-2061
- [196] Balanda, K. P.; MacGillivray, H. L. Kurtosis: A Critical Review; 1988. https://doi.org/10.1007/978-3-642-41320-9_1.
- [197] Decarlo, L. T. On the Meaning and Use of Kurtosis.; 1997. https://doi.org/10.1007/978-3-642-41320-9_1.
- [198] Dronamraju, K. rao. Erwin Schrödinger and the Origins of Molecular Biology. *Genetics* 1999, 153 (3), 1071–1076. https://doi.org/10.1007/978-3-642-41320-9_1.
- [199] Collell, G.; Fauquet, J. Brain Activity and Cognition: A Connection from Thermodynamics and Information Theory. In *Front. Psychol.*; 2015. https://doi.org/10.1007/978-3-642-41320-9_1.
- [200] (186) Brillouin, L. The Negentropy Principle of Information; 1953, *Journal of Applied Physics*, Vol. 24, No. 9, 1953, pp. 1152-1163. https://doi.org/10.1007/978-3-642-41320-9_1.
- [201] Li, X.-L.; Adali, T. Independent Component Analysis by Entropy Bound Minimization. *IEEE Transactions on Signal Processing* 2010, 58 (10), 5151–5164. <https://doi.org/10.1109/TSP.2010.2055859>.
- [202] Batina, L.; Gierlichs, B.; Prouff, E.; Rivain, M.; Standaert, F.-X.; Veyrat-Charvillon, N. Mutual Information Analysis: A Comprehensive Study. *Journal of Cryptology* 2010, 24, 269–291. https://doi.org/10.1007/978-3-642-41320-9_1.
- [203] Wu, J.; Gupta, S.; Bajaj, C. L. Higher Order Mutual Information Approximation for Feature Selection. *ArXiv* 2016, *abs/1612.00554*. https://doi.org/10.1007/978-3-642-41320-9_1.
- [204] Mazucheli, J.; Menezes, A. F. B.; Nadarajah, S. Mle.Tools: An R Package for Maximum Likelihood Bias Correction; 2017. https://doi.org/10.1007/978-3-642-41320-9_1.
- [205] Hyvärinen, A.; Oja E. A Fast Fixed-Point Algorithm for Independent Component Analysis. *Neural Computation*, 9(7):1483-1492, 1997
- [206] Miettinen, J.; Matilainen, M.; Nordhausen, K.; Taskinen, S. Extracting Conditionally Heteroskedastic Components Using Independent Component Analysis. *Journal of Time Series Analysis* n/a (n/a). <https://doi.org/10.1111/jtsa.12505>.
- [207] Tichavský, P.; Koldovský, Z.; Oja, E. Performance Analysis of the FastICA Algorithm and Cramér-Rao Bounds for Linear Independent Component Analysis; *IEEE TRANSACTIONS*

- ON SIGNAL PROCESSING*. 2006, nr 54. s. 1189-1203, 2010. https://doi.org/10.1007/978-3-642-41320-9_1.
- [208] Linsker, R. Self-Organization in a Perceptual Network. *Computer* 1988, 21, 105–117. https://doi.org/10.1007/978-3-642-41320-9_1.
- [209] Bell A. J. Sejnowski T. J. An information-maximisation approach to blind separation and blind deconvolution. *Journal Neural Computation*. 1995, nr 7. s. 1129-1159
- [210] Naik G., Kumar D. An Overview of Independent Component Analysis and Its Applications. *Informatica*. 2011, s. 63-81
- [211] Raimondo F., Kamienkowski J. E., Sigman M., Slezak D. F. CUDAICA: GPU Optimization of Infomax-ICA EEG Analysis. *Computational Intelligence and Neuroscience*, 2012
- [212] Karhunen J. Neural approaches to independent component analysis and source separation. *Proc 4th European Symposium on Artificial Neural Networks (ESANN '96)*, 1996
- [213] Rejer I., Górski P. *Independent Component Analysis for EEG data preprocessing - algorithms comparison*. Proceedings of the 12th International Conference on Computer Information Systems and Industrial Management Applications CISIM 2013. Lectures Notes in Artificial Intelligence. Springer, 2013
- [214] Abdur-Rahim, J. A.; Ogawa, T.; Hirayama, J.; Ishii, S. Database-Driven Artifact Detection Method for EEG Systems with Few Channels (DAD). *2014 IEEE Biomedical Circuits and Systems Conference (BioCAS) Proceedings* 2014, 5–8. https://doi.org/10.1007/978-3-642-41320-9_1.
- [215] Jiang, X.; Bian, G.-B.; Tian, Z. Removal of Artifacts from EEG Signals: A Review. In *Sensors*; 2019. https://doi.org/10.1007/978-3-642-41320-9_1.
- [216] Chavez, M.; Grosselin, F.; Bussalib, A.; De Vico F.; Navarro-Sune, X. Surrogate-Based Artifact Removal From Single-Channel EEG, *2017 IEEE Transactions on Neural Systems and Rehabilitation Engineering*. PP. 10.1109/TNSRE.2018.2794184.
- [217] Rejer, I.; Cieszyński L.. Independent component analysis for a low-channel SSVEP-BCI *Pattern Analysis and Applications* 22 (2018): 47-62.
- [218] Valderrama, J. T.; Torre, A. de la; Dun, B. van. An Automatic Algorithm for Blink-Artifact Suppression Based on Iterative Template Matching: Application to Single Channel Recording of Cortical Auditory Evoked Potentials. *Journal of neural engineering* 2018, 15 (1), 016008. https://doi.org/10.1007/978-3-642-41320-9_1.
- [219] Chen, X.; Liu, A.; Peng, H.; Ward, R. K. A Preliminary Study of Muscular Artifact Cancellation in Single-Channel EEG. In *Sensors*; 2014. https://doi.org/10.1007/978-3-642-41320-9_1.
- [220] Chen, X.; He, C.; Peng, H. Removal of Muscle Artifacts from Single-Channel EEG Based on Ensemble Empirical Mode Decomposition and Multiset Canonical Correlation Analysis.

- J. Applied Mathematics* 2014, 2014, 261347–261347. https://doi.org/10.1007/978-3-642-41320-9_1.
- [221] James, C. J.; Lowe, D. Single Channel Analysis of Electromagnetic Brain Signals through ICA in a Dynamical Systems Framework. *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society* 2001, 2, 1974–1977 vol.2. https://doi.org/10.1007/978-3-642-41320-9_1.
- [222] Sharpley, R.; Vatchev, V.. Analysis of the Intrinsic Mode Functions, 2006 *Constructive Approximation*. 24. 17-47. 10.1007/s00365-005-0603-z.
- [223] Ma, Z.; Wen, G.; Jiang, C. EEMD Independent Extraction for Mixing Features of Rotating Machinery Reconstructed in Phase Space. In *Sensors*; 2015. https://doi.org/10.1007/978-3-642-41320-9_1.
- [224] Mijovic, B.; Vos, M. D.; Gligorijevic, I.; Huffel, S. V. Combining EMD with ICA for Extracting Independent Sources from Single Channel and Two-Channel Data. *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology* 2010, 5387–5390. https://doi.org/10.1007/978-3-642-41320-9_1.
- [225] Bhatia, D.; Bandhu, D. Mathematical Modeling and Simulation of Knee Ankle Muscles for Different Locomotion Activities; 2010. https://doi.org/10.1007/978-3-642-41320-9_1.
- [226] Chandra, N.; Dey, S.; Shankar, S.; Kumar, R. An Evaluation to the Effects of Correlation on Pseudo Noise Sequences; 2015. https://doi.org/10.1007/978-3-642-41320-9_1.
- [227] Usoro, A. E. Some Basic Properties of Cross-Correlation Functions of n-Dimensional Vector Time Series; 2015. https://doi.org/10.1007/978-3-642-41320-9_1.
- [228] Asuero, A. G.; Sayago, A.; Gonzalez, A. G. The Correlation Coefficient: An Overview; 2006. https://doi.org/10.1007/978-3-642-41320-9_1.
- [229] Górski P., Porównanie algorytmów analizy składowych niezależnych w usuwaniu szumu z wielu sygnałów śpiewu, *Metody komputerowe w zastosowaniu do analizy i wspierania kształcenia głosu śpiewaczego*, red. nauk. Edward Półrolniczak, 2014
- [230] Górski P., Separacja sygnałów śpiewu metodą analizy składowych niezależnych, *Metody komputerowe w zastosowaniu do analizy i wspierania kształcenia głosu śpiewaczego*, red. nauk. Edward Półrolniczak, 2014
- [231] Rejer I. *EEG feature selection for BCI based on motor imaginary task*. Foundation of Computer Decision Sciences. 2012, nr 37. s. 283–292
- [232] Rejer, I.; Górski, P. Benefits of ICA in the Case of a Few Channel EEG. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* 2015, 7434–7437. https://doi.org/10.1007/978-3-642-41320-9_1.
- [233] Tibshirani, R.. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58(1):267–288, 1996.

- [234]Rejer, I.; Górski, P. ICA for Detecting Artifacts in a Few Channel BCI. In *IDEAL*; 2015. https://doi.org/10.1007/978-3-642-41320-9_1.
- [235]Renard, Y.; Lotte, F.; Gibert, G.; Congedo, M.; Maby, E.; Delannoy, V.; Bertrand, O.; Lécuyer, A. OpenViBE: An Open-Source Software Platform to Design, Test, and Use BrainComputer Interfaces in Real and Virtual Environments. *PRESENCE: Teleoperators and Virtual Environments* 2010, 19, 35–53. https://doi.org/10.1007/978-3-642-41320-9_1.
- [236]Leonides C., Digital Signal Processing Systems: Implementation Techniques, Volume 68, 1st Edition *Advances in Theory and Applications*, Serial Editors:, Hardcover ISBN: 9780120127689, eBook ISBN: 9780080529844, Imprint: Academic Press, Published Date: 11th May 1995, pp: 174, 256-257
- [237]Gustafsson, F. Determining the Initial States in Forward-Backward Filtering. *IEEE Transactions on Signal Processing* 1996, 44 (4), 988–992. <https://doi.org/10.1109/78.492552>.
- [238]Schalk, G.; McFarland, D. J.; Hinterberger, T.; Birbaumer, N.; Wolpaw, J. R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering* 2004, 51 (6), 1034–1043. <https://doi.org/10.1109/TBME.2004.827072>.
- [239]Goldberger, A. L.; Amaral, L. A.; Glass, L.; Hausdorff, J. M.; Ivanov, P. C.; Mark, R. G.; Mietus, J. E.; Moody, G. B.; Peng, C. K.; Stanley, H. E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 2000, 101 (23), E215-220. <https://doi.org/10.1161/01.cir.101.23.e215>.
- [240]Jasper, H. H. The ten-twenty electrode system of the international federation in electroencephalography and clinical neurophysiology, *EEG Journal*, Vol. 10. pp: 371–375, 1958

SPIS RYSUNKÓW

Rysunek 1.1.1	a) Fotografia z aparaturą EEG z elektrodami z czasów Bergera, 1926 rok (źródło: https://www.mpiwg-berlin.mpg.de/resrep00_01/Jahresbericht_2_5_section.html), b) Współczesna aparatura do rejestracji sygnału EEG, przedstawiony model to: NEURO PRAX® EEG, (źródło: https://www.neurocaregroup.com/neuro_prax_eeg.html).....	11
Rysunek 1.1.2	Rozmieszczenie płatów mózgowych u człowieka. Źródło: http://www.anatomia.gmo.pl/ukl_ner.html	12
Rysunek 1.1.3	Rozmieszczenie oraz nazewnictwo 21 elektrod EEG według systemu 10-20. Źródło: http://thomaskosch.com/index.php/2016/09/28/visualizing-real-time-brain-localization-in-3d/	12
Rysunek 1.1.4	Montaż (a) monopolarny oraz (b) bipolarny. Źródło: https://neupsykey.com/electroencephalographic-electrodes-channels-and-montages-and-how-they-are-chosen/	13
Rysunek 1.2.1	Jedna sekunda zarejestrowanej próbki surowego sygnału EEG. Źródło: https://pdfs.semanticscholar.org/7e4c/65c0360c3cc35640ccbde44fc66f539bdc0d.pdf?_ga=2.203412051.371460869.1554716859-2058687032.1552914876	14
Rysunek 1.2.2	Sygnał EEG zarejestrowany u osoby dorosłej w stanie czuwania, przedstawiający asynchroniczne wyładowania iglicowe m.in. w obszarze ciemieniowym oraz skroniowym. Źródło: https://www.researchgate.net/publication/233536748_22q112_Microduplication_syndrome_and_epilepsy_with_continuous_spikes_and_waves_during_sleep_CSWS_A_case_report_and_review_of_the_literature/figures?lo=1	15
Rysunek 1.2.3	Widmo mocy sygnału EEG, podzielone na pasma częstotliwości, kolejno: delta, teta, alfa, beta. Źródło: https://www.researchgate.net/publication/272147753_Mathematical_Modeling_of_Human_Brain_Neuronal_Activity_in_the_Absence_of_External_Stimuli/figures?lo=1	16
Rysunek 1.2.4	Związek między domeną czasu i częstotliwości a) Sygnał w dziedzinie czasu b) Sygnał w dziedzinie częstotliwości c) Trójwymiarowy układ współrzędnych czas-częstotliwość-amplituda. Źródło: https://www.researchgate.net/figure/Figure2The-relationship-between-the-time-and-frequency-domains-a-Time-domain-view-b_fig1_280923204	17
Rysunek 1.3.1	Fale mózgowie w różnych pasmach częstotliwości (delta, teta, alfa, beta oraz gamma) Źródło: http://yogamudra.pl/wp-content/uploads/2014/06/fale-mozgowe.jpg	18
Rysunek 2.3.1	Schemat blokowy opisujący kolejne etapy metody FASTER Źródło:	

	http://www.tara.tcd.ie/handle/2262/41103	45
Rysunek 3.1.1	Przykład problemu przyjęcia cocktailowego, Źródło: https://www.statsoft.pl/textbook/graphics/Speakers.gif	54
Rysunek 3.1.2	Najczęściej stosowane podejścia do rozkładu obserwowanych zmiennych losowych na statystycznie niezależne zmienne losowe. Źródło: opracowanie własne.....	57
Rysunek 3.1.3	Ilustracja kurtozy. Linie przerywane pokazują rozkłady normalne, natomiast linie ciągłe przedstawiają rozkłady z kurtozą dodatnią - leptokurtyczną (a) i kurtozą ujemną - platokurtyczną (b). Źródło: http://www.columbia.edu/~ld208/psymeth97.pdf	59
Rysunek 3.1.4	Wielowymiarowy rozkład dwóch sygnałów o rozkładzie Gaussa. Źródło: https://www.semanticscholar.org/paper/Independent-component-analysis%3A-algorithms-and-Hyv%C3%A4rinen-Oja/577d19a115f9ef6f002483fcf88adbb3b5479556/figure/6	63
Rysunek 3.2.1	Korelacja liczby japońskich samochodów osobowych sprzedawanych w USA oraz liczby samobójstw w wyniku zderzenia pojazdu silnikowego. Korelacja: 93.57% Źródło: http://www.tylervigen.com/spurious-correlations	65
Rysunek 3.3.1	Ilustracja przedstawiająca przykład niekompletnego modelu ICA, w której liczba źródeł jest większa od liczby obserwacji. Źródło: https://pdfs.semanticscholar.org/4b0b/39fcd83492a192a2f3385151575837f7047.pdf?_ga=2.151192383.722134934.1560240146-2058687032.1552914876	71
Rysunek 3.3.2	Ilustracja przedstawiająca przykład nadkompletnego modelu ICA, w której liczba źródeł jest mniejsza od liczby obserwacji. Źródło: https://pdfs.semanticscholar.org/4b0b/39fcd83492a192a2f3385151575837f7047.pdf?_ga=2.151192383.722134934.1560240146-2058687032.1552914876	72
Rysunek 4.1.1	Sygnały źródłowe. Źródło: Opracowanie własne.....	80
Rysunek 4.1.2	Sygnały uzyskane po przeprowadzeniu procesu mieszania zgodnie ze wzorem 4.1.1. Źródło: Opracowanie własne.....	81
Rysunek 4.1.1.1	Składowe obliczone za pomocą algorytmu FastICA w wersji symetrycznej. Źródło: Opracowanie własne.....	83
Rysunek 4.2.1	Schemat eksperymentu przedstawionego na drugim konkursie BCI. Źródło: https://www.bbci.de/competition/ii/#datasets	87
Rysunek 4.2.2	Schemat montażu elektrod do rejestracji danych do eksperymentu przedstawionego na drugim konkursie BCI. Źródło: https://www.bbci.de/competition/ii/#datasets	88
Rysunek 5.1.1	Schemat blokowy przedstawiający lewą gałąź algorytmu metody MAICA. Źródło: opracowanie własne.....	106
Rysunek 5.1.2	Schemat blokowy przedstawiający prawą gałąź algorytmu metody MAICA. Źródło: opracowanie własne.....	107
Rysunek 5.1.3	Zasada działania filtru dolnoprzepustowego typu FIR; a) filtr z przesunięciem fazowym; b) filtr zero-fazowy. Źródło: opracowanie własne.....	108

Rysunek 5.2.1	Algorytm doboru parametrów procesu filtrowania; algorytm zwraca wektor L (wektor rozmiarów okien kolejnych filtrów).....	114
Rysunek 6.1.1	Oryginalne sygnały sinusoidalne. Źródło: opracowanie własne.	118
Rysunek 6.1.2	Liniowa kombinacja źródeł sinusoidalnych przedstawionych na Rysunku 6.1.1 w proporcjach przedstawionych we Wzorze: 6.1.1. Źródło: opracowanie własne.	118
Rysunek 6.1.3	Zestaw składowych zwróconych przez algorytm MAICA (ICA1, ICA2, ..., ICA10) uruchomiony z domyślnymi parametrami: $P2=0.6$, $P1=0.97$, and $P3=0.4$. Źródło: opracowanie własne.	119
Rysunek 6.1.4	Zestaw składowych zwróconych przez algorytm MAICA (ICA1, ICA2, ..., ICA14) uruchomiony z parametrami: $P2=0.7$, $P1=0.97$, i $P3=0.2$. Źródło: opracowanie własne.	121
Rysunek 6.1.5	Zestaw składowych zwróconych przez algorytm MAICA (ICA1, ICA2,..., ICA6) uruchomiony z parametrami: $P2 = 0.2$, $P1= 0.97$ i $P3= 0.99$. Źródło: opracowanie własne.	122
Rysunek 6.1.6	Zestaw składowych zwróconych przez metodę DE, $s = 30$, $d = 4$ (10 sygnałów na wejściu algorytmu FastICA). Źródło: opracowanie własne.....	124
Rysunek 6.1.7	Zestaw komponentów zwróconych przez metodę DE: $s=2$, $d=46$ (86 sygnałów na wejściu do algorytmu FastICA). Źródło: opracowanie własne.	127
Rysunek 6.1.8	Zestaw składowych zwróconych przez metodę SCICA dla liczby bloków równej 5 (10 sygnałów na wejściu algorytmu FastICA). Źródło: opracowanie własne.....	127
Rysunek 6.1.9	Zestaw składowych zwróconych przez metodę EEMD-ICA dla 4 funkcji IMF oraz 20%-wego poziomu szumu (10 sygnałów na wejściu algorytmu FastICA). Źródło: opracowanie własne.....	128
Rysunek 6.1.10	Zestaw składowych zwróconych przez metodę WICA dla 4 poziomej dekompozycji (10 sygnałów na wejściu algorytmu FastICA). Źródło: opracowanie własne.....	130
Rysunek 6.2.1	Fragment sygnału EEG zarejestrowanego w pięciu wybranych kanałach (Oz, Cz, Fpz, T8, T7). Źródło: opracowanie własne.....	132
Rysunek 6.2.2	Składowe wyjściowe zwrócone przez algorytm FastICA (po zastosowaniu algorytmu MAICA) w połączeniu z oryginalnymi sygnałami; przedstawiono sześć wybranych par (4 o wysokiej i 2 o niskiej korelacji). Źródło: opracowanie własne.....	133
Rysunek 6.2.3	Składowe wynikowe zwrócone przez algorytm FastICA (po zastosowaniu MAICA) połączone ze składowymi wynikowymi zwróconymi przez algorytm FastICA zastosowany bezpośrednio na 64 oryginalnych sygnałach; przedstawiono 5 losowo wybranych par. Źródło: opracowanie własne..	135
Rysunek 6.2.4	Najbardziej charakterystyczne składowe wyjściowe zwrócone przez algorytm FastICA dla zestawu 64 oryginalnych sygnałów. Źródło: opracowanie własne.....	136
Rysunek 6.2.5	Najbardziej charakterystyczne składowe wyjściowe zwrócone przez algorytm FastICA dla zestawu 60 sygnałów utworzonych za pomocą algorytmu MAICA. Źródło: opracowanie własne.....	136

SPIS TABEL

Tabela 2.1.1	Podstawowe rodzaje artefaktów zakłócających sygnał EEG. Źródła: https://www.researchgate.net/publication/325495058_Identification_and_Removal_of_Physiological_Artifacts_from_Electroencephalogram_Signals_A_Review https://www.researchgate.net/publication/275955830_Methods_for_Artifact_Detection_and_Removal_from_Scalp_EEG_A_Review	32
Tabela 4.1.1	Współczynnik korelacji sygnałów źródłowych oraz sygnałów uzyskanych na wyjściu algorytmu FastICA.....	82
Tabela 4.1.1.1	Współczynniki korelacji sygnałów oryginalnych oraz składowych ICA otrzymane w badaniu pierwszym.....	83
Tabela 4.1.2.1	Współczynniki korelacji sygnałów oryginalnych oraz składowych ICA otrzymane w badaniu drugim.....	84
Tabela 4.1.2.2	Czas działania algorytmów ICA (każdy algorytm był uruchomiony trzykrotnie)	85
Tabela 4.2.1.1	Średnia dokładność klasyfikacji uzyskana dla podzbiorów o różnej liczbie cech, wyznaczona dla danych surowych oraz danych przetworzonych przy wykorzystaniu trzech algorytmów ICA (D – dokładność, S – odchylenie standardowe).....	89
Tabela 4.2.2.1	Dokładność klasyfikacji; w przypadku kolumny ‘Surowe sygnały’ składowa 1 oznacza kanał C3, składowa 2 – kanał Cz, natomiast składowa 3 – kanał C4.....	91
Tabela 4.2.2.2	Korelacja sygnałów surowych oraz składowych ICA obliczonych za pomocą algorytmu FastICA w wersji symetrycznej.....	92
Tabela 4.2.2.3	Korelacja sygnałów surowych oraz składowych ICA obliczonych za pomocą algorytmu FastICA w wersji deflacyjnej.....	93
Tabela 4.2.2.4	Korelacja sygnałów surowych oraz składowych ICA obliczonych za pomocą algorytmu Infomax.....	93
Tabela 4.2.2.5	Dokładność klasyfikacji po skorelowaniu składowych ICA z sygnałami zarejestrowanymi w poszczególnych kanałach.....	93
Tabela 4.2.3.1	Dokładność klasyfikacji uzyskana dla każdej kombinacji sygnałów odpowiadających kanałom C3, Cz i C4 dla wszystkich zestawów danych: oryginał, ICA3 i ICA6.....	96
Tabela 4.2.3.2	Zestawy najbardziej istotnych cech wybranych za pomocą metody LASSO dla różnych kombinacji sygnałów pochodzących ze zbioru danych ICA6.....	97
Tabela 4.3.1	Dokładność klasyfikacji uzyskana dla pary kanałów C3-C4 (pierwszy wiersz) oraz 15 zestawów składowych ICA (pozostałe wiersze) w kolejnych rundach testowych; dwie ostatnie kolumny przedstawiają uśrednioną dokładność dla 5 rund testowych i wzrost dokładności po zastosowaniu algorytmu FastICA.....	103
Tabela 6.1.1	Źródłowe sygnały sinusoidalne.....	117

Tabela 6.1.2	Korelacja pomiędzy składowymi zwróconymi przez algorytm MAICA oraz sinusoidami źródłowymi (w tabeli przedstawiono tylko pary sygnałów o najwyższej korelacji)	119
Tabela 6.1.3	Korelacja pomiędzy składowymi zwróconymi przez algorytm MAICA oraz sinusoidami źródłowymi (parametry algorytmu: $P2=0.7$, $PI=0.97$ i $P3=0.2$)	120
Tabela 6.1.4	Korelacja pomiędzy składowymi zwróconymi przez algorytm MAICA oraz sinusoidami źródłowymi (parametry algorytmu: $P2 = 0.2$, $PI= 0.97$ i $P3= 0.99$)	122
Tabela 6.1.5	Korelacja pomiędzy składowymi zwróconymi przez metodę DE dla parametrów: $s=30$, $d=4$ (10 sygnałów na wejściu do algorytmu FastICA)	123
Tabela 6.1.6	Korelacja pomiędzy składowymi zwróconymi przez metodę DE dla parametrów: $s=2$, $d=46$ (86 sygnałów na wejściu do algorytmu FastICA)	124
Tabela 6.1.7	Korelacja pomiędzy składowymi zwróconymi przez metodę SCICA dla liczby bloków równej 5 (10 sygnałów na wejściu do algorytmu FastICA)	127
Tabela 6.1.8	Korelacja pomiędzy składowymi zwróconymi przez metodę EEMD-ICA dla 4 funkcji IMF oraz 20%-wego poziomu szumu (10 sygnałów na wejściu do algorytmu FastICA)	128
Tabela 6.1.9	Korelacja pomiędzy składowymi zwróconymi przez metodę WICA przy 4 stopniowej dekompozycji (10 sygnałów na wejściu do algorytmu FastICA)	129
Tabela 6.1.10	Podsumowanie wyników uzyskanych za pomocą wszystkich 5 metod.....	131
Tabela 6.3.1	Wektory parametrów filtrów wygładzających wyznaczone za pomocą metody MAICA dla każdego podmiotu oraz kanału.....	140
Tabela 6.3.2	Dokładność klasyfikacji uzyskana dla poszczególnych podmiotów po zastosowaniu klasyfikatora C_classic oraz C_MAICA w sesji treningowo-walidacyjnej oraz testowej.....	141
Tabela 6.3.3	Czas przetwarzania potrzebny do przeprowadzenia klasyfikacji jednej próby z zastosowaniem algorytmu MAICA oraz bez niego.....	143