

POLITECHNIKA WARSZAWSKA

DYSCYPLINA NAUKOWA INFORMATYKA TECHNICZNA
I TELEKOMUNIKACJA
DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

Rozprawa doktorska

mgr inż. Renata Maria Plucińska

**Weryfikacja tożsamości osób na podstawie analizy widma
sygnału EEG i jego podpasm
z wykorzystaniem metod uczenia maszynowego**

Promotor
dr hab. inż. Konrad Jędrzejewski, profesor uczelni

WARSZAWA 2023

PODZIĘKOWANIA

Pragnę podziękować mojemu promotorowi, dr. hab. inż. Konradowi Jędrzejewskiemu, profesorowi uczelni, którego nieocenione wsparcie, wiedza i cenne wskazówki odegrały kluczową rolę w mojej drodze naukowej. Dziękuję za poświęcony czas i motywację.

Dziękuję również zespołowi z Instytutu Biologii Doświadczalnej PAN imienia Marcelego Nenckiego za udostępnienie zbioru sygnałów EEG, na których mogłam oprzeć moją pracę oraz za całokształt współpracy naukowej.

Chciałabym również podziękować moim rodzicom i narzeczonemu za okazane wsparcie, zrozumienie i cierpliwość.

Streszczenie

W niniejszej rozprawie przedstawiono wyniki badań dotyczących weryfikacji tożsamości osób na podstawie cech biometrycznych zawartych w sygnałach elektroencefalograficznych (EEG). Jedną z zalet stosowania sygnału EEG w celu weryfikacji tożsamości jest to, że może on zostać pozyskany jedynie w nieinwazyjnym pomiarze bezpośrednim i tylko od żywej osoby, dzięki czemu wykazuje bardzo niską podatność na fałszerstwa, kradzieże czy wyłudzenia. Sygnał ten jest trudny do interpretacji ze względu na towarzyszące mu zakłócenia oraz złożoną i stosunkowo spontaniczną aktywność mózgu.

W ramach realizacji pracy opracowano metody weryfikacji tożsamości osób na podstawie analizy widma sygnału EEG i jego podpasm z wykorzystaniem metod uczenia maszynowego, zapewniające wysokie miary oceny jakości weryfikacji, niezależne od dziennych lub długookresowych zmian w sygnale. Podjęto też próbę zmniejszenia liczby analizowanych podpasm widma sygnału EEG oraz elektrod i określenia minimalnej liczby sesji treningowych, które zapewnią wysoką dokładność i swoistość weryfikacji tożsamości osób.

Opracowanie metod weryfikacji tożsamości poprzedzono stworzeniem unikalnego w tym obszarze badań zbioru sygnałów EEG, zarejestrowanych w trakcie wielu sesji pomiarowych, odbywających się w ciągu kilku miesięcy. Badanie efektywności metod weryfikacji tożsamości osób na podstawie sygnału EEG w wielokrotnie powtarzanych sesjach pomiarowych rejestrowanych, w różnych dniach umożliwiło rzetelną ocenę proponowanych rozwiązań.

Zaproponowane w rozprawie metody weryfikacji tożsamości osób opierają się na wykorzystaniu cech spektralnych sygnału EEG, w szczególności współczynników gęstości widmowej mocy wyrażonych w skali decybelowej i ich klasyfikacji za pomocą metody głosowania większościowego z użyciem sztucznych sieci neuronowych. Osiągnięto średnią dokładność weryfikacji tożsamości równą 97,8 % przy odchyleniu standardowym 1,0 %. Średnia wartość współczynnika fałszywych akceptacji dla symulowanego ataku intruzów wyniosła 2,1 % przy odchyleniu standardowym równym 2,1 %.

Autorka ma nadzieję, że zaprezentowane w rozprawie metody weryfikacji tożsamości osób na podstawie sygnału EEG oraz przeprowadzone analizy będą stanowić wartościowy wkład w rozwój biometrii opartej na analizie sygnału EEG, a także ułatwią komercyjne wdrożenie systemu biometrycznego wykorzystującego sygnały EEG do weryfikacji tożsamości osób.

Słowa kluczowe: *biometria, weryfikacja tożsamości, ekstrakcja cech, elektroencefalografia, EEG, widmo gęstości mocy, uczenie maszynowe, sztuczna sieć neuronowa, uczenie zespołowe*

Abstract

This dissertation presents the results of research on identity verification based on biometric features in electroencephalography signals (EEG). One of the advantages of using the EEG signal in the verification is that it can only be obtained in a non-invasive direct measurement and only from a living person, making it highly resistant to counterfeiting, theft, or scam. This signal is difficult to interpret due to the accompanying interferences and the complex and relatively spontaneous activity of the brain.

As a part of the work, methods for identity verification of individuals were developed based on the spectral analysis of EEG signals and their sub-bands, using machine learning methods that provide high measures of verification quality independent of daily or long-term changes in the signal. Moreover, an attempt was made to reduce the number of analyzed sub-bands of the EEG signal spectrum, number of electrodes and to determine the minimum number of training sessions that would also ensure high accuracy and specificity in verifying the identity of individuals.

The development of the identity verification methods was preceded by the preparation of a unique dataset of EEG signals recorded during multiple measurement sessions over several months. The study of the effectiveness of identity verification methods based on EEG signals across multiple repeated measurement sessions recorded on different days enabled the reliable evaluation of the proposed solutions.

The methods of verifying the identity verification of individuals proposed in the dissertation are based on using spectral features of the EEG signal, particularly power spectral density coefficients expressed in the decibel scale, and their classification through a majority voting method using artificial neural networks. An averaged identity verification accuracy of 97.8 % was achieved with a standard deviation of 1.0 %. The averaged false acceptance rate for a simulated intrusion attack was 2.1 %, with a standard deviation of 2.1 %.

The author hopes that the presented in the dissertation methods of identity verification of individuals based on EEG signals and the presented analyses will provide a valuable contribution to the development of biometrics based on the analysis of the EEG signal and will facilitate the commercial implementation of a biometric system that uses EEG signals to verify the identity of individuals.

Keywords: *biometrics, verification, feature extraction, electroencephalography, EEG, power spectral density, machine learning, artificial neural network, ensemble learning*

Spis treści

Wykaz stosowanych skrótów	11
Wykaz najważniejszych symboli	12
1. Wprowadzenie	13
1.1. Biometryczna weryfikacja tożsamości	13
1.2. Sygnał EEG jako cecha biometryczna.....	14
1.3. Zagadnienia badawcze.....	16
1.4. Cel i tezy pracy	18
1.5. Układ pracy.....	20
2. Elektroencefalografia.....	22
2.1. Powstawanie sygnału EEG	22
2.2. Akwizycja sygnału EEG.....	27
2.3. Charakterystyka sygnału EEG.....	29
2.4. Charakterystyka rytmów sygnału EEG	30
2.5. Podsumowanie rozdziału	34
3. Zastosowanie elektroencefalografii w biometrii.....	35
3.1. Podstawowe pojęcia biometrii.....	35
3.2. Metody oceny jakości klasyfikacji	36
3.3. Analiza sygnału EEG jako źródła cech biometrycznych.....	38
3.4. Przegląd metod rozpoznawania tożsamości osób na podstawie sygnału EEG.....	40
3.5. Podsumowanie rozdziału	43
4. Opis wykorzystywanych metod przetwarzania sygnału EEG i uczenia maszynowego ...	44
4.1. Opis analizowanego zbioru rejestracji sygnałów EEG.....	44
4.2. Przetwarzanie wstępne sygnału	44
4.3. Ekstrakcja cech	47
4.4. Metody uczenia maszynowego.....	49
4.4.1. Drzewa decyzyjne i lasy losowe	50
4.4.2. Metoda k-najbliższych sąsiadów	51
4.4.3. Maszyna wektorów nośnych	51
4.4.4. Sztuczne sieci neuronowe	52
4.5. Podsumowanie rozdziału	53

5.	Opis i wyniki przeprowadzonych badań.....	54
5.1.	Podział na zbiory trenujące i testujące.....	54
5.1.1.	Przeprowadzone badania.....	55
5.1.2.	Wnioski	61
5.2.	Wpływ skalowania współczynników widmowej gęstości mocy.....	61
5.2.1.	Przeprowadzone badania.....	61
5.2.2.	Wnioski	67
5.3.	Analiza zastosowania różnych klasyfikatorów.....	67
5.3.1.	Porównanie klasyfikatorów	67
5.3.2.	Wyniki dla różnej liczby neuronów ukrytych	69
5.3.3.	Uczenie zespołowe	70
5.3.4.	Wnioski	74
5.4.	Wpływ podpasm widma sygnału EEG.....	75
5.4.1.	Przeprowadzone badania.....	75
5.4.2.	Wnioski	84
5.5.	Wpływ liczby oraz umiejscowienia elektrod.....	84
5.5.1.	Przeprowadzone badania.....	85
5.5.2.	Wnioski	90
5.6.	Wpływ liczby sesji pomiarowych sygnału EEG użytych do treningu	90
5.6.1.	Przeprowadzone badania.....	91
5.6.2.	Wnioski	98
5.7.	Atak intruzów	99
5.7.1.	Przeprowadzone badania.....	99
5.7.2.	Wnioski	101
5.8.	Sparametryzowane cechy podpasm widma sygnału EEG.....	101
5.8.1.	Przeprowadzone badania.....	102
5.8.2.	Wnioski	107
6.	Podsumowanie i wnioski końcowe.....	109
6.1.	Podsumowanie przeprowadzonych badań.....	109

6.2. Ograniczenia.....	113
6.3. Wnioski i kierunki dalszych badań.....	114
Bibliografia.....	116
Dodatek A. Uśrednione wartości miar jakości klasyfikacji dla różnych metod skalowania współczynników widmowej gęstości mocy	127
Dodatek B. Uśrednione wartości miar jakości klasyfikacji dla różnych podpasm widma sygnału EEG	131
Dodatek C. Uśrednione wartości miar jakości klasyfikacji dla różnych zestawów elektrod i podpasm sygnału EEG	137
Dodatek D. Uśrednione wartości miar jakości klasyfikacji dla sparametryzowanych cech podpasm widma sygnału EEG	141

Wykaz stosowanych skrótów

ACC	–	dokładność (ang. <i>accuracy</i>)
ANN	–	sztuczna sieć neuronowa (ang. <i>Artificial Neural Network</i>)
BCI	–	interfejs mózg-komputer (ang. <i>Brain Computer Interface</i>)
CAR	–	wspólny uśredniony potencjał odniesienia (ang. <i>Common Average Reference</i>)
DFT	–	dyskretna transformata Fouriera (ang. <i>Discrete Fourier Transform</i>)
DT	–	drzewa decyzyjne (ang. <i>Decision Tree</i>)
EEG	–	elektroencefalografia (ang. <i>electroencephalography</i>)
EER	–	błąd zrównoważony (ang. <i>Equal Error Rate</i>)
EKG	–	elektrokardiografia (ang. <i>electrocardiography</i>)
EMG	–	elektromiografia (ang. <i>electromyography</i>)
EOG	–	elektrookulografia (ang. <i>electrooculography</i>)
EPSP	–	postsynaptyczny potencjał pobudzający (ang. <i>Excitatory Postsynaptic Potential</i>)
FAR	–	współczynnik fałszywych akceptacji (ang. <i>False Acceptance Rate</i>)
FFT	–	szybka transformata Fouriera (ang. <i>Fast Fourier Transform</i>)
FN	–	wynik fałszywie negatywny (ang. <i>False Negative</i>)
FP	–	wynik fałszywie pozytywny (ang. <i>False Positive</i>)
FRR	–	współczynnik fałszywych odrzuceń (ang. <i>False Rejection Rate</i>)

IPSP	–	postsynaptyczny potencjał hamujący (ang. <i>Inhibitory Postsynaptic Potential</i>)
KNN	–	algorytm k-najbliższych sąsiadów (ang. <i>K-Nearest Neighbors algorithm</i>)
MLP	–	wielowarstwowy perceptron (ang. <i>Multi-Layer Perceptron</i>)
PREC	–	precyzja (ang. <i>precision</i>)
PSD	–	widmowa gęstość mocy (ang. <i>Power Spectral Density</i>)
RF	–	las losowy (ang. <i>Random Forest</i>)
SEN	–	czułość (ang. <i>sensitivity</i>)
SPEC	–	swoistość (ang. <i>specificity</i>)
SVM	–	maszyna wektorów nośnych (ang. <i>Support Vector Machines</i>)
TN	–	wynik prawdziwie negatywny (ang. <i>True Negative</i>)
TP	–	wynik prawdziwie pozytywny (ang. <i>True Positive</i>)

Wykaz najważniejszych symboli

- α – podpasmo widma sygnału EEG odpowiadające rytmowi alfa
- β – podpasmo widma sygnału EEG odpowiadające rytmowi beta
- γ – podpasmo widma sygnału EEG odpowiadające rytmowi gamma
- δ – podpasmo widma sygnału EEG odpowiadające rytmowi theta
- θ – podpasmo widma sygnału EEG odpowiadające rytmowi delta

1. Wprowadzenie

1.1. Biometryczna weryfikacja tożsamości

Wraz z rozwojem technologii wiele czynności w naszym codziennym życiu zostało zautomatyzowanych. Dotyczy to między innymi kontroli dostępu do pomieszczeń, urządzeń mobilnych, poufnych informacji czy operacji bankowych. Dzięki temu zyskujemy większą wygodę podczas korzystania z różnych systemów i usług. Jednocześnie stajemy się bardziej narażeni na przestępstwa polegające na wyłudzeniu naszej tożsamości w celu zyskania nieuprawnionego dostępu do różnorodnych usług lub chronionych informacji. W związku z tym większą uwagę zaczęto przykładac do zwiększenia poziomu bezpieczeństwa podczas przydzielania dostępu do określonych usług. Zazwyczaj odbywa się to poprzez potwierdzanie tożsamości osób uprawnionych do wykonywania określonych działań z wykorzystaniem haseł lub specjalnych kart dostępu. W większości przypadków takie rozwiązania mogą okazać się odpowiednie, jednak w systemach wymagających wysokiego poziomu zabezpieczeń, przykładowo wojskowych, mogą one okazać się niewystarczające – hasła, które trudno złamać zazwyczaj szybko ulegają zapomnieniu, a karty, którymi można potwierdzić tożsamość łatwo stracić. Między innymi dlatego zaczęto poszukiwać metod potwierdzania tożsamości uprawnionej osoby w oparciu o cechy jej zachowania bądź anatomii, czyli jej cechy biometryczne [1], [2].

Pomiarem i selekcją indywidualnych cech organizmów żywych, a także udoskonalaniem metod pomiaru i wyboru najbardziej niepowtarzalnych osobniczo parametrów tych cech zajmują się techniki biometryczne. Aby konkretna cecha mogła zostać użyta w procesie rozpoznawania tożsamości, musi być na stałe związana z osobą, unikalna i niezmienna w czasie. W tym celu zazwyczaj wykorzystywane są cechy fizyczne związane z obrazem linii papilarnych [3], czy dłoni [4], układem naczyń krwionośnych w palcu [5] lub w dłoni [6], obrazem twarzy [7] czy ucha [8], charakterystycznymi punktami tęczówki [9] i innymi [10]. Opracowano również szereg metod potwierdzania tożsamości osób opartych o cechy behawioralne. Za przykład mogą posłużyć prędkość, nacisk czy kąt nachylenia pióra podczas pisania, dynamika uderzeń w klawisze klawiatury [11] lub sposób chodzenia [12]. Do tej kategorii cech biometrycznych należą również sygnały biomedyczne, do których zalicza się sygnał elektroencefalograficzny (EEG).

W procesie pomiaru cechy biometrycznej następuje rejestracja fizycznego sygnału wejściowego lub obrazu, który następnie jest przetwarzany i poddawany analizie, w trakcie której wyznaczane są charakterystyczne stałe parametry zarejestrowanej cechy. Tylko

te parametry w postaci wzorca biometrycznego zostają zapamiętane w bazie danych wzorców biometrycznych. Dane te są później wykorzystywane do rozpoznawania biometrycznego. Rozpoznawanie biometryczne osób może być przeprowadzane na dwa sposoby – poprzez potwierdzanie tożsamości (weryfikację) oraz ustalanie tożsamości (identyfikację) [13]. Identyfikacja polega na ustaleniu tożsamości osoby na podstawie jej wzorca biometrycznego poprzez porównanie wzorca badanej osoby ze wzorcami wszystkich zarejestrowanych osób znajdujących się w przeszukiwanej bazie. W trakcie weryfikacji następuje potwierdzenie, że dana osoba jest tą, za którą się podaje, czyli jej wzorzec biometryczny jest porównywany ze wskazanym przez nią wzorcem przechowywanym w bazie wzorców. Zarówno w procesie identyfikacji, jak i weryfikacji wynik porównania stanowi podstawę decyzji i podjęcia (lub nie) określonej akcji, np. umożliwienia dostępu do telefonu komórkowego, sejfu lub systemu informatycznego.

Oprócz wykorzystania rozpoznawania biometrycznego w obszarach powszechnie dostępnych usług coraz ważniejszy staje się sektor zastosowań w systemach, w których jest wymagany wysoki poziom bezpieczeństwa dostępu do obiektu (np. do pomieszczeń służbowych w zastosowaniach militarnych) lub w trakcie wykonywania określonej czynności (np. ciągła kontrola tożsamości osoby pilotującej wojskowy bezzałogowy statek powietrzny – tzw. dron). Do zastosowań wymagających większego poziomu bezpieczeństwa zaczęto rozważać użycie sygnału EEG. W porównaniu do bardziej tradycyjnych cech bazujących na łatwo dostępnych częściach ciała, takich jak na przykład palec, oko, twarz albo dłoń, sygnał EEG nie jest widoczny ani możliwy do pozyskania bez użycia specjalistycznej aparatury, dzięki czemu jest trudniejszy do kradzieży, podrobienia, wyłudzenia oraz jest mniej podatny na ataki intruzów [14], [15]. Sygnał ten może zostać pozyskany jedynie od żywych osób, co więcej nie może zostać skradziony na odległość [15], czy zarejestrowany zdalnie bez świadomego zaangażowania osoby, do której należy [16]. Dodatkową zaletą zastosowania sygnału EEG w celu rozpoznawania tożsamości osób jest stosunkowo niski koszt akwizycji (rejestracji) oraz jej nieinwazyjność. Rozważania na ten temat prowadzono szeroko pod koniec ubiegłego wieku [17]–[19].

1.2. Sygnał EEG jako cecha biometryczna

Pierwotnym źródłem sygnałów generowanych w mózgu są neurony, będące komórkami wyspecjalizowanymi w wymianie informacji pomiędzy sobą za pomocą impulsów elektrycznych powstałych w wyniku procesów metabolicznych [20]. Od przepływu tych informacji zależą odpowiedzi na bodźce u człowieka i niemal wszystkich zwierząt [20].

Potencjał pochodzący z wielu zsynchronizowanych neuronów, szczególnie umiejscowionych w warstwie powierzchniowej kory mózgowej jest na tyle duży, że może on zostać zmierzony w sposób nieinwazyjny na powierzchni głowy. Rejestracja tego sygnału odbywa się z wykorzystaniem specjalnych elektrod za pomocą urządzenia zwanego elektroencefalografem. W wyniku pomiarów otrzymywany jest elektroencefalogram, będący zbiorem wykresów zmian napięcia na każdej z elektrod w funkcji czasu. Zwyczajowo elektrody są umieszczane w umownych punktach na powierzchni głowy, przez co pomiar sygnału EEG zawiera informacje o rozkładzie napięć zarówno w czasie, jak i w przestrzeni.

Sygnał EEG jest zależny od czynności wykonywanych przez ośrodkowy układ nerwowy i dzięki temu możliwe jest wykorzystanie go do otrzymywania cennych informacji diagnostycznych zarówno w badaniach naukowych, jak i w medycynie klinicznej. Może być wykorzystywany podczas diagnozowania zaburzeń neurologicznych, takich jak przykładowo choroba Parkinsona [21] czy epilepsja [22], analizy snu [23] oraz jego zaburzeń, na przykład narkolepsji [24]. Oprócz tego sygnał EEG może być stosowany w trakcie zbierania informacji na temat funkcji kognitywnych umysłu [25] czy monitorowania jego stanu, przykładowo w treningach neurobiofeedback (badany uczy się regulować stan swojego umysłu na podstawie otrzymywanej informacji zwrotnej o stanie swojego umysłu), poziomu skupienia uwagi, zmęczenia, stresu, czy w analizie emocji [26], co może pomagać w diagnozowaniu zaburzeń i tworzeniu bardziej efektywnych strategii terapeutycznych. Coraz popularniejsze stają się próby zastosowania EEG w systemach wykorzystujących interfejsy mózg-komputer (BCI, ang. *Brain-Computer Interface*) umożliwiających między innymi sterowanie urządzeniami za pomocą myśli [27].

W miarę doskonalenia klinicznych zastosowań pomiaru EEG opracowywano nowe metody oceny stanu mózgu. Optymalizowano standardy akwizycji sygnałów, ułożenia elektrod na powierzchni głowy badanego, udoskonalano sprzęt. Postęp w dziedzinie informatyki i elektroniki pozwolił częściowo zautomatyzować analizę sygnałów EEG, wspomagając proces diagnostyczny, a rozwój metod uczenia maszynowego w ostatnich latach umożliwił zastosowanie zaawansowanych metod przetwarzania sygnału EEG. Prowadzone są badania nad wykorzystaniem tych metod między innymi do wykrywania i analizy chorób psychicznych, takich jak schizofrenia [28] lub depresja [29], klasyfikacji snu [30], detekcji epilepsji [31], [32], narkolepsji [33], [34], czy choroby Parkinsona [35] i innych.

Badania nad zastosowaniem sygnału EEG jako źródła cech biometrycznych do rozpoznawania osób rozpoczęły się stosunkowo niedawno i dopiero pod koniec lat 90-tych zeszłego wieku został ukazany ich potencjał [17]–[19]. Wykorzystywanie sygnału EEG

do tworzenia cech biometrycznych opiera się na założeniu, że występują w nim duże różnice międzyosobnicze, a małe pomiędzy kolejnymi rejestracjami tej samej osoby [36]. Sygnał ten może więc zostać użyty zarówno w procesie weryfikacji, jak również identyfikacji.

1.3. Zagadnienia badawcze

Na potrzeby rozprawy zdefiniowano kilka zagadnień badawczych, które należy uwzględnić podczas opracowywania metod wykorzystujących sygnał EEG do weryfikacji tożsamości osób z użyciem uczenia maszynowego. W szczególności należy zwrócić uwagę na zagadnienia związane z:

- cechami sygnału EEG i jego zmiennością,
- czasem przygotowania do akwizycji sygnału,
- liczbą powtórzeń sesji pomiarowych sygnału EEG niezbędnych do określenia biometrycznego wzorca badanej osoby,
- odpornością na intruzów.

Cechy sygnału EEG i jego zmienność

Sygnał EEG jest niestacjonarny i nieokresowy, jednakże możliwe jest wyróżnienie w nim pewnych powtarzalnych elementów, między innymi rytmów (fal): delta, theta, alfa, beta i gamma. Amplituda tego sygnału jest wyjątkowo niska, często nieprzekraczająca 100 μV , co powoduje, że sygnał EEG jest podatny na zakłócenia. W jego przebiegach występują artefakty, czyli zmiany w zapisie, które nie są pochodzenia mózgowego [37]. Można je podzielić na artefakty pochodzące od czynników [37], [38]:

- technicznych, których źródłem mogą być nieprawidłowe procedury pomiarowe, zakłócenia związane z otoczeniem badanego, niedoskonałości aparatury itp.,
- biologicznych, które wynikają z naturalnych procesów fizjologicznych organizmu.

Podstawowym problemem badawczym poruszonym w rozprawie jest uzyskanie odporności metody weryfikacji tożsamości osób na możliwe zmiany sygnału, którym może ulegać w zależności m.in. od pory dnia, czynników technicznych, wahań temperatury, nastroju czy po prostu senności u badanego. Jednym z proponowanych rozwiązań opisanych w literaturze [16] jest wykorzystywanie sposobów aktywacji sygnału EEG wymuszających powtarzalny kształt sygnału poprzez generowanie określonych bodźców lub intencjonalne powtarzanie danej czynności lub myśli. W zależności od zastosowania, takie rozwiązania mogą być problematyczne ze względu na to, że wymagają pełnej uwagi oraz współpracy ze strony osoby rozpoznawanej. Podczas regularnego stosowania tych sposobów, mogą one okazać się nużące

dla osoby badanej. Rozwiązaniami, które lepiej oddają naturalny stan człowieka są metody oparte na jego EEG spoczynkowym, czyli takim gdzie rejestrowana jest spontaniczna aktywność mózgu [39]. Analizy przedstawione w niniejszych badaniach zostały przeprowadzone na EEG spoczynkowym.

Czas przygotowania do akwizycji sygnału i czas weryfikacji

Akwizycja sygnału EEG odbywa się zazwyczaj za pomocą 21 elektrod rozmieszczonych na powierzchni głowy osoby badanej. Założenie wszystkich elektrod zazwyczaj wymaga długiego czasu, co może negatywnie wpływać na komfort i samopoczucie osoby weryfikowanej. Z tego powodu podjęto próbę zmniejszenia liczby wykorzystywanych elektrod, w celu skrócenia czasu potrzebnego na przygotowanie do akwizycji sygnału. Redukcja liczby elektrod dodatkowo powoduje zmniejszenie liczby cech podawanych na wejście klasyfikatora, a tym samym przyspieszenie jego uczenia i procesu weryfikacji. W rozprawie klasyfikator jest rozumiany jako algorytm służący określeniu, czy podawane na jego wejście cechy należą do osoby, którą nauczył się rozpoznawać, czy nie.

Zmniejszenie liczby analizowanych cech związane jest również z analizą i wyborem podpasm w sygnale EEG, które niosą najwięcej informacji o osobniczych cechach badanego. Rytm widoczne w sygnale EEG odpowiadają pewnym podpasmom widma tego sygnału w dziedzinie częstotliwości [40], [41]. Redukcja liczby elektrod oraz analiza wybranych podpasm zawartych w sygnale EEG skraca czas trenowania oraz generowania odpowiedzi przez klasyfikator.

Liczba powtórzeń sesji rejestracji sygnału EEG niezbędnych do określenia biometrycznego wzorca badanej osoby

W doniesieniach literaturowych coraz częściej wspomina się o konieczności zwiększenia liczby pomiarów sygnału EEG dla pojedynczej osoby, na podstawie których opracowuje się i ocenia efektywność wykorzystania EEG jako metody biometrycznego rozpoznawania tożsamości. Jednak wciąż wiele prac w tej dziedzinie bazuje na sygnałach zarejestrowanych w czasie jednej [36], [42]–[48] bądź małej liczby sesji pomiarowych. Ponadto zazwyczaj badania, w których wykonano więcej sesji, przeprowadzano w ciągu tego samego dnia [49] lub dla małej liczby osób [17]–[19]. W niektórych pracach próbowano odnieść się do tego problemu poprzez zwiększanie liczby oddzielnych sesji pomiarowych, przykładowo analizując sygnały z pięciu do sześciu sesji [50]–[53].

Istnieje więc silna potrzeba przeprowadzenia szerszych badań nad wpływem liczby rozdzielnych sesji na stałość wyników rozpoznawania osób bazującego na sygnale EEG [16]. Zagadnienie to jest wciąż aktualne, co zostało uwidocznione w ostatnio publikowanych artykułach o użyciu EEG w biometrii [14], [51], [52], [54]–[56]. Wykorzystywanie różnych fragmentów tych samych rejestracji jako danych treningowych i testowych może doprowadzić do fałszywego zawyżenia dokładności uzyskiwanych wyników, co może doprowadzić do prawie idealnych rezultatów rozpoznawania [48].

W rozprawie zaproponowano rozwiązanie wykorzystujące rozdzielone w czasie sesje pomiarowe sygnału EEG, podzielone na rejestracje treningowe i testowe. Takie podejście powinno umożliwić klasyfikatorowi selekcję i analizę stałości cech indywidualnych dla danego użytkownika w czasie, a nie jedynie oszacować różnice międzyosobnicze na podstawie pojedynczych rejestracji [15]. Zmniejszane jest wtedy ryzyko popełnienia błędu weryfikacji przez system, który nauczył się rozróżniać daną osobę w oparciu o cechy nie będące cechami stałymi, np. poprzez naukę zakłóceń powtarzających się w trakcie jednej rejestracji. Dodatkowo unika się problemu wycieku danych [57], który może spowodować fałszywie wysokie wartości miar jakości klasyfikacji.

Odporność na intruzów

System weryfikacji tożsamości osób powinien być odporny na ataki intruzów, rozumianych jako osoby zewnętrzne (nieuwzględniane w trakcie tworzenia systemu), które podszywają się pod kogoś innego i nie są uprawnione do określonych działań. W trakcie badań wykorzystano dodatkowy zbiór rejestracji sygnałów EEG osób, które nie zostały uwzględnione w trakcie trenowania klasyfikatora. Miało to na celu sprawdzenie czy zaproponowane w rozprawie rozwiązania okażą się odporne na próby włamań przez nieznaną klasyfikatorowi osoby.

1.4. Cel i tezy pracy

Celem badań przedstawionych w niniejszej rozprawie było opracowanie nowych rozwiązań zwiększających jakość weryfikacji tożsamości osób na podstawie analizy widmowej sygnału EEG z wykorzystaniem metod uczenia maszynowego. Ewaluacja tych rozwiązań została przeprowadzona z wykorzystaniem wielosesyjnego zbioru rejestracji sygnału EEG za pomocą statystycznych miar oceny jakości klasyfikacji. Na potrzeby rozprawy we współpracy z zespołem z Instytutu Biologii Doświadczalnej PAN im. Marcelego Nenckiego w Warszawie skompletowano obszerny zbiór rejestracji sygnałów EEG.

W rozprawie postawiono następujące tezy:

1. Możliwe jest opracowanie metody weryfikacji tożsamości osób na podstawie analizy widmowej sygnału EEG z wykorzystaniem metod uczenia maszynowego, niezależnej od dziennych lub długookresowych zmian w sygnale, która zapewniałaby uzyskanie wysokich miar oceny jakości klasyfikacji, w szczególności dokładności i swoistości.
2. Możliwa jest redukcja liczby analizowanych podpasm widma sygnału EEG, które zapewnią uzyskanie parametrów weryfikacji tożsamości na podobnym poziomie, jak dla całego rozpatrywanego pasma sygnału EEG.
3. Możliwe jest zmniejszenie liczby elektrod do akwizycji sygnału EEG oraz określenie zestawu elektrod wygodnego do zastosowania z punktu widzenia osób weryfikowanych, zapewniającego uzyskanie jakości weryfikacji na stosunkowo wysokim poziomie.
4. Możliwe jest określenie minimalnej liczby sesji pomiarowych sygnału EEG używanych w procesie uczenia klasyfikatora w celu skrócenia procesu przygotowywania systemu do użycia w praktyce.

Zakłada się, że opracowane rozwiązania uzyskają bardzo dobre parametry weryfikacji tożsamości, w szczególności dokładność i swoistość, rozumiane jako stosunek prawidłowo zaklasyfikowanych odpowiedzi klasyfikatora do wszystkich podjętych prób przeprowadzenia weryfikacji i jako stosunek prawidłowych odrzuceń ataków intruzów do wszystkich ataków intruzów poddawanych weryfikacji.

Wkład własny autorki

Poniżej przedstawiono oryginalny wkład autorki w dziedzinie weryfikacji tożsamości osób na podstawie sygnału EEG:

- opracowanie metod weryfikacji tożsamości osób w oparciu o cechy spektralne sygnału EEG, które pomimo dziennych i długookresowych wahań w sygnale EEG zapewniają wysoką wartość dokładności oraz innych miar statystycznych klasyfikacji,
- zbadanie wpływu podziału danych na zbiory treningowe i testowe na efektywność weryfikacji tożsamości osób na podstawie sygnału EEG [58], [59],
- wykazanie, że wyrażenie widmowej gęstości mocy w skali decybelowej znacząco poprawia jakość weryfikacji tożsamości osób w stosunku do zastosowania innych metod skalowania widma bądź ich braku [60], [61],
- zbadanie i dobór minimalnego zestawu podpasm widma sygnału EEG, który umożliwi uzyskanie parametrów weryfikacji tożsamości na podobnym poziomie jak dla całego rozpatrywanego pasma sygnału EEG [58], [59],

- analiza wpływu pojedynczych oraz wybranych zestawów elektrod na dokładność weryfikacji tożsamości osób, w szczególności przeprowadzenie badań na zbiorze sesji testowych, odbywających się w innych dniach niż sesje treningowe [62], [63],
- zbadanie wpływu liczby sesji treningowych na miary jakości weryfikacji tożsamości osób [60],
- analiza skuteczności zaproponowanych metod weryfikacji tożsamości osób oraz sprawdzenie ich odporności na zasymulowany atak intruzów [59], [60].

Jednym z aspektów wyróżniających rozprawę jest również przeprowadzenie badań z wykorzystaniem sygnałów zarejestrowanych w trakcie dwudziestu sesji pomiarowych EEG dla każdej z osób. Każda z sesji dla pojedynczej osoby odbywała się innego dnia. Regularna, rejestracja wielu sesji dla każdej z osób jest skomplikowana organizacyjnie, a jednocześnie niezbędna do przeprowadzenia wiarygodnych badań nad zastosowaniem sygnału EEG do rozpoznawania tożsamości.

1.5. Układ pracy

Rozprawa została podzielona na sześć rozdziałów. W rozdziale drugim przybliżono właściwości sygnału EEG. Przedstawiono sposób powstawania sygnału EEG i metody jego akwizycji. Opisano również sygnał EEG, obecne w nim zakłócenia oraz jego podstawowe składowe.

Rozdział trzeci poświęcono opisowi zastosowania sygnału EEG do weryfikacji tożsamości osób. Przedstawiono w nim przyjęte w rozprawie metody oceny jakości klasyfikacji odpowiadające typowym miarom statystycznym stosowanym w uczeniu maszynowym. Przeanalizowano zastosowanie sygnału EEG jako źródła cech biometrycznych oraz przedstawiono przegląd metod rozpoznawania tożsamości na podstawie sygnału EEG.

W rozdziale czwartym zamieszczono opis zbioru rejestracji sygnałów EEG, wykorzystywanego w rozprawie oraz opisano zastosowane metody wstępnego przetwarzania sygnału EEG. Scharakteryzowano sposoby ekstrakcji cech na podstawie współczynników gęstości widmowej mocy (PSD, ang. *Power Spectral Density*) oraz wyznaczanych na ich podstawie sparametryzowanych cech podpasem widma sygnału EEG. Rozdział zakończono opisem rozpatrywanych klasyfikatorów.

W rozdziale piątym przedstawiono wyniki przeprowadzonych badań. Prace obejmowały analizę wpływu sposobu podziału danych na zbiory treningowe i testowe, analizę metod skalowania współczynników widmowej gęstości mocy oraz wybór klasyfikatora. W dalszej części rozdziału przedstawiono wyniki badań nad doborem podpasem sygnału EEG i zestawu

elektrod, które są najbardziej użyteczne w procesie weryfikacji na podstawie sygnału EEG rejestrowanego w stanie spoczynku. Dla zaproponowanych rozwiązań zbadano wpływ liczby sesji pomiarowych sygnału EEG użytych do treningu klasyfikatora na jakość weryfikacji tożsamości osób oraz sprawdzono odporność zaproponowanych metod na ataki intruzów, wykorzystując nieuwzględnione w trakcie trenowania klasyfikatorów sesje zarejestrowane od dodatkowych osób. Na końcu rozdziału przedstawiono wyniki dla sparametryzowanych cech podpasm widma sygnału EEG. W rozdziale szóstym zamieszczono podsumowanie wyników badań i wnioski końcowe.

2. Elektroencefalografia

Każdy z nas postrzega świat w odmienny sposób. Różnie definiujemy czysto abstrakcyjne pojęcia takie jak przyjaźń czy moralność, inaczej interpretujemy kolory. Wewnątrz danego gatunku mózgi pod względem strukturalnym są niemal takie same, jednakże ich działanie jest osobniczo różne. Zagadnienie to od wieków fascynowało naukowców z różnorodnych dziedzin, tworząc podwaliny pod badania, które umożliwiłyby zajrzenie do ludzkiego umysłu. Za jednego z prekursorów takich prac można uznać Richarda Catona, angielskiego fizjologa, który w 1875 roku opublikował wyniki swoich badań nad zapisem czynności bioelektrycznej mózgu zwierzęcego [37]. Obserwował on mózgi królików i małp [64]. Za pionierów elektrofizjologii na świecie uchodzą również, dzięki swoim pracom z końca XIX wieku, polscy elektrofizjolodzy – Napoleon Nikodem Cybulski i Adolf Beck, którzy prowadzili badania związane z rejestracją prądów mózgowych, m.in. rejestrowali oni czynność bioelektryczną kory mózgu psów i małp [37].

Pierwszą osobą, która opublikowała przebiegi sygnałów bioelektrycznych zarejestrowanych z powierzchni głowy człowieka był Hans Berger [65]. To właśnie on wprowadził termin elektroencefalografia oraz założył pierwszą pracownię, w której rejestrowano ten sygnał. W swoich badaniach zauważył związek pomiędzy sygnałami odbieranymi z powierzchni głowy, a pracą mózgu. Między innymi to dzięki niemu EEG stało się podstawowym badaniem czynności bioelektrycznej mózgu.


W rozdziale przedstawiono opis powstawania sygnału EEG oraz jego akwizycji za pomocą umiejscawiania elektrod w układzie 10-20. Opisane zostały zakłócenia obecne w tym sygnale oraz krótko scharakteryzowano występujące w nim rytmy.

2.1. Powstawanie sygnału EEG

Jedną z najpopularniejszych metod obrazowania bioelektrycznej aktywności mózgu jest rejestracja sygnału elektroencefalograficznego [33], [38]. Jest to sygnał biomedyczny, rejestrowany za pomocą urządzenia zwanego elektroencefalografem. Jego akwizycja odbywa się z użyciem elektrod rejestrujących w nieinwazyjny sposób sygnał bioelektryczny z powierzchni głowy osoby badanej. W wyniku pomiarów otrzymuje się elektroencefalogram, będący zbiorem od kilku do ponad stu jednoczesnych wykresów zmian napięcia na elektrodach w funkcji czasu.

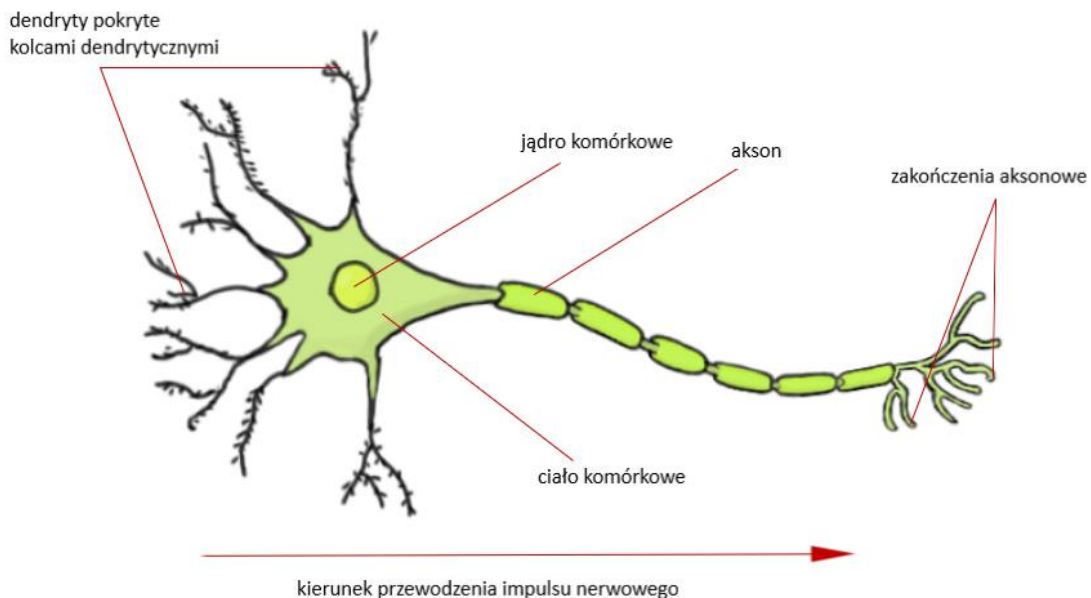
Na rysunku 1 zaprezentowano schemat typowego toru przetwarzania sygnału EEG. Sygnały zarejestrowane z elektrod znajdujących się na głowie osoby badanej są wzmacniane i filtrowane

we wzmacniaczu. Następnie mogą być tradycyjnie rysowane z użyciem rejestratora papierowego lub po konwersji na postać cyfrową zapisywane w pamięci komputera. W zależności od celu pomiarów sygnały te są dalej analizowane za pomocą odpowiedniego oprogramowania, często również prezentowane lekarzowi (lub innej osobie przeprowadzającej rejestrację sygnału EEG) na ekranie komputera lub w postaci wydruku w celu analizy wzrokowej.



Rysunek 1. Schemat standardowego toru przetwarzania sygnału EEG.

Podczas akwizycji sygnału EEG elektrody rejestrują zmiany napięcia w grupach komórek nerwowych mózgu zwanych neuronami. Neurony są komórkami wyspecjalizowanymi w wymianie informacji za pomocą impulsów elektrycznych. Wewnątrz neuronów impuls jest przekazywany od dendrytów do aksonu. Schemat przykładowego neuronu został zaprezentowany na rysunku 2.



Rysunek 2. Schemat neuronu.
Na podstawie: [20].


W neuronie można wyróżnić następujące podstawowe elementy strukturalne [20]:

- dendryty, które odbierają sygnały z innych neuronów,
- ciało komórkowe, będące największą częścią neuronu – posiada jądro komórkowe, w którym sumowane są odebrane przez dendryty sygnały i jeżeli otrzymana suma sygnałów przekroczy określony próg, generowane są potencjały iglicowe, będące odpowiedzią neuronu na pobudzenie,
- akson, który przekazuje dalej sygnały do dendrytów kolejnych neuronów, gruczołów lub mięśni.

W stanie spoczynku różnica pomiędzy ładunkiem znajdującym się wewnątrz komórki, a jej otoczeniem wynosi około 70 mV (umownie -70 mV, gdyż akson komórki nerwowej jest elektrycznie spolaryzowany ujemnie względem środowiska zewnętrznego). Różnica ta nazywana jest potencjałem spoczynkowym lub błonowym. Oznacza ona, że równowaga pomiędzy wewnątrz, a zewnątrz komórki jest stabilna i nie ulega zmianom [20].

Bodźce elektryczne, mechaniczne bądź chemiczne mogą wpłynąć na potencjał spoczynkowy neuronu. W zależności od działania bodźca, może on doprowadzić błonę komórkową do depolaryzacji lub hiperpolaryzacji. Pierwszy z tych stanów oznacza, że potencjał błonowy staje się mniej ujemny. W drugim przypadku staje się on bardziej ujemny. Depolaryzacja błony zbliża neuron do stanu pobudzenia neuronu, czyli takiego, w którym dochodzi do powstawania i przekazywania impulsu nerwowego. Jej hiperpolaryzacja z kolei zmniejsza pobudliwość neuronu, czyli prowadzi do hamowania odpowiedzi neuronu [20].

Jeżeli bodziec lub suma mniejszych bodźców jest wystarczająco silna i przekroczy wartość progową wynoszącą około -55 mV, generowany jest potencjał czynnościowy, zwany też iglicowym. Po gwałtownej depolaryzacji błony następuje repolaryzacja, w czasie której następuje spadek potencjału poniżej wartości spoczynkowej. Przykład wygenerowanego potencjału czynnościowego został przedstawiony na rysunku 3. Jest on elektrycznym pobudzeniem rozchodzącym się wzdłuż błony aksonu do zakończeń aksonowych. W trakcie generowania impulsu, komórka wchodzi w okres refrakcji bezwzględnej, w czasie której, niezależnie od siły pobudzenia, nie wygeneruje następnego potencjału czynnościowego. Potem komórka wchodzi w okres refrakcji względnej, w czasie której jest w stanie generować potencjały, jeżeli bodźce pobudzające będą odpowiednio silne. Później potencjał błonowy wraca do stanu spoczynkowego.



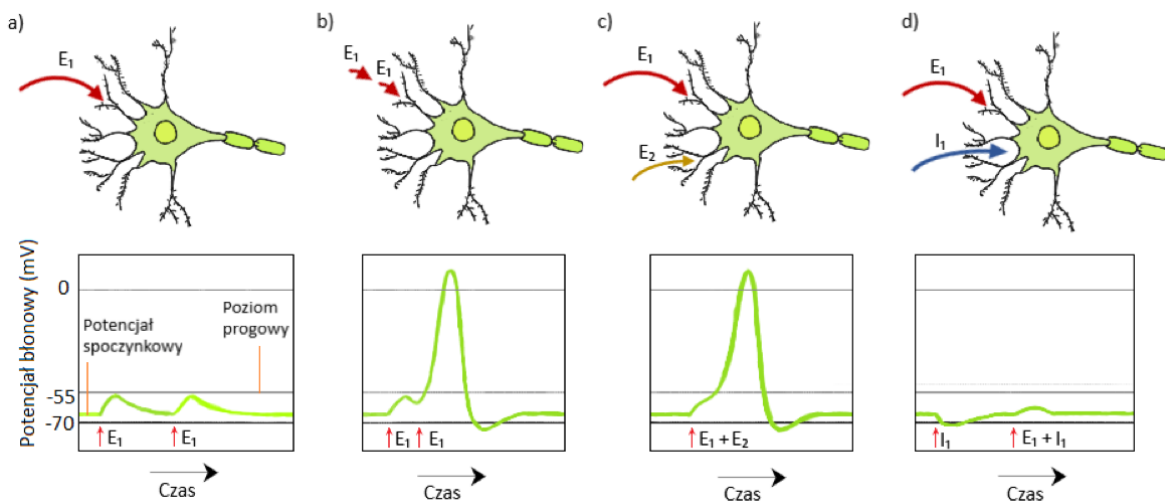
Rysunek 3. Potencjał czynnościowy.
Na podstawie: [20].

Pomiędzy neuronami znajdują się łączące je synapsy. Sygnał pomiędzy synapsami jest przekazywany elektrycznie bądź częściej chemicznie (sygnał jest przenoszony za pomocą neuroprzekaźnika). Neuronem presynaptycznym jest nazywany neuron, znajdujący się przed daną synapsą, zaś postsynaptycznym ten, który ma w niej swój początek. W zależności od neuroprzekaźników i związanych z nimi receptorów, neuron postsynaptyczny może odbierać postsynaptyczne potencjały pobudzające (EPSP, ang. *Excitatory Postsynaptic Potential*), które depolaryzują błonę, bądź postsynaptyczne potencjały hamujące (IPSP, ang. *Inhibitory Postsynaptic Potential*), hiperpolaryzujące ją. EPSP i IPSP są odpowiedziami ulegającymi gradacji, czyli mogą być silniejsze lub słabsze.

Powstawanie potencjału czynnościowego jest wynikiem zachodzącego sumowania czasowego i przestrzennego EPSP i IPSP. Podczas sumowania czasowego następuje sumowanie sygnałów, które pojawiają się przed zniknięciem poprzedniego. W przypadku sumowania przestrzennego neuron postsynaptyczny jest stymulowany jednocześnie przez kilka neuronów, uwalniających swoje neuroprzekaźniki [20].

Zagadnienie sumowania potencjałów EPSP i IPSP zostało zilustrowane na rysunku 4. Symbolami E_1 i E_2 oznaczono dwa EPSP pochodzące z dwóch różnych miejsc, a I_1 oznacza IPSP. Pierwszy rozpatrywany przykład został zilustrowany na rysunku 4a, gdzie dwa słabe bodźce E_1 są rozdzielone w czasie i są zbyt słabe by samodzielnie wywołać potencjał czynnościowy. Na rysunku 4b pokazano sposób w jaki zachodzi sumowanie czasowe. Dwa bodźce E_1 zbyt słabe by samodzielnie wywołać potencjał czynnościowy z tego samego miejsca pojawiają się w krótkim odstępie czasowym. Po zsumowaniu potencjał błony

przekracza poziom progowy, co powoduje wygenerowanie potencjału czynnościowego. Sumowanie przestrzenne zaprezentowano na rysunku 4c, gdzie pod wpływem jednoczesnych słabych bodźców E_1 i E_2 pochodzących z różnych miejsc następuje zsumowanie obu potencjałów, zostaje przekroczony poziom progowy i wygenerowany potencjał czynnościowy. Sumowanie przestrzenne EPSP i IPSP zostało pokazane na rysunku 4d, gdzie potencjały E_1 i I_1 , czyli potencjały pobudzające i hamujące wzajemnie się niwelują, w wyniku czego nie zostaje wygenerowany potencjał czynnościowy.




Rysunek 4. Sumowanie IPSP i EPSP.
Na podstawie: [66].

Zjawiska elektryczne, które pojawiają się w momencie pobudzenia komórki mogą zostać zarejestrowane za pomocą odpowiednich mikroelektrod znajdujących się w pobliżu badanej komórki. Architektura dendrytu wpływa na pola elektryczne generowane przez pojedynczą komórkę. Jeżeli dendryty są ulokowane promieniście wokół ciała komórkowego, pola elektryczne mogą się znosić, a jeżeli są ulokowane w znacznym stopniu równoległe, mogą się wzmacniać tworząc rozległe pole elektryczne zwane polem otwartym. W strukturach o podobnej orientacji przestrzennej pola elektryczne neuronów sumują się, co sprzyja wykrywalności zespołów generujących zjawiska bioelektryczne [67]. Z tego powodu pola struktur warstwowych, takich jak kora mózgu są możliwe do wykrycia z dalszych odległości, niż wynikałoby to z wartości stałych przestrzennych (wielkość zaniku potencjału wraz z oddalaniem się od miejsca pobudzenia) dla danych struktur komórkowych [67]. Dzięki temu elektroda umieszczona na powierzchni skóry głowy jest w stanie zarejestrować zmiany napięcia spowodowane aktywnością elektryczną struktur mózgowych.

2.2. Akwizycja sygnału EEG

Do rejestracji sygnału EEG wykorzystywane są elektrody rozlokowane na powierzchni skóry głowy osoby badanej. Czynność mózgu jest przestrzennie uporządkowana, dlatego określono pewne sposoby ułożenia elektrod na głowie. Najpopularniejszym standardem jest układ 10-20 [68]. Umieszczenie elektrod stosowane w tym układzie zostało przedstawione na rysunku 5.



Rysunek 5. Układ elektrod 10-20. Widok od góry.
Na podstawie: [68].

Nazwa tego systemu wywodzi się od procentowych odległości pomiędzy punktami charakterystycznymi (10 %) i elektrodami (20 %). Każda z elektrod ma ściśle określone miejsce i nazwę, zawierającą literę oraz cyfrę. Użyte litery są akronimami od obszarów mózgu, nad którymi znajdują się elektrody: Fp – *pre-frontal* (biegun czołowy), F – *frontal* (płat czołowy), C – *central* (punkt centralny), T – *temporal* (płat skroniowy), P – *parietal* (płat ciemieniowy), O – *occipital* (płat potyliczny), A – *auditory* (elektrody przymocowane do płatków uszu). Cyfry wskazują na stronę głowy, po której znajdują się elektrody – elektrody oznaczone cyfrą parzystą są umiejscowione po prawej stronie, nieparzystą po lewej. Elektrody na środku głowy nie oznaczają się cyfrą, tylko literą z (od *zero*). Układane są wzdłuż linii łączącej *nasion* (wgnębienie przy nasadzie nosa) oraz *inion* (guzowatość potyliczną). Centralna linia elektrod w tym układzie znajduje się w połowie tej odległości [37].

W klasycznym układzie stosuje się 21 elektrod (19 elektrod czynnych i 2 referencyjne A1, A2). W zależności od zastosowań możliwa jest modyfikacja tego systemu umożliwiająca

użycie większej bądź mniejszej liczby elektrod. Mniejsza liczba elektrod w stosunku do tradycyjnego zestawu 19 elektrod czynnych jest zazwyczaj używana w badaniach, w których wystarczy mniejsza rozdzielczość przestrzenna, przykładowo podczas większości badań EEG-neurobiofeedback lub w trakcie akwizycji sygnału za pomocą opasek EEG, czyli noszonych na głowie komercyjnych urządzeń, służących do rejestrowania bioelektrycznej aktywności mózgu. Przykładowe opaski zostały zaprezentowane na rysunkach 6a i 6b. Na rysunku 6c pokazano przykładową akwizycję sygnału EEG za pomocą czepka silikonowego, czyli nakrycia głowy wykonanego z elastycznego materiału silikonowego, używanego do umocowania elektrod na skórze głowy. W porównaniu do komercyjnych opasek EEG, daje on większą swobodę w doborze oraz umiejscowieniu elektrod.



Rysunek 6. Przykłady urządzeń do akwizycji sygnału EEG.

a) 14-kanalowa opaska EMOTIV EPOCx. Źródło: <https://www.emotiv.com/epoc-x/> [online] 25.03.2023;

b) 4-kanalowa opaska Muse 2. Źródło: <https://choosemuse.com/muse-2/> [online] 25.03.2023;

c) akwizycja za pomocą czepka silikonowego. Źródło: [69].

W wyniku akwizycji sygnału EEG otrzymuje się zbiór przebiegów zmian napięcia w czasie dla każdej z elektrod względem elektrody referencyjnej. Zazwyczaj jest ona umieszczana w miejscu, znajdującym się na tyle blisko źródła sygnału by docierały do niej artefakty wpływające na sygnał, lecz na tyle daleko od niego by nie docierała do niej badana aktywność bioelektryczna. W ten sposób obliczając różnicę między elektrodą czynną, a referencyjną, następuje częściowe wy tłumienie zakłóceń współbieżnych. Częstym punktem umieszczenia elektrody referencyjnej jest miejsce znajdujące się na linii bruzdy środkowej mózgu pomiędzy elektrodami Fp_1 i Fp_2 (Fp_z) albo jako elektrodę referencyjną często przyjmuje się którąś z elektrod usznych (A_1 , A_2) bądź obie te elektrody (wtedy sygnał referencyjny może być wyznaczony jako średnia sygnałów z obu elektrod) [37], [70].

Sygnał EEG może być analizowany zarówno poprzez wykorzystanie odprowadzeń unipolarnych (jednobiegunowych) i bipolarnych (dwubiegunowych). Odprowadzenia unipolarne reprezentują sygnał jako zbiór różnic napięć pomiędzy elektrodami czynnymi,

a referencyjną. Zaletą analizy sygnału przedstawionego w ten sposób jest możliwość ilościowej oceny czynności bioelektrycznej w danym miejscu oraz uzyskania względnie dokładnych danych o kształcie, wielkości oraz biegunowości zmian potencjałów [37].

W przypadku odprowadzeń bipolarnych analizowany jest sygnał pomiędzy dwoma elektrodami zarejestrowanymi w sposób unipolarny. Ten sposób umożliwia lokalizację czynności bioelektrycznych na podstawie między innymi wyszukiwania punktów zmiany faz [37]. Sposoby łączenia ze sobą tych elektrod definiowane są za pomocą odpowiednich montażu bipolarnych. Wśród schematów montażu bipolarnych można wyróżnić między innymi podłużne montażu bipolarne (elektrody są łączone w liniach prostych od przodu do tyłu) oraz poprzeczne montażu bipolarne (elektrody są łączone od strony prawej do lewej).

W badaniach przedstawionych w rozprawie wykorzystano sygnały zarejestrowane za pomocą 19 elektrod czynnych i elektrody referencyjnej A2. Sygnały były analizowane z wykorzystaniem odprowadzeń unipolarnych.

2.3. Charakterystyka sygnału EEG

Rutynowe badanie EEG trwa zazwyczaj około 20 minut. W zależności od przeprowadzanych badań i potrzeb czas ten może ulegać zmianie. Rejestracja sygnału często występuje w paśmie 0,2-70 Hz, choć zakresy częstotliwości mogą być zmieniane w oprogramowaniu używanym do akwizycji sygnału. Cechą charakterystyczną sygnałów EEG jest ich niska amplituda, zazwyczaj poniżej 100 μV . Sygnał ten jest stochastyczny i niestacjonarny, dodatkowo często w rejestracjach występują artefakty, czyli zmiany w zapisie, które nie są pochodzenia mózgowego [37]. Występujące w sygnale EEG zakłócenia możemy podzielić na artefakty [37], [38]:

- Pochodzenia technicznego, których źródłem są zjawiska fizyczne w otoczeniu badanego, usterki aparatury lub nieodpowiednia metoda pomiarowa. Przyczyną tych artefaktów jest przeprowadzanie pomiarów w nieekranowanych pomieszczeniach, niewłaściwe uziemienie sprzętu lub nieprawidłowe założenie elektrod, które zwiększa impedancję pomiędzy elektrodą, a skórą. Wśród najczęściej występujących artefaktów technicznych wyróżnić można zakłócenia sieciowe o częstotliwości 50 lub 60 Hz i ich harmoniczne, wahania linii bazowej oraz nagłe zmiany napięcia w postaci iglic. Podstawowymi sposobami zmniejszania wpływu artefaktów technicznych na sygnał EEG jest oddalenie pacjenta, aparatury i przewodów od źródła zakłóceń oraz ekranowanie ich. Dodatkowo można zmniejszyć oporności pomiędzy elektrodą, a skórą za pomocą odgarnięcia

włosów pomiędzy nimi, użycia specjalnej pasty przewodzącej bądź oczyszczenia powierzchni skóry głowy badanego.


- Pochodzenia biologicznego (fizjologiczne), których przyczyną są inne sygnały biomedyczne spowodowane funkcjonowaniem ciała osoby badanej. Przyczyną tych artefaktów mogą być zakłócenia pochodzące z sygnału elektrookulograficznego (EOG) powodowane przez ruchy oka i zmiany jego polaryzacji. Innymi przykładami są zakłócenia elektrokardiograficzne (EKG), wynikające z czynności bioelektrycznej serca, oraz elektromiograficzne (EMG), spowodowane czynnością bioelektryczną mięśni. Do tej kategorii artefaktów zaliczają się również zakłócenia wynikające ze zmian oporności skóry, których przykładową przyczyną może być pot. Wpływ zakłóceń biologicznych może być minimalizowany przez stosowanie możliwie najlepszych warunków pomiarowych, m.in. poprzez ułożenie badanego w wygodnej pozycji, poproszenie go by się nie ruszał lub o to, by lekko otworzył usta, jeżeli zaciska szczęki.

2.4. Charakterystyka rytmów sygnału EEG

Pomimo swojej zmienności sygnał EEG zawiera pewne regularności, które umożliwiają wyróżnienie charakterystycznych grafoelementów. Te elementy są graficznym wyrazem określonych zjawisk bioelektrycznych występujących w obrębie głowy osoby badanej. Podstawową strukturą tych grafoelementów są fale będące prostą, krótkotrwałą zmianą różnicy potencjałów w EEG [37]. Rytm składa się z fal o podobnym kształcie, powtarzających się z pewną częstotliwością [37].

Poniżej zamieszczono krótki opis podstawowych rytmów obecnych w sygnale EEG, z kolei na rysunkach 7–11 zilustrowano ich kształty. Osie poziome zostały wyrażone w sekundach. Osie pionowe nie zostały opisane przez autora rysunków.

Rytm delta (δ) składa się z wysokonapięciowych fal o zakresie częstotliwości 1-4 cykli na sekundę i amplitudzie wynoszącej około 50 μV bądź wyższej [38]. Występują one u dzieci oraz u dorosłych w czasie snu. Wyrażna obecność rytmu delta u dorosłych w czasie czuwania świadczy o patologii, co wyraża również jego nazwa – została ona wprowadzona w 1936 roku przez G. Waltera, dla skojarzenia ze stanami chorobowymi (*disease*), zwyrodnieniem (*degeneration*), śmiercią (*death*) i mechanizmem obronnym (*defence*) [71]. Na rysunku 7 zilustrowano przykładowe fale delta.




Rysunek 7. Fale delta.

Autor oryginału: Hugo Gamboa. Licencja: CC BY-SA 3.0. Bez zmian.

Źródło: https://commons.wikimedia.org/wiki/File:Eeg_delta.svg [online] dostęp 26.03.2023.

Rytm theta (θ) odnosi się do fal o zakresie częstotliwości 4-8 cykli na sekundę [37] oraz amplitudzie do 30 μV [38]. Fale theta mogą wyraźnie występować w stanie hiperwentylacji, w czasie drzemki oraz u dzieci przed okresem dojrzewania. Mogą pojawiać się w czasie medytacji, transu, hipnozy, intensywnych emocji bądź marzenia [72]. Przykładowe fale theta zostały przedstawione na rysunku 8. U większości osób występuje przewaga czynności theta w lewej okolicy skroniowej [67].




Rysunek 8. Fale theta.

Autor oryginału: Hugo Gamboa. Licencja: CC BY-SA 3.0. Bez etykiety osi odciętych.

Źródło: https://commons.wikimedia.org/wiki/File:Eeg_theta.svg [online] dostęp 26.03.2023.

Rytm alfa (α) zawiera fale o amplitudach do 100 μV [67] i zakresie częstotliwości 8-12 cykli na sekundę [72]. Ich przykład zaprezentowano na rysunku 9. Fale te są wynikiem aktywności neuronów w ośrodkach wzrokowych w płatach potylicznych, gdy osoba badana odpoczywa z zamkniętymi oczyma. [20]. Zanikają pod wpływem napięcia uwagi, przede wszystkim wzrokowej [37]. Zanik bądź zmniejszenie fal alfa pod wpływem bodźców świetlnych nosi nazwę reakcji zatrzymania [71]. Rytm ten posiada stosunkowo regularną, niemal sinusoidalną strukturę. Jest on szczególnie widoczny w sygnałach EEG zarejestrowanych z elektrod znajdujących się w tylnej części głowy. W tym samym paśmie częstotliwości pojawia się również rytm mu (μ), który można zarejestrować w okolicach kory motorycznej [72].




Rysunek 9. Fale alfa.

Autor oryginału: Hugo Gamboa. Licencja: CC BY-SA 3.0. Bez zmian.

Źródło: https://commons.wikimedia.org/wiki/File:Eeg_alpha.svg [online] dostęp 26.03.2023.

Rytm beta (β) obejmuje fale o amplitudach zazwyczaj do 25-30 μV [67] i zakresie częstotliwości 12-30 cykli na sekundę [72]. Fale te dominują w czasie aktywności umysłowej. Pojawiają się w trakcie zadań związanych z percepcją czy przetwarzaniem informacji [20]. Uważa się, że rytm beta jest związany z procesami przenoszenia uwagi wzrokowej [73], a zanika pod wpływem bodźców kinestetyczno-ruchowych [37]. Rysunek 10 przedstawia przykładowe fale beta.




Rysunek 10. Fale beta.

Autor oryginału: Hugo Gamboa. Licencja: CC BY-SA 3.0. Bez zmian.

Źródło: https://commons.wikimedia.org/wiki/File:Eeg_beta.svg [online] dostęp 26.03.2023.

W rytmie gamma (γ) wyróżnić można fale o zakresie częstotliwości powyżej 30 cykli na sekundę towarzyszące czynnościom ruchowym i motorycznym. Rytm związany jest z wyższymi procesami poznawczymi, przykładowo percepcją sensoryczną i pamięcią [72]. Przykładowe fale gamma zostały zaprezentowane na rysunku 11.



Rysunek 11. Fale gamma.

Autor oryginału: Hugo Gamboa. Licencja: CC BY-SA 3.0. Bez zmian.

Źródło: https://commons.wikimedia.org/wiki/File:Eeg_gamma.svg [online] dostęp 26.03.2023.


Stochastyczna i nieokresowa natura sygnału EEG sprawia, że różnice pomiędzy poszczególnymi rytmami są płynne i często w publikowanych pracach nieznacznie różnią się

między sobą ich amplitudy oraz granice zakresów ich częstotliwości. W rozprawie przyjęto przedstawione w tabeli 1 jedne z najczęściej wymienianych w literaturze zakresów częstotliwości, ustalone ze współpracownikami z Instytutu Biologii Doświadczalnej PAN im. Marcelego Nenckiego w Warszawie, z którymi prowadzono badania. Zakresy te zostały później użyte do zidentyfikowania określonych podpasów w widmie badanego sygnału.

Tabela 1. Zakresy częstotliwości podpasów widma sygnału EEG przyjęte w rozprawie.

Nazwa rytmu	Częstotliwość minimalna [Hz]	Częstotliwość maksymalna [Hz]
δ	1	4
θ	4	8
α	8	12
β	12	30
γ	30	45

Na rysunku 12 przedstawiono fragment zarejestrowanego sygnału EEG wyświetlony w podłużnym montażu bipolarnym. Zawiera on część z opisanych w tym punkcie rytmów. Literą A oznaczono wyraźnie widoczne fale alfa, zarejestrowane przez elektrody z tylnej części głowy. Literą B oznaczono zanik tych fal po otwarciu oczu. Wysokonapięciowe fale beta zostały zaznaczone literą C. Na rysunku widoczne są również zakłócenia biologiczne sygnałem EOG spowodowane zamknięciem oczu (D) oraz ich otwarciem (E). Artefakty te są widoczne na wielu kanałach, a ich amplituda przekracza amplitudę sygnału EEG.



Rysunek 12. Fragment zapisu EEG z dnia 07.07.2016 r. wyświetlony w programie EDFbrowser. Na podstawie: [33].

2.5. Podsumowanie rozdziału

Rozdział ten poświęcono krótkiemu przybliżeniu właściwości sygnału EEG. Na początku został omówiony mechanizm powstawania sygnału i jego źródła fizjologiczne, które są przyczyną jego osobniczej niepowtarzalności. Następnie przedstawiono sposób umiejscawiania elektrod służących do rejestracji sygnału EEG i opisano sposoby jego akwizycji. W dalszej części przedstawiono ogólną charakterystykę sygnału EEG, jego zakresy amplitud i częstotliwości oraz opisano kwestie związane z zakłóceniami technicznymi i biologicznymi sygnału EEG. Scharakteryzowano poszczególne rytmy, które można wyróżnić w sygnale EEG oraz ich znaczenie fizjologiczne. Określono ich zakresy częstotliwości, przyjęte do przeprowadzanych rozważań i analiz w dalszej części rozprawy.

3. Zastosowanie elektroencefalografii w biometrii

Według słownika języka polskiego PWN [74] biometria jest nauką zajmującą się badaniem prawidłowości kierujących zmiennością cech populacji organizmów żywych, posługującą się metodami statystyki matematycznej oraz opisującą techniki dokonywania ich pomiarów. Jej nazwa pochodzi od greckich słów *bios* i *metron* oznaczających kolejno życie oraz pomiar. Ten dział nauki nie precyzuje jednak dokładnego zastosowania zarejestrowanych danych.


Aspektem biometrii, którego dotyczy ta praca jest biometryczne rozpoznawanie tożsamości, definiowane jako automatyczne rozpoznawanie tożsamości osób dzięki ich unikalnym cechom fizycznym lub behawioralnym [13]. Cechy fizyczne są związane z właściwościami anatomicznymi danej osoby, a cechy behawioralne z zachowaniem i działaniem osoby w czasie. Cechy te po zarejestrowaniu są przetwarzane w celu utworzenia wzorca, który jest zapisywany i przechowywany w bazie, by później mógł zostać użyty do porównań ze wzorcami pochodzącymi od aktualnie rozpoznawanej osoby. Ważne jest, żeby przekształcenie we wzorzec było jednokierunkowe, tak aby nie dało się odtworzyć z niego oryginalnego źródła cech. Cecha biometryczna jest przypisana do konkretnej osoby fizycznej i nie ulega (bądź ulega bardzo wolno) zmianom w czasie.

W tym rozdziale krótko opisano zastosowanie elektroencefalografii w biometrii. Scharakteryzowano podstawowe pojęcia stosowane w tej dziedzinie oraz zdefiniowano metody oceny jakości weryfikacji stosowane w rozprawie. Następnie rozpatrzono wykorzystanie sygnału EEG jako źródła cech biometrycznych oraz przedstawiono przegląd literatury dotyczący badań nad rozpoznawaniem tożsamości osób z wykorzystaniem tego sygnału.

3.1. Podstawowe pojęcia biometrii

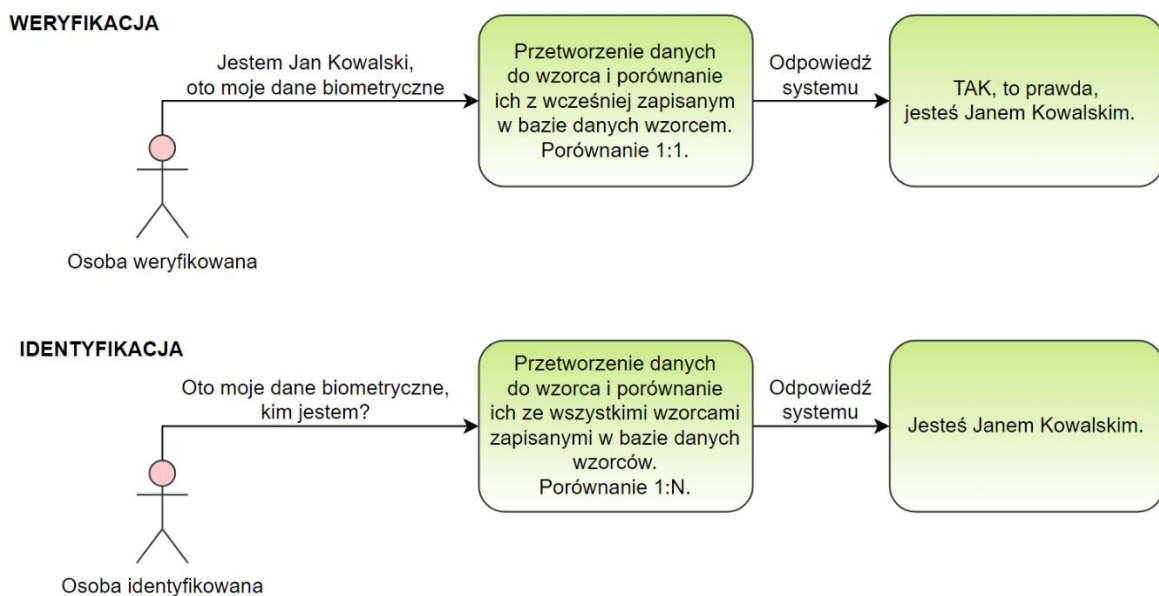
Pomiar biometryczny obejmuje rejestrację fizycznych sygnałów lub obrazów z organizmu oraz ich przetworzenie na dane w postaci cyfrowej, które są poddawane dalszej obróbce i umożliwiają rozpoznawanie tożsamości osób. Na rysunku 13 przedstawiono uproszczony schemat typowego pomiaru biometrycznego. Na początku następuje pomiar fizycznej lub behawioralnej cechy biometrycznej (ang. *biometric characteristic*), którą można wyekstrahować na potrzeby biometrycznego rozpoznawania [13]. Wynikiem pomiaru jest próbka biometryczna (ang. *biometric sample*), która jest analogową lub cyfrową (sygnał lub obraz) reprezentacją cechy biometrycznej [13]. Przykładem jest obraz linii papilarnych. Kolejnym etapem jest wyznaczenie parametrów cechy (ang. *biometric feature*), które można użyć w procesie porównania [13]. Przykładem mogą być długości palców. Wynikiem

tych działań jest powstanie wzorca biometrycznego (ang. *biometric reference*). Jest to dana referencyjna zachowywana w bazie danych na potrzeby rozpoznawania biometrycznego. Przykładem mogą być odległości pomiędzy charakterystycznymi punktami linii papilarnych (minucjami) [13].



Rysunek 13. Pomiar biometryczny.

Jak opisano w punkcie 1.1 rozpoznawanie biometryczne można podzielić na ustalenie tożsamości (identyfikacja) lub potwierdzenie tożsamości (weryfikacja) [13]. Schematy procesów weryfikacji i identyfikacji zaprezentowano na rysunku 14.



Rysunek 14. Schematy procesów weryfikacji oraz identyfikacji. N -liczba wzorców w przeszukiwanej bazie.

3.2. Metody oceny jakości klasyfikacji

Podczas opracowywania algorytmów rozpoznawania tożsamości niezbędna jest ewaluacja ich jakości. Zazwyczaj odbywa się to na podstawie statystycznych miar oceny jakości klasyfikacji. W wielu pracach są stosowane różne miary lub te same miary noszące różne nazwy [2].

W rozprawie przyjęto metody oceny jakości weryfikacji biometrycznej odpowiadające typowym miarom oceny jakości klasyfikacji, jakimi są dokładność ACC (ang. *accuracy*) (1), czułość SEN (ang. *sensitivity*) (2), swoistość SPEC (ang. *specificity*) (3), precyzja PREC (ang. *precision*) (4), współczynnik fałszywych akceptacji FAR (ang. *False Acceptance Rate*) (5) i współczynnik fałszywych odrzuceń FRR (ang. *False Rejection Rate*) (6). Miary te są wyrażone następującymi wzorami [2], [75]–[77]:

$$ACC = \frac{TP + TN}{TP + FN + FP + TN}, \quad (1)$$

$$SEN = \frac{TP}{TP + FN}, \quad (2)$$

$$SPEC = \frac{TN}{FP + TN}, \quad (3)$$

$$PREC = \frac{TP}{TP + FP}, \quad (4)$$

$$FAR = 1 - SPEC = \frac{FP}{FP + TN}, \quad (5)$$

$$FRR = 1 - SEN = \frac{FN}{TP + FN}, \quad (6)$$

gdzie:

- *TP (True Positive)* – liczba przypadków prawdziwie pozytywnych, czyli prawidłowo potwierdzonych tożsamości (*match*),
- *TN (True Negative)* – liczba przypadków prawdziwie negatywnych, czyli prawidłowo odrzuconych próbek biometrycznych osób podszywających się pod kogoś innego (*non-match*),
- *FP (False Positive)* – liczba przypadków fałszywie pozytywnych, odpowiadających błędowi fałszywej akceptacji (*false acceptance* lub *false match*), w kontekście tej pracy oznaczających nieprawidłowe potwierdzenie tożsamości osoby podszywającej się pod kogoś innego,
- *FN (False Negative)* – liczba przypadków fałszywie negatywnych, odpowiadających błędowi fałszywego odrzucenia (*false rejection* lub *false non-match*), w kontekście tej pracy oznaczających nieprawidłowe uznanie osoby weryfikowanej za osobę podszywającą się pod kogoś innego.

W przeprowadzonych badaniach, dokładność może być interpretowana jako procent prawidłowo zaklasyfikowanych próbek biometrycznych, czułość jako zdolność do prawidłowego potwierdzania tożsamości osób weryfikowanych, swoistość jako zdolność

do wykrywania intruzów i precyzja jako procent prawidłowo potwierdzonych próbek osoby weryfikowanej do wszystkich próbek rozpoznanych jako ta osoba.

Inną miarą oceny jakości klasyfikacji wykorzystywaną w biometrii jest błąd zrównoważony EER (ang. *Equal Error Rate*), czyli punkt, w którym współczynniki FAR i FRR są sobie równe. Im niższa jego wartość, tym lepiej działa klasyfikator. Zazwyczaj, kiedy wzrasta FAR, maleje FRR i odwrotnie, choć w idealnym systemie obie te wartości byłyby równe zero.

3.3. Analiza sygnału EEG jako źródła cech biometrycznych

Podczas projektowania systemów biometrycznych opartych na sygnale EEG należy uwzględnić między innymi [14], [78]:

- Uniwersalność (*universality*) – system powinien być oparty na cesze, której próbka może zostać pobrana od możliwie największej liczby osób [78]. Sygnał EEG spełnia tę właściwość, gdyż może zostać pozyskany z każdej żywej osoby od jej narodzin, do śmierci, pomimo, że w ciągu całego życia ulega on zmianom (sygnał EEG niemowlęcia czy dziecka różni się od sygnału EEG osoby dorosłej). Nie wszystkie cechy biometryczne spełniają tę właściwość, np. żywa osoba może na którymś etapie życia stracić palec, co uniemożliwiłoby analizę jego odcisku, czy zawartych w nim naczyń krwionośnych.
- Unikalność (*uniqueness*) – różnice pomiędzy wzorcami dwóch różnych osób powinny być większe niż różnice pomiędzy wzorcami tej samej osoby, ale uzyskanymi innego dnia. Uważa się, że sygnał EEG spełnia tę właściwość [36].
- Niezmiennność (*permanence*) – cecha nie powinna ulegać szybkim zmianom w czasie. Cechy sygnału EEG w stanie spoczynku są wysoce dziedziczne [79], [80], co sugeruje, że spoczynkowe EEG zawiera stałe indywidualne cechy sygnału, które mogą zostać wykorzystane w biometrii.
- Łatwość pobrania (*collectability*) – dotyczy stopnia łatwości i skuteczności pomiaru oraz możliwości realizacji technicznej. Akwizycja powinna być szybka i wygodna dla użytkownika, nieinwazyjna. Jednym z aspektów niniejszej rozprawy jest próba zminimalizowania liczby elektrod używanych do akwizycji sygnału EEG w celu weryfikacji tożsamości.
- Łatwość obejścia (*circumvention*) – system musi być odporny na fałszerstwa, próby ominięcia lub złamania poprzez stosowanie fałszywych sygnałów lub innych metod nieautoryzowanego dostępu.

- Akceptowalność (*acceptability*) – system powinien być akceptowalny przez użytkowników. Zastosowanie sygnału EEG budzi pewne obawy w związku z możliwością ujawnienia danych wrażliwych takich jak stan zdrowia oraz informacji o zmęczeniu, stanie upojenia alkoholowego czy stresie [78].

Rozróżnianie ludzi na podstawie sygnału EEG polega na analizie unikalnych cech tego sygnału, wynikających z indywidualnych właściwości mózgu będących rezultatem jego budowy fizycznej oraz od psychicznego ukształtowania danej osoby. Dokładność rozpoznawania tożsamości osób z wykorzystaniem sygnału EEG zależy również od sposobu rejestracji sygnału, jakości danych treningowych, a także od wykorzystanych metod analizy.

Potencjalnych zastosowań sygnału EEG do biometrycznej weryfikacji tożsamości osób można szukać między innymi w systemach:

- Charakteryzujących się wysokim stopniem poufności – sygnał EEG może zostać wykorzystany do autoryzacji dostępu do chronionych informacji lub pomieszczeń, tak aby dostęp był udzielany tylko osobom uprawnionym.
- Opartych na ciągłym potwierdzaniu tożsamości – za przykład może posłużyć pilotowanie wojskowego drona lub prowadzenie rozmowy dyplomatycznej. Sygnał EEG ma tę zaletę, że osoba, której sygnał jest rejestrowany może znajdować się w dowolnej pozycji.
- BCI lub neurobiofeedback – weryfikacja tożsamości osób może zostać użyta do potwierdzenia tożsamości podczas przypisania protokołu obsługi urządzenia lub treningu dla danej osoby albo do potwierdzenia dopasowania właściwego protokołu. Prosty system biometryczny może być użyty do wspomaganie decyzji personelu medycznego (potwierdzenie, że dany trening jest przeprowadzany dla właściwej osoby) oraz być pomocny dla osób z zaburzeniami neurologicznymi podczas korzystania z komputera lub wózka inwalidzkiego.

Zastosowań sygnału EEG w rozpoznawaniu biometrycznym można również szukać w systemach medycznych, gdzie takie metody mogą zostać wykorzystane do sprawdzenia, czy pacjent w danej placówce nie miał już robionego badania. Taka sytuacja może zdarzyć się przykładowo w przypadku pomyłki w zapisie danych osobowych, wymiany dokumentu potwierdzającego tożsamość (np. dowodu osobistego) lub zmiany nazwiska. Rozpoznawanie tożsamości z wykorzystaniem sygnału EEG może też znaleźć zastosowanie w badaniach naukowych, w których dane są zanonimizowane bądź stosowana jest podwójnie ślepa próba, czyli w badaniach, w których ani osoby koordynujące eksperyment ani jego uczestnicy nie mają

dostępu do informacji mogących wpłynąć na jego przebieg (np. o przynależności badanego do grupy eksperymentalnej). System biometryczny oparty na sygnale EEG mógłby przypisywać przeprowadzone badania odpowiednim pacjentom, bez udziału osób przeprowadzających eksperyment.

Chociaż sygnał EEG jest specyficzny dla każdej osoby, podlega on pewnym zmianom w zależności od stanu emocjonalnego, zmęczenia oraz innych czynników. Z tego powodu ważnym jest opracowanie odpowiednich algorytmów, które mimo tych utrudnień zapewnią ekstrakcję niezmiennych w czasie cech osobniczych z tego sygnału. Biometryczne metody rozpoznawania tożsamości na jego podstawie wciąż wymagają dalszych badań i rozwoju technologicznego. Trudność w realizacji tych badań wynika z braku ujednoczonych, dobrze opisanych procedur opracowywania algorytmów weryfikacji tożsamości na podstawie sygnału EEG oraz z problemów związanych ze skompletowaniem odpowiednio dużych zbiorów rejestracji tego sygnału – wynikają one z dosyć długiego czasu potrzebnego na przygotowanie osoby do akwizycji sygnału EEG. Trwają prace nad zastosowaniem w rozpoznawaniu tożsamości osób komercyjnych opasek do rejestracji sygnału EEG [81] w celu skrócenia czasu przygotowania do akwizycji.

3.4. Przegląd metod rozpoznawania tożsamości osób na podstawie sygnału EEG

Historia rozpoznawania tożsamości osób na podstawie sygnałów EEG jest stosunkowo krótka. Pod koniec XX wieku zademonstrowano potencjał zastosowania sygnału EEG w rozpoznawaniu tożsamości osób na podstawie cech biometrycznych znajdujących się w sygnale EEG zarejestrowanym w stanie spoczynku z zamkniętymi oczyma [17]–[19]. Jednak dopiero od roku 2010 nastąpił znaczący wzrost zainteresowania tymi metodami [14]. Sygnał EEG może być używany zarówno do identyfikacji [42], [82], jak i do weryfikacji [47], [52], [53] tożsamości osób.

Sposoby akwizycji sygnału EEG w zastosowaniach biometrycznych można podzielić na [16]:

- Rejestracje potencjałów wywołanych związanych ze zdarzeniem, oparte na zewnętrznej stymulacji. W tych badaniach osobie rozpoznawanej są prezentowane wielokrotnie bodźce, przykładowo świetlne lub dźwiękowe. Rozpoznawanie tożsamości osoby odbywa się na podstawie uśrednionych potencjałów wywołanych wygenerowanych przez mózg. Oczekuje się, że będą one osobnicze i powtarzalne. Za przykład mogą posłużyć prace [42], [83].

- Rejestracje potencjałów wywołanych związanych z zadaniem, oparte na wewnętrznej stymulacji. Podczas akwizycji sygnału osoba badana jest proszona o wykonanie intencjonalnej czynności. Może to być na przykład pomyślenie o jakimś słowie, czy odliczanie w myślach. Rozwiązanie to opisano w pracach [43], [84].
- Rejestracje czynności spoczynkowej EEG, gdzie osoba rozpoznawana jest proszona o zrelaksowanie się z oczyma otwartymi lub zamkniętymi. Ten rodzaj sygnałów może zostać w łatwy sposób zarejestrowany od każdej przytomnej osoby. Zagadnieniem tym zajmowano się m.in. w pracach: [19], [36], [47], [85], [86].

Akwizycja spoczynkowego sygnału EEG jest najpopularniejszym sposobem pozyskiwania tego sygnału i nie wymaga stosowania dodatkowego specjalistycznego oprogramowania oraz sprzętu ponad ten niezbędny do rutynowej rejestracji tego sygnału. Ten sposób akwizycji nie absorbuje w pełni uwagi osoby, której tożsamość jest potwierdzana, co zwiększa liczbę jego potencjalnych zastosowań. Sygnał ten może zostać zarejestrowany z powierzchni głowy osoby chorej psychicznie bądź nie będącej w stanie wykonać prostych czynności. Niezależnie od sposobu czy głębokości koncentracji, wciąż jest to sygnał spoczynkowy odzwierciedlający spontaniczną aktywność mózgu. W pozostałych sposobach akwizycji sygnału EEG mogą wystąpić problemy wynikające z intencjonalnego nieutrzymania uwagi lub spowodowane znudzeniem po odbyciu kilkunastu akwizycji w ciągu miesiąca. Mogą to być przykładowo obserwacje otoczenia zamiast ekranu, na którym prezentowany jest bodziec czy myślenie o tym, że jest się spóźnionym, zamiast wykonywania operacji matematycznych. Ten aspekt jednak powinien zostać dokładniej zbadany i brany pod uwagę podczas opracowywania systemu uwzględniającego sygnał EEG w rozpoznawaniu tożsamości osób.

Za pomocą pozostałych metod rejestracji sygnału możliwe jest uzyskanie bardziej powtarzalnego przebiegu sygnału niż z użyciem rejestracji EEG spoczynkowego, akwizycja jest jednak bardziej czasochłonna. Dodatkowo trzeba brać pod uwagę efekt adaptacji neuronów, który jest fizjologicznym fenomenem spowodowanym przez powtarzające się bodźce. Żeby zapobiegać adaptacji neuronów trzeba śledzić zmiany odpowiedzi bądź używać względnie stabilnych cech sygnału [14].

Rozpoznawanie biometryczne na podstawie spoczynkowego EEG często opiera się na analizie cech spektralnych sygnału i zastosowaniu sieci neuronowych [54]. Integracja otrzymanych informacji z sygnałów zarejestrowanych w ten sposób jest jednak bardziej wymagająca ze względu na niestacjonarne zmiany, wywoływane przez spontaniczną aktywność mózgu, powodującą zmiany kowariancji cech mocy [87], [88].

Prace zaprezentowane przez Poulusa i innych stały się podłożem do badań nad wykorzystaniem sygnału EEG w rozpoznawaniu tożsamości osób [17]–[19]. W tych badaniach, używając jedynie jednej elektrody (O2-Cz), autorom udało się osiągnąć zadawalające wyniki dla 4 osób z 45 sesjami pomiarowymi oraz 75 osób z jedną sesją. W jednej z tych prac [19] analizowano rejestracje sygnału spoczynkowego z zamkniętymi oczyma. Z użyciem Szybkiej Transformaty Fouriera i sieci neuronowych rozpatrywano nakładające się na siebie podpasma odpowiadające zakresowi rytmu alfa. W tych badaniach autorzy weryfikowali tożsamość osób i osiągnęli wartość poprawnej klasyfikacji (ang. *Correct Classification*) w zakresie od 80 % do 100 % dla różnych podpasm i osób.

W 2010 roku, autorzy publikacji [50] przeprowadzili dekompozycję sygnału z użyciem transformaty falkowej oraz sieci neuronowej i osiągnęli współczynnik poprawnej klasyfikacji (CCR, ang. *Correct Classification Rate*) na poziomie 81 % z użyciem 4 elektrod do akwizycji sygnału EEG i 71 % dla dwóch elektrod. Badania były przeprowadzane na grupie 10 osób z 5 rozdzielными sesjami rejestrowanymi przez okres dwóch tygodni. Wyniki były prezentowane dla stanu spoczynkowego z oczyma otwartymi oraz zamkniętymi.

Na przestrzeni lat pojawiały się próby zbadania wpływu liczby rozdzielnych sesji pomiarowych na jakość rozpoznawania tożsamości, m.in. przedstawione w pracy [51]. Autorzy tej publikacji analizowali cechy biometryczne wyekstrahowane z sygnału EEG wykorzystując bazę zawierającą rejestracje 45 zdrowych dorosłych, którym wykonano pomiary potencjałów wywołanych związanych ze zdarzeniem. Zarejestrowano od 5 do 6 rozdzielnych sesji pomiarowych, nagranych na przestrzeni trzech lat. Autorzy w cytowanej pracy używali ukrytych modeli Markova (HMM, ang. *Hidden Markov Models*). W swojej pracy podkreślili, że używanie jedynie jednej sesji akwizycji do przeprowadzania rozpoznawania tożsamości bazującego na sygnale EEG może prowadzić do fałszywie wysokich wyników testowania.

W pracy przeglądowej [14] zauważono, że w większości poprzednich badań związanych z rozpoznawaniem tożsamości za pomocą cech zawartych w sygnale EEG badani uczestniczyli tylko raz lub parę razy. W rzeczywistości jednak większość systemów biometrycznych jest używana regularnie każdego dnia. System też powinien być prosty i umożliwiać użytkownikowi korzystanie z niego samodzielnie bez pomocy osób z zewnątrz. Zwrócono również uwagę na to, że system musi być w stanie rozpoznawać zapisanych użytkowników po upływie dni, tygodni lub lat. Przytoczono przykład badań innych autorów [89], w których współczynnik HTER (ang. *Half Total Error Rate*) wzrósł z 7,1 % do 36,2 % dla rejestracji wykonanych zaledwie po 3 dniach oraz badań [90], gdzie współczynnik TAR (ang. *True Acceptance Rate*) z jednodniowym odstępem pomiędzy rejestracjami wyniósł 94.60 %,

z tygodniowym 83,64 %, a po 6 miesiącach spadł do 78,20 %. Stwierdzono również, że dane używane w zbiorach testowych powinny być niezależne (lub prawie niezależne) od zbioru danych treningowych. Ważniejsze jest by rejestracje sygnałów w zbiorach treningowych i testowych były rozdzielone w czasie, niż jedynie podzielone na różne sposoby za pomocą różnych metod krosvalidacji. Zasygnalizowano także, że sygnały EEG obecne w zbiorach treningowych powinny być zbierane w różnych warunkach, w celu uwzględnienia różnych czynników mogących wpływać na działanie mózgu. Wśród przykładów można wyróżnić leki, które mogą wpłynąć na wzrost mocy w zakresie rytmów beta i theta [91], nikotynę, kofeinę [92], alkohol [93] i inne.

Badania [16], [56] wskazują, że popularne metody ekstrakcji cech obejmują modele szeregów czasowych, takie jak modele autoregresyjne, metody oparte na koherencji oraz metody oparte na cechach spektralnych, głównie na widmowej gęstości mocy (PSD) lub transformacie falkowej. Ponadto w badaniach [16] opisano metody oparte na transformacie kosinusowej, metody oparte na uczeniu nadzorowanym, takie jak liniowa analiza dyskryminacyjna (LDA, ang. *Linear Discriminant Analysis*), wspólny wzorzec przestrzenny (CSP, ang. *Common Spatial Pattern*) i sztuczne sieci neuronowe (ANN, ang. *Artificial Neural Network*). Przedstawiono także metody uczenia nienadzorowanego takie jak metody statystyczne (analiza składowych głównych, analiza składowych niezależnych) czy metody oparte na grupowaniu. W artykułach [16], [56] opisano również metody klasyfikacji takie jak k-najbliższych sąsiadów, sztuczne sieci neuronowe, maszyny wektorów nośnych (SVM, ang. *Support Vector Machines*), metody oparte na uczeniu głębokim i inne.

3.5. Podsumowanie rozdziału

W ostatnich latach wzrosło zainteresowanie wykorzystaniem sygnału EEG jako źródła cech, które można użyć w procesie rozpoznawania tożsamości osób. Cechy osobnicze zawarte w sygnale EEG są unikalne i wynikają z indywidualnych właściwości mózgu będących rezultatem jego budowy fizycznej oraz ukształtowania psychicznego danej osoby. Dokładność rozpoznawania tożsamości z wykorzystaniem tego sygnału zależy jednak od wielu czynników i cały czas trwają prace nad ustaleniem najlepszych sposobów zastosowania tego sygnału do weryfikacji tożsamości osób. Analiza literatury wykazała, że badania, w których przeprowadzono większą liczbę sesji akwizycji sygnału EEG, zazwyczaj osiągają gorsze parametry rozpoznawania.

4. Opis wykorzystywanych metod przetwarzania sygnału EEG i uczenia maszynowego

Rozdział ten został poświęcony przedstawieniu metod przetwarzania sygnału EEG i uczenia maszynowego użytych w rozprawie. Na początku opisano wykorzystywany zbiór sygnałów EEG. Następnie pokazano sposób przetwarzania wstępnego sygnałów oraz cechy, które były z nich wyodrębniane. Na końcu krótko scharakteryzowano wykorzystywane w pracy klasyfikatory.

4.1. Opis analizowanego zbioru rejestracji sygnałów EEG

W trakcie pracy autorka rozprawy we współpracy z Instytutem Biologii Doświadczalnej PAN im. Marcelego Nenckiego zgromadziła duży i spójny zbiór sygnałów EEG. Rejestracje zostały zanonimizowane. Zbiór ten jest znacznie bardziej obszerny niż ogólnodostępne zbiory rejestracji sygnałów EEG i umożliwia przeprowadzenie szczegółowych analiz, które pozwolą ocenić potencjał zastosowania sygnału EEG do regularnej weryfikacji biometrycznej.

Zbiór danych, na którym były przeprowadzane badania składał się z 580 zapisów sygnałów EEG, zarejestrowanych z elektrod umieszczonych na głowach 29 osób (14 kobiet, 15 mężczyzn). Średni wiek badanych wynosił 28,17 lat. Najmłodsza osoba miała 23 lata, najstarsza 44. Dla każdej z tych osób przeprowadzono 20 sesji pomiarowych, które zazwyczaj trwały kilka minut. Każda z tych sesji odbywała się innego dnia. Czas pomiędzy pierwszą, a ostatnią rejestracją średnio wynosił około 70 dni (od 43 do 129 dni). Oprócz tych zapisów, wykorzystano również osobny zbiór 23 pojedynczych rejestracji innych osób, który został użyty do symulowania ataku intruzów. Łącznie posługiwano się 603 rejestracjami sygnałów EEG.

Akwizycja sygnałów odbywała się za pomocą wzmacniacza ExG-32 firmy ELMIKO BIOSIGNALS [94]. Częstotliwość próbkowania wynosiła 500 Hz. Każda z rejestracji zawierała zapisy z 19 elektrod czynnych, które zostały umiejscowione zgodnie z opisanym w punkcie 2.2 układem elektrod 10-20. W czasie akwizycji sygnałów, impedancja pomiędzy elektrodami a skórą była utrzymywana na poziomie poniżej 10 k Ω . Elektroda referencyjną była elektroda A2, umiejscowiona na prawym uchu.

4.2. Przetwarzanie wstępne sygnału

W przeprowadzonych badaniach założono, że dla celów porównawczych istotne jest zachowanie równolicznych zbiorów danych, nawet kosztem pozostawienia artefaktów

w sygnale. Niektóre artefakty pochodzenia biologicznego mogą zawierać dodatkowe cechy osobnicze, użyteczne podczas weryfikacji tożsamości (przykładowo sygnały EMG). System weryfikacji powinien też móc działać w czasie rzeczywistym, co jest utrudnione podczas usuwania artefaktów. W związku z powyższym nie zastosowano automatycznych ani ręcznych metod usuwania artefaktów.

Z każdej rejestracji sygnału EEG analizie były poddawane 3-minutowe fragmenty, rozpoczynające się po pierwszych 30 sekundach od rozpoczęcia badania. Sygnały były filtrowane w przedziale 0,2-70 Hz. Dodatkowo zakłócenia sieciowe zostały odfiltrowane za pomocą filtru wycinającego 50 Hz (ang. *notch*). Analizy wykonano w środowisku MATLAB 2022b. Do obliczeń wykorzystano komputer o następujących parametrach:

- system: Ubuntu 20.04.5 LTS 64-bit,
- procesor: AMD® Ryzen Threadripper pro 3955wx 16-cores, 32 threads,
- RAM: 251,5 GiB.

W badaniach, w których analizowano cechy wyekstrahowane z co najmniej dwóch elektrod zastosowano filtrację przestrzenną za pomocą wspólnego uśrednionego potencjału odniesienia (CAR, ang. *Common Average Reference*) [95], [96]:

$$x_{i,n} = x_{i,n} - \frac{1}{N} \sum_{n=1}^N x_i, \quad (7)$$

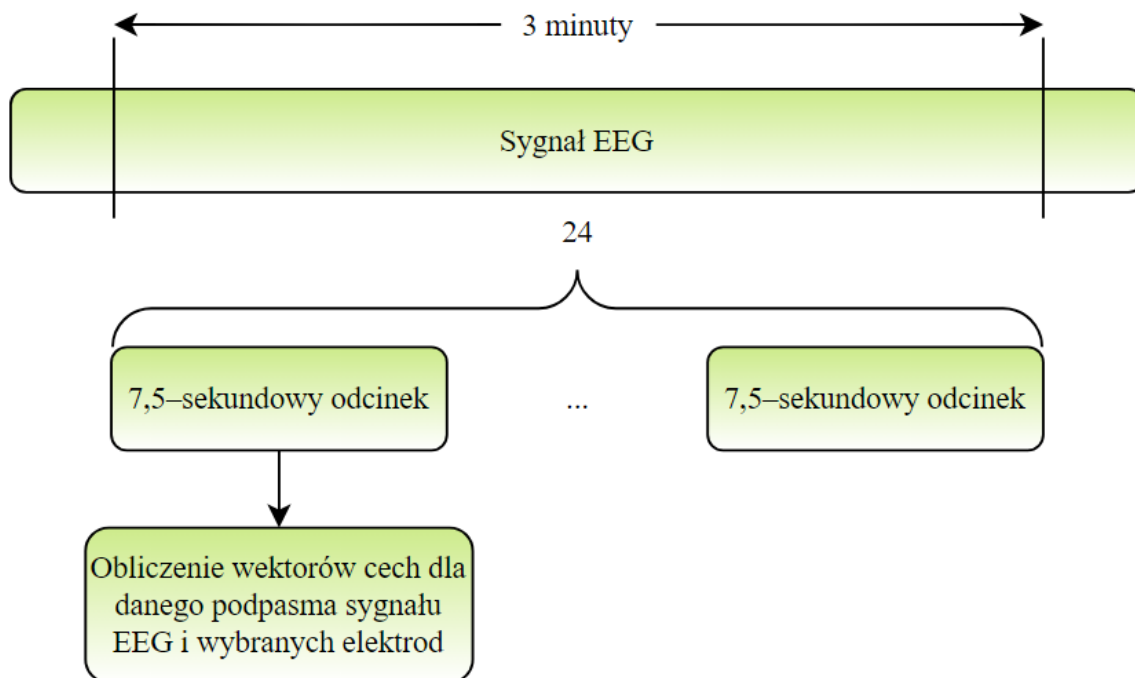
gdzie:

- x – wektor analizowanych danych,
- i – numer próbki w wektorze,
- n – numer elektrody,
- N – liczba elektrod.

W badaniach, w których były analizowane cechy pochodzące tylko z jednej elektrody, nie stosowano tego filtru przestrzennego.

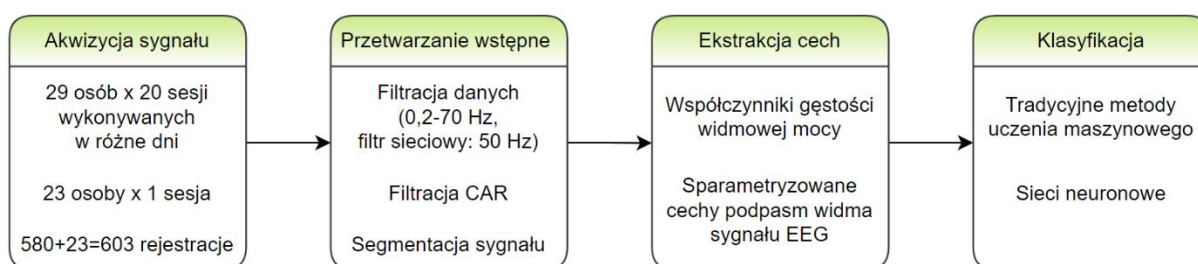
Kolejnym etapem przetwarzania sygnału był jego podział na nienakładające się na siebie odcinki czasowe. Wyodrębniano z nich informacje, które później były podawane na wejście klasyfikatora. W pracy analizowano 7,5-sekundowe odcinki podobnie jak w pracach [46], [47].

Z przygotowanych odcinków były ekstrahowane cechy sygnału. W ten sposób z każdej sesji pomiarowej od każdej osoby było możliwe uzyskanie 24 wektorów cech. Sposób przygotowania danych został zilustrowany na rysunku 15.



Rysunek 15. Segmentacja danych.

Następnie wyodrębniono cechy oparte na współczynnikach estymujących gęstość widmową mocy sygnału EEG, które podawano na wejście klasyfikatora. W większości badań klasyfikatorem była sztuczna sieć neuronowa. W przeprowadzonych analizach dla każdej osoby tworzone były klasyfikatory, które uczyły się ją rozpoznawać. Schemat przetwarzania sygnału zaprezentowano na rysunku 16.



Rysunek 16. Schemat przetwarzania sygnału EEG.

Do dalszych badań wybrano metody ekstrakcji cech oparte na cechach spektralnych sygnału EEG obliczonych za pomocą metody Welcha. W literaturze można znaleźć prace na temat stabilności w czasie cech spektralnych sygnału EEG [97], których często poszukuje się w podpasmach odpowiadających rytmowi alfa [98]–[100]. Stabilność w czasie cech spektralnych sygnału EEG sugeruje, że zawierają one informacje na temat częstotliwości fal mózgowych, które są charakterystyczne dla każdej osoby. Oznacza to, że analiza widmowa sygnału EEG może dostarczyć informacji o unikalnym wzorze fal mózgowych danej osoby, które mogą być wykorzystane do weryfikacji tożsamości. Choć analiza widma sygnału EEG

może być utrudniona ze względu na to, że sygnał EEG jest podatny na zmiany spowodowane stanem emocjonalnym, zmęczeniem i innymi czynnikami, w ramach wykonanych badań postanowiono sprawdzić, czy mimo tego będzie możliwe przeprowadzenie weryfikacji tożsamości osób na zadowalającym poziomie.

4.3. Ekstrakcja cech

W tym punkcie opisano zaproponowane sposoby ekstrakcji cech, które były wykorzystywane w dalszej części rozprawy. Pierwszym z nich [101] jest estymacja gęstości widma mocy (PSD, ang. *Power Spectral Density*) za pomocą metody Welcha [102]. Metoda ta opiera się na zastosowaniu Transformaty Fouriera (FT, ang. *Fourier Transform*), która jest podstawowym narzędziem umożliwiającym przekształcenie sygnału z dziedziny czasu do dziedziny częstotliwości. Poniżej przedstawiono wzór na wyznaczenie Transformaty Fouriera [103]:

$$X(f) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j2\pi ft} dt, \quad (8)$$

gdzie:

- $x(t)$ – funkcja ciągła w dziedzinie czasu, która podlega transformacji,
- $X(f)$ – funkcja ciągła w dziedzinie częstotliwości.

Dyskretna Transformata Fouriera (DFT, *Discrete Fourier Transform*) jest procedurą matematyczną wykorzystywaną między innymi do analizy częstotliwości sygnału dyskretnego. Oblicza się ją dla N punktów sygnału w dziedzinie czasu. Poniżej przedstawiono wzór na wyznaczenie DFT [103]:

$$X(m) = \sum_{n=0}^{N-1} x(n) \cdot e^{-j2\pi nm/N}, \quad (9)$$

gdzie:

- $x(n)$ – sygnał w dziedzinie czasu w N punktach sygnału w dziedzinie czasu,
- $m = 0, 1, \dots, N$.

Złożoność obliczeniowa tak wyrażonej transformaty jest jednak bardzo wysoka – należy przeprowadzić N^2 mnożeń zespolonych [103]. Efektywnym sposobem wyznaczenia Dyskretnej Transformaty Fouriera jest Szybka Transformata Fouriera (FFT, ang. *Fast Fourier Transform*), która została opublikowana przez Cooley'a i Tukey'a w 1965 roku [103]. Umożliwia ona zmniejszenie liczby mnożeń zespolonych do około $\frac{N}{2} \cdot \log_2 N$ [103].

Wadą Dyskretnej Transformaty Fouriera jest to, że transformaty sygnałów, które nie są stacjonarne lub okresowe, zawierają przecieki widma, czyli przedostanie się widma na sąsiednie wartości częstotliwości. Żeby ograniczyć ich wpływ na sygnał, przemnaża się oryginalny ciąg danych czasowych przez funkcję tzw. okna. Metoda ta zmniejsza przeciek widma, choć nie eliminuje go całkowicie.

W badaniach przeprowadzonych w ramach rozprawy zastosowano metodę Welcha, służącą wyznaczaniu widmowej gęstości mocy sygnału wejściowego. W tej metodzie [102] przekształcany segment danych dzielony jest na odcinki czasowe, zazwyczaj nakładające się na siebie. Każdy z tych odcinków czasowych jest przemnażany przez funkcję okna w dziedzinie czasu, a następnie jest obliczana jego Dyskretna Transformata Fouriera podzielona przez długość przekształcanego odcinka czasowego. Wartość bezwzględna otrzymanego wektora zostaje podniesiona do kwadratu, pomnożona przez długość przekształcanego odcinka czasowego i podzielona przez średnią moc użytego okna, wyrażoną jako średnia podniesionych do kwadratu próbek. W ten sposób dla każdego odcinka czasowego zostaje obliczony zmodyfikowany periodogram. Gęstość widmowa mocy przekształcanego segmentu jest następnie obliczana jako średnia otrzymanych periodogramów. Metoda ta umożliwia zredukowanie wariancji widma mocy.

Pierwszym rodzajem cech badanych w rozprawie były współczynniki gęstości widmowej mocy wyznaczone dla każdego z 7,5-sekundowych odcinków z wykorzystaniem metody Welcha. Sygnał wejściowy był dzielony na 1-sekundowe odcinki czasowe nakładające się na siebie z przesunięciem 0,5 sekundy. Wykorzystywaną funkcją okna było okno Hamminga. Wartości współczynników gęstości widmowej mocy były estymowane dla częstotliwości w zakresie 1-45 Hz. W ten sposób z jednego 7,5-sekundowego odcinka dla każdej z elektrod ekstrahowano wektor zawierający 45 cech.

Drugim sposobem ekstrakcji cech, zaprezentowanym w rozprawie są sparametryzowane cechy podpasem widma sygnału EEG, które zostały wykorzystane w publikacjach [58], [59], [62], [63], których główną autorką była autorka niniejszej rozprawy. Rozpatrywanymi cechami były:

$$- \frac{f_{max}}{f_{samp}} \quad - \quad \text{znormalizowana częstotliwość maksymalna,} \quad (10)$$

$$- \frac{P_{max}}{P_{band}} \quad - \quad \text{maksymalna moc w danym podpaśmie podzielona przez} \quad (11)$$

średnią moc sygnału w tym podpaśmie,

$$- \frac{P_{bandsum}}{P_{sum}} \quad - \quad \text{zsumowana moc w danym podpaśmie podzielona przez zsumowaną moc sygnału,} \quad (12)$$

$$- \frac{P_{max}}{P_{mean}} \quad - \quad \text{maksymalna moc w danym podpaśmie podzielona przez średnią moc w całym paśmie,} \quad (13)$$

gdzie:

- f_{max} – maksymalna częstotliwość w danym podpaśmie,
- f_{samp} – częstotliwość próbkowania,
- P_{max} – maksymalna moc w danym podpaśmie,
- P_{band} – średnia moc w danym podpaśmie,
- $P_{bandsum}$ – zsumowana moc w danym podpaśmie,
- P_{sum} – zsumowana moc w całym rozpatrywanym paśmie 1-45 Hz,
- P_{mean} – średnia moc w całym rozpatrywanym paśmie 1-45 Hz.

Każda sparametryzowana cecha była obliczana oddzielnie dla podpasem widma sygnału EEG, odpowiadających zakresom częstotliwości występujących w nim rytmów δ , θ , α , β i γ (por. opis w punkcie 2.4). Rozpatrywane cechy zostały wyselekcjonowane na podstawie analizy korelacji pomiędzy różnymi sparametryzowanymi cechami.

4.4. Metody uczenia maszynowego

Uczenie maszynowe (ang. *machine learning*) [104] jest obszarem sztucznej inteligencji, który obejmuje opracowywanie algorytmów umożliwiających komputerom naukę na podstawie danych treningowych. Metody uczenia maszynowego opierają się na wykorzystaniu danych wejściowych, nazywanych zbiorem treningowym (uczącym), w celu nauczenia modelu predykcyjnego (klasyfikatora) rozpoznawania wzorców, podejmowania decyzji lub generowania prognoz bez konieczności bezpośredniego programowania.

W analizach przedstawionych w rozprawie zastosowano uczenie z nadzorem, które polega na tym, że tworzony model odwzorowuje relację pomiędzy danymi wejściowymi, a podanymi danymi wyjściowymi. Model ten jest trenowany na zbiorze treningowym, gdzie algorytmy uczenia maszynowego analizują dane, dopasowują parametry modelu i uczą się reguł i wzorców występujących w danych.

W przedstawionych w rozprawie badaniach prowadzono klasyfikację dwuklasową [81]. Dla każdej weryfikowanej osoby tworzono dedykowany klasyfikator, który na podstawie

danych treningowych tworzył wzorzec biometryczny tej osoby używany do potwierdzania jej tożsamości. W przypadku sieci neuronowej były to wagi połączeń pomiędzy neuronami. Inaczej ujmując model predykcyjny przypisywał podawane na swoje wejście wektory cech do jednej z dwóch klas: pierwsza klasa odpowiadała osobie, którą klasyfikator uczył się rozpoznawać, drugiej klasie przypisywał wektory cech należące do innych osób. W czasie treningu na wejście klasyfikatora były podawane wektory cech osoby, którą uczył się rozpoznawać oraz taka sama liczba wektorów cech innych osób z bazy treningowej. Podczas badań przeprowadzonych w ramach przygotowania rozprawy przetestowano różne parametry klasyfikatorów. Dla zwiększenia czytelności, w punkcie 5.3.1, przedstawiono wyniki dla tych parametrów, dla których uzyskano najwyższe średnie wartości dokładności weryfikacji tożsamości osób. Poniżej opisano rozpatrywane w rozprawie klasyfikatory.

4.4.1. Drzewa decyzyjne i lasy losowe

Drzewa decyzyjne (DT, ang. *Decision Tree*) [104], [105] są algorytmami wykorzystywanymi do rozwiązywania problemów klasyfikacji lub regresji. Tworzone są poprzez serię kolejnych decyzji dotyczących cech podlegających klasyfikacji. Na podstawie dostępnych danych treningowych, tworzone jest drzewo decyzyjne, będące strukturą hierarchiczną składającą się z węzłów decyzyjnych, w których są testowane kolejne cechy oraz z liści odpowiadających podjętym ostatecznym decyzjom.

W zadaniach klasyfikacji proces tworzenia drzewa decyzyjnego polega na iteracyjnym podziale danych na podstawie cech, które najlepiej separują klasy. Na początku następuje wybór cechy podziałowej. Algorytm ocenia różne cechy i wybiera tę, która na podstawie zadanego kryterium najlepiej rozdziela dane. W kolejnym kroku następuje podział danych, gdzie dane treningowe są dzielone na podzbiory na podstawie wartości cechy podziałowej. Proces jest powtarzany dla każdego nowo utworzonego podzbioru danych, aż zostanie osiągnięty warunek końcowy, np. osiągnięcie maksymalnej głębokości drzewa lub minimalnej liczby próbek w węźle. Jeżeli nie jest już możliwe dokonanie dalszego podziału, tworzone są liście reprezentujące końcowe decyzje klasyfikacyjne. W ramach badań przeprowadzonych na potrzeby rozprawy przeanalizowano różne parametry drzew decyzyjnych, między innymi zbadano różne cechy podziałowe i maksymalne liczby podziałów. W najlepszych przypadkach dokładności uśrednione w zbiorze 29 osób były do siebie zbliżone. Ostatecznie, w rozprawie przyjęto cechę podziałową opartą o test interakcji [106].

Drzewa decyzyjne mają wiele zalet, takich jak łatwość interpretacji, zdolność do przetwarzania zarówno danych kategorycznych, jak i ciągłych oraz efektywność

obliczeniową. Jednak mogą być podatne na przetrenowanie, czyli nadmierne dopasowywanie się danych do zbioru treningowego, szczególnie w przypadku zbyt złożonych struktur drzewa. Jednym ze sposobów przeciwdziałania temu problemowi jest zastosowanie algorytmu lasów losowych (RF, ang. *Random Forest*).

Algorytm lasów losowych [104], [107] opiera się na koncepcji uczenia zespołowego, polegającej na łączeniu wielu prostych modeli decyzyjnych jakimi są drzewa decyzyjne aby uzyskać złożony, lepszy model decyzyjny. W celu dokonania klasyfikacji, każde drzewo w lesie decyzyjnym dokonuje predykcji i za pomocą głosowania większościowego jest podejmowana decyzja. Liczbę drzew decyzyjnych wybrano eksperymentalnie na podstawie wartości dokładności uśrednionej w zbiorze 29 osób. W rozprawie zamieszczono wyniki dla lasu losowego składającego się z 50 drzew decyzyjnych. Powyżej tej wartości nie zaobserwowano zauważalnej poprawy dokładności.

4.4.2. Metoda k-najbliższych sąsiadów

Metoda k-najbliższych sąsiadów (KNN, ang. *k-Nearest Neighbors*) [104] jest jedną z prostszych oraz często używanych metod stosowanych w uczeniu maszynowym. Jej działanie opiera się na prostym mechanizmie klasyfikacji nowych obserwacji na podstawie ich podobieństwa do już istniejących obserwacji w zbiorze treningowym.

Metoda k-najbliższych sąsiadów polega na tym, że jeżeli pewien obiekt jest podobny do innych obiektów w zbiorze treningowym, to prawdopodobnie należy do tej samej klasy. Algorytm dokonuje klasyfikacji nowego obiektu, porównując go z k najbliższymi obiektami ze zbioru treningowego, gdzie k to ustalona liczba sąsiadów. Dystans pomiędzy nimi może być obliczany za pomocą różnych miar odległości, np. euklidesowej. W zadaniach związanych z klasyfikacją nowy obiekt jest przypisywany do klasy, która występuje najczęściej wśród jego k najbliższych sąsiadów. W ramach przygotowań do badań prezentowanych w rozprawie porównano ze sobą dokładności uzyskane dla różnych dystansów oraz różnej liczby sąsiadów. Najlepsze wyniki osiągnięto dla liczby sąsiadów $k = 1$ i dystansu pomiędzy kolejnymi obiektami obliczonego za pomocą odległości miejskiej (ang. *City Block*).

4.4.3. Maszyna wektorów nośnych

Kluczowa idea, na której opiera się klasyfikacja danych za pomocą maszyny wektorów nośnych (SVM, ang. *Support Vector Machines*) [104] polega na znalezieniu hiperpłaszczyzny, rozdzielającej wektory cech poszczególnych klas. W tym algorytmie dąży się do zmaksymalizowania odległości pomiędzy tą hiperpłaszczyzną a najbliższymi wektorami

cech należącymi do różnych klas (wektorami nośnymi). W badaniach przeprowadzonych w ramach rozprawy wykorzystano maszynę wektorów nośnych z liniową funkcją jądra.

4.4.4. Sztuczne sieci neuronowe

Sztuczne sieci neuronowe [33], [104], [108] są jedną z technik uczenia maszynowego, której inspiracją jest sposób działania mózgu. Składają się z połączonych ze sobą jednostek zwanych neuronami, które przetwarzają i przekazują dalej informacje. Mogą być używane zarówno do klasyfikacji, jak i do regresji. Na podstawie podawanych na wejście sztucznej sieci neuronowej przykładów i pożądaných odpowiedzi zwrotnych aktualizowane są współczynniki wagowe sieci.

W rozprawie wykorzystywaną siecią neuronową był wielowarstwowy perceptron (MLP, ang. *Multi-Layer Perceptron*). Jest to rodzaj jednokierunkowej sieci neuronowej, która zwykle składa się z jednej warstwy wejściowej, warstw ukrytych oraz warstwy wyjściowej. Liczba neuronów w warstwie wejściowej zależy od długości wektora cech podawanego na wejście sieci. Neurony wyjściowe określają wynik działania sieci. Pomiędzy nimi znajdują się neurony w warstwie bądź warstwach ukrytych. Nazwa „ukryte” wywodzi się z faktu, że użytkownik nie ma bezpośredniego dostępu do tej lub tych warstw. W sieci MLP przepływ informacji odbywa się w jednym kierunku – od warstwy wejściowej do warstwy wyjściowej. Informacje są przekazywane za pomocą połączeń pomiędzy neuronami, którym przypisana jest jakaś waga, która może być narzucona bądź zainicjalizowana losowo. Częstość zabiegów jest dodawanie wyrazu wolnego, czyli wartości progowej (ang. *bias*), która odpowiada neuronowi o stałej odpowiedzi. Dla każdego neuronu jest obliczana ważona suma otrzymanych sygnałów wejściowych, która następnie jest porównywana z progiem. W ten sposób jest obliczane pobudzenie neuronu. Wyjściowy sygnał neuronu jest obliczany jako wartość funkcji aktywacji w otrzymanym pobudzeniu.

W badaniach przeprowadzonych w ramach rozprawy do trenowania sieci wykorzystywano algorytm Levenberga-Marquardta [109]. Algorytm ten jest jedną z najczęściej stosowanych metod uczenia sztucznych sieci neuronowych. Na podstawie otrzymywanej informacji zwrotnej na temat oczekiwanej od sieci predykcji, systematycznie są nanoszone poprawki na wagi połączeń pomiędzy neuronami, przez co błąd predykcji sieci jest zmniejszany. Uczenie sieci trwa aż do momentu osiągnięcia zdefiniowanego kryterium jej zakończenia, przykładowo określonej liczby iteracji lub minimalnego błędu.

Zaletą sztucznych sieci neuronowych jest ich zdolność do modelowania złożonych nieliniowych zależności w danych oraz adaptacji do różnorodnych problemów [108]. Jednak wymagają one dużej liczby danych treningowych.

Sztuczne sieci neuronowe wykorzystywane w badaniach przeprowadzonych w ramach rozprawy składały się z jednej warstwy ukrytej i dwóch neuronów w warstwie wyjściowej. Jeden z neuronów wyjściowych miał za zadanie określać, czy dana osoba jest tą, którą sieć uczyła się rozpoznawać, drugi, że nią nie jest. W warstwie ukrytej zastosowano tangensoidalną funkcję aktywacji, w warstwie wyjściowej liniową [110].

4.5. Podsumowanie rozdziału

W rozdziale opisano zbiory rejestracji sygnałów EEG, które użyto do przeprowadzenia analiz w ramach rozprawy. Opisany został sposób przetwarzania wstępnego sygnału oraz przedstawiono wykorzystywane sposoby ekstrakcji cech. Scharakteryzowano również rozpatrywane w rozprawie klasyfikatory. W szczególności opisano wykorzystywaną w dalszych częściach rozprawy sztuczną sieć neuronową.

5. Opis i wyniki przeprowadzonych badań

W niniejszym rozdziale przedstawiono wyniki przeprowadzonych badań. Na początku przeanalizowano sposób w jaki podział danych na zbiory treningowe i testowe wpływa na uzyskiwane rezultaty weryfikacji tożsamości osób, a następnie zbadano jak wybrane sposoby skalowania współczynników gęstości widmowej mocy oddziałują na otrzymane wyniki. W ramach przeprowadzonych badań porównano ze sobą dokładności uzyskane za pomocą drzew decyzyjnych, lasów losowych, maszyn wektorów nośnych, metody k-najbliższych sąsiadów i sztucznych sieci neuronowych. Pokazano także wyniki badań dotyczących wykorzystaniu metod uczenia zespołowego.

W dalszej części rozdziału zbadano wpływ poszczególnych podpasów widma sygnału EEG na skuteczność weryfikacji tożsamości. Następnie, na podstawie wyników uzyskanych dla pojedynczych elektrod wyselekcjonowano zestaw, który pomimo znacznie mniejszej liczby elektrod również zapewnia stosunkowo wysoką efektywność weryfikacji tożsamości. Określono również najmniejszą liczbę sesji pomiarowych sygnału EEG, używanych do uczenia klasyfikatorów, po której dalsza poprawa jakości weryfikacji była niewielka. W kolejnym etapie badań zbadano odporność prezentowanych w rozprawie metod weryfikacji tożsamości osób na atak intruzów, czyli dodatkowych osób, których rejestracje nie zostały użyte do trenowania klasyfikatorów. Na końcu przedstawiono wyniki uzyskane z wykorzystaniem sparametryzowanych cech podpasów widma sygnału EEG.

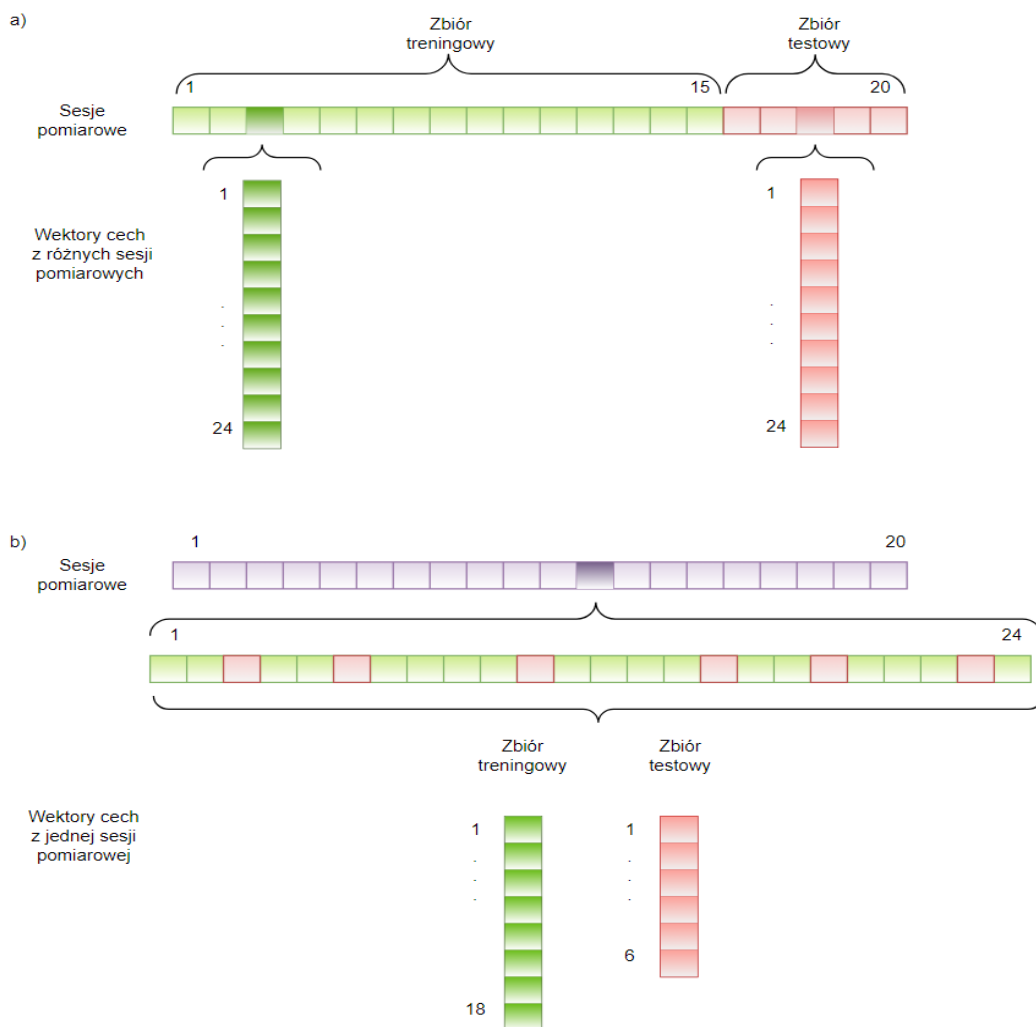
5.1. Podział na zbiory trenujące i testujące

W tym punkcie przedstawiono wyniki badań nad podziałem danych na zbiory trenujące i testujące. W badaniach prezentowanych w rozprawie wykorzystano klasyfikację dwuklasową [81]. Dla każdej osoby, która była weryfikowana tworzono dedykowany klasyfikator, który na podstawie danych treningowych tworzył wzorzec biometryczny danej osoby, używany do potwierdzania jej tożsamości. W przypadku sztucznej sieci neuronowej były to wagi połączeń pomiędzy neuronami. W czasie treningu na wejście klasyfikatora były podawane wektory cech osoby, którą uczył się rozpoznawać oraz taka sama liczba wektorów cech pozostałych osób, które powinny zostać odrzucone. Wektory cech podawane na wejście klasyfikatora były ekstrahowane z widma sygnału EEG, tak jak opisano w punktach 4.2 i 4.3.

5.1.1. Przeprowadzone badania

Poniżej przedstawiono badania, w których pokazano wpływ sposobu podziału danych na zbiory treningowe i testowe na wyniki weryfikacji tożsamości osób. W tym celu poddano analizie sygnały z 19 elektrod rozmieszczonych na głowach osób badanych zgodnie z układem 10-20 (rysunek 5). Dla każdej z 29 osób zarejestrowano po 20 sesji pomiarowych. Wyodrębniono z nich 3-minutowe segmenty, które zostały podzielone na 24 odcinki. Z każdego odcinka ekstrahowano cechy (rysunek 15).

Rozpatrzono dwa scenariusze podziału danych na zbiory treningowe i testowe. W pierwszym scenariuszu (podział międzysesyjny) zbiory treningowe i testowe były tworzone z wektorów cech, które pochodziły z różnych, rozdzielonych w czasie, sesji pomiarowych. W drugim scenariuszu (podział wewnątrzsesyjny) wektory cech uzyskane z różnych części tych samych sesji pomiarowych były używane w zbiorach danych treningowych i testowych. Oba sposoby podziału danych zostały zaprezentowane na rysunku 17.



Rysunek 17. Podział na zbiory treningowe i testowe dla weryfikowanej osoby według scenariuszy, w których oba zbiory pochodziły z różnych sesji pomiarowych (a), z różnych części tych samych sesji (b).

W scenariuszu podziału międzysesyjnego (rysunek 17a) wektory cech w zbiorze treningowym były tworzone z wykorzystaniem pierwszych 15 sesji pomiarowych dla każdej z 29 osób, dla których tworzono klasyfikatory, a w zbiorze testowym z wykorzystaniem ich ostatnich pięciu sesji. Z kolei w scenariuszu podziału wewnątrzsesyjnego (rysunek 17b) wektory cech do zbioru testowego dla każdej z 29 osób, dla których tworzono klasyfikatory, były losowane z różnych części tych samych 20 sesji pomiarowych osoby weryfikowanej. Pozostałe wektory cech umieszczono w zbiorze treningowym. W obu scenariuszach zbiory treningowe i testowe, uzyskane dla każdej sesji, były ze sobą łączone. Wektory cech pozostałych 28 osób były losowo dobierane tak, aby klasyfikator był trenowany na równej liczbie wektorów cech zarówno należących do osoby, którą klasyfikator rozpoznawał, jak i tych, które powinien odrzucić.

Dla tak przygotowanych zbiorów danych, w badaniach przeprowadzonych w następnych punktach, przeprowadzano 8-krotną krosvalidację [111] w zbiorze treningowym. Zestawy cech w sesjach treningowych podzielono na 8 równych części. Po kolei każda z tych części była traktowana jako podzbiór walidacyjny, a pozostałe jako podzbiory treningowe, przy czym liczba przypadków pozytywnych (liczba wektorów cech pochodzących od osoby, którą klasyfikator uczył się rozpoznawać), zawsze była równa liczbie przypadków negatywnych (liczbie wektorów cech pochodzących od pozostałych osób). Dla każdej osoby trenowano 10 klasyfikatorów uczonych z użyciem podzbioru trenującego. Na podstawie podzbioru walidującego wybierany był najlepszy klasyfikator (czyli taki, który zapewniał najwyższą wartość dokładności). Ostatecznie w wyniku krosvalidacji, dla każdej osoby powstawało 8 wyselekcjonowanych najlepszych klasyfikatorów uczonych i walidowanych na różnych częściach zbioru treningowego. W badaniach do klasyfikacji używano sztucznej sieci neuronowej.

W tabeli 2 przedstawiono otrzymane w wyniku przeprowadzonych badań uśrednione wartości miar jakości weryfikacji oraz ich odchylenia standardowe w zależności od wykorzystanego sposobu podziału danych na zbiory treningowe i testowe. Rozpatrywano cechy będące współczynnikami gęstości widmowej mocy. W rozprawie przyjęto sposób zapisywania wyników, w którym najpierw podawana jest wartość średnia, a następnie po znaku „±” jej odchylenie standardowe. W obu scenariuszach 75 % danych znajdowało się w zbiorze treningowym i 25 % w zbiorze testowym.

W tabeli 3 zamieszczono p-wartości otrzymane z wykorzystaniem testu Wilcoxona [112] dla par obserwacji. Porównano ze sobą wartości miar jakości weryfikacji (dokładności – ACC, czułości – SEN, swoistości – SPEC, precyzji – PREC, współczynnika fałszywych akceptacji

– FAR i współczynnika fałszywych odrzuceń – FRR) uzyskane dla obu scenariuszy podziału danych na zbiory treningowe i testowe. Test Wilcoxon dla par obserwacji jest nieparametrycznym testem statystycznym, który sprawdza hipotezę zerową polegającą na tym, że dwie grupy pochodzą z rozkładu o równych medianach. Nie wymaga on założeń o rozkładzie normalnym danych. O wyborze tego testu zdecydowało to, że w części badań, przeprowadzonych dla wektorów cech będących współczynnikami gęstości widmowej mocy, niektóre grupy nie posiadały rozkładu normalnego.

Tabela 2. Porównanie uśrednionych miar jakości klasyfikacji oraz ich odchyłeń standardowych w zależności od wykorzystanego sposobu podziału danych na zbiory treningowe i testowe.

Scenariusz	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
podziału międzysesyjnego	92,4±5,8	92,6±8,7	92,3±3,7	92,2±4,2	7,7±3,7	7,4±8,7
podziału wewnątrzsesyjnego	95,5±2,3	97,5±1,9	93,5±3,2	93,9±2,9	6,5±3,2	2,5±1,9

Tabela 3. Wyniki testu Wilcoxon dla par obserwacji (p-wartości) pomiędzy rozpatrywanymi scenariuszami podziału danych na zbiory treningowe i testowe. Porównanie pomiędzy miarami jakości weryfikacji uzyskanymi dla 15 sesji treningowych i 5 testowych.

Miara jakości klasyfikacji	ACC	SEN	SPEC	PREC	FAR	FRR
p	0,041	0,005	0,263	0,154	0,277	0,005

Przedstawione w powyższych tabelach wyniki wskazują na występowanie istotnych różnic statystycznych ($p < 0,05$) pomiędzy wartościami dokładności, czułości oraz współczynnika fałszywych odrzuceń otrzymanymi z wykorzystaniem podziału wewnątrzsesyjnego i międzysesyjnego. W przypadku podziału wewnątrzsesyjnego uśredniona w zbiorze osób dokładność okazała się być wyższa ($95,5 \pm 2,3$ %) niż otrzymana z wykorzystaniem podziału międzysesyjnego ($92,4 \pm 5,8$ %), a odchylenia standardowe były niższe. Szczególną różnicę można zaobserwować w wartości czułości. Dla podziału międzysesyjnego wyniosła ona $92,6 \pm 8,7$ %, a dla podziału wewnątrzsesyjnego $97,5 \pm 1,9$ %. Różnica pomiędzy uśrednionymi miarami wyniosła 4,9 %, a wartość odchylenia standardowego zmalała ponad 4-krotnie. Z kolei nie znaleziono istotnych statystycznie różnic pomiędzy wartościami swoistości, precyzji i współczynnika fałszywych akceptacji uzyskanymi dla obu scenariuszy.

W publikacjach [58], [59], w których główną autorką była autorka niniejszej rozprawy, przeprowadzono podobne badania. Pokazano w nich w jaki sposób podział danych na zbiory treningowe i testowe wpływa na rezultaty weryfikacji tożsamości. W odróżnieniu od badań, których wyniki pokazano powyżej, badania przedstawione w artykule [58] wykonano

dla wektorów sparametryzowanych cech wyekstrahowanych z widma sygnału EEG za pomocą wzorów (10)-(13). Natomiast w publikacji [59] wykorzystywano cechy określone wzorami (10)-(12). W obu artykułach wykorzystano 4-krotną krosvalidację. Szczegółowy opis badań znajduje się w tych artykułach.

W badaniach, których wyniki pokazano w artykule [59], za pomocą analizy wariancji (ANOVA, ang. *Analysis of Variance*), polegającej w uproszczeniu na przeprowadzeniu testu równości wartości średnich pomiędzy grupami [112], porównano różnice pomiędzy uzyskanymi w obu scenariuszach wartościami miar jakości klasyfikacji. Wyniki serii testów ANOVA (w postaci p-wartości) pomiędzy wartościami dokładności, czułości, swoistości i precyzji uzyskanymi w obu scenariuszach zostały przedstawione w tabeli 4. Przedstawione w tabeli badania były prowadzone zarówno dla całego rozpatrywanego pasma sygnału EEG (wiersz All w tabeli 4) oraz dla podpasem sygnału EEG odpowiadających pojedynczym rytmom i ich wybranym zestawom. Wątek doboru podpasem widma sygnału EEG został opisany szerzej w punkcie 5.4.

Tabela 4. Wyniki serii testów ANOVA (p-wartości) porównujących wartości średnie miar jakości klasyfikacji pomiędzy oboma scenariuszami. Wyniki zaznaczone na czerwono oznaczają występowanie istotnych statystycznie różnic ($p < 0,05$). Źródło: [59].

EEG Bands	ACC (%)	SEN (%)	SPEC (%)	PREC (%)
δ	0.03	7.0×10^{-3}	0.36	0.13
θ	0.07	2.1×10^{-3}	0.41	0.81
α	0.17	0.03	0.46	0.80
β	0.17	0.07	0.95	0.65
γ	0.04	1.1×10^{-3}	0.66	0.67
$\beta \gamma$	0.10	0.03	0.74	0.56
$\alpha \beta$	0.05	0.03	0.39	0.18
$\alpha \beta \gamma$	0.05	0.02	0.61	0.41
$\delta \alpha \beta \gamma$	0.03	0.02	0.23	0.15
All	0.02	0.01	0.44	0.26

W przypadku całego rozpatrywanego pasma sygnału EEG (wiersz All w tabeli 4), wyniki przeprowadzonej serii testów ANOVA wykazały brak występowania istotnych statystycznie różnic dla miar wartości swoistości (SPEC) i precyzji (PREC) pomiędzy oboma scenariuszami ($p \geq 0,05$ wartości zaznaczone na zielono w tabeli 4). Dla podziału wewnątrzsesyjnego średnia wartość swoistości wyniosła $95,2 \pm 2,8$ %, a precyzji $95,3 \pm 2,6$ %. W przypadku scenariusza podziału międzysesyjnego te wartości wyniosły kolejno $94,6 \pm 3,6$ % i $94,3 \pm 3,9$ %. Podobnie jak w przypadku przedstawionych powyżej cech będących współczynnikami widmowej gęstości mocy (tabela 3) znaleziono istotne różnice w wartościach dokładności (ACC) i czułości (SEN), które okazały się być wyższe w przypadku scenariusza podziału

wewnątrzsesyjnego (odpowiednio: $95,7 \pm 2,3$ % i $96,2 \pm 2,9$ %) niż dla scenariusza podziału międzysesyjnego ($93,1 \pm 5,6$ % i $91,6 \pm 9,0$ %).

W przypadku rozpatrywanych podpasem widma sygnału EEG oraz ich zestawów można zauważyć, że podobnie, jak dla całego pasma sygnału EEG, za wyjątkiem podpasma β występowały istotne różnice w wartościach czułości, które były wyższe w przypadku scenariusza podziału wewnątrzsesyjnego. Podobnie w przypadku scenariusza podziału wewnątrzsesyjnego, otrzymane dokładności okazały się wyższe i znaleziono istotnie statycznie różne dla wszystkich podpasem, za wyjątkiem podpasem odpowiadających pojedynczym rytmom θ , α , β oraz kombinacji podpasem $\beta+\gamma$, gdzie test wykazał brak występowania istotnych statystycznie różnic między nimi. Dla żadnego z rozpatrywanych zestawów podpasem test nie wykazał istotnych różnic pomiędzy wartościami swoistości i precyzji pomiędzy dwoma scenariuszami.

W przypadku wykorzystania cech będących współczynnikami widma, jak również sparametryzowanych cech, różnice w średnich wartościach czułości pomiędzy scenariuszami mogą być wynikiem chwilowych zmian, które zachodzą w sygnale EEG w związku z psychofizycznym stanem osoby weryfikowanej. Inną przyczyną otrzymanych różnic w wartościach czułości pomiędzy scenariuszami może być wpływ artefaktów pochodzenia technicznego.


Zarówno dla cech w postaci całego rozpatrywanego pasma widma sygnału EEG, jak i sparametryzowanych, przeanalizowano wpływ utworzenia zbiorów testowych według scenariuszy podziału wewnątrzsesyjnego i międzysesyjnego na jakość weryfikacji tożsamości osób dla rozpatrywanych cech sygnału EEG. Różnica pomiędzy oboma scenariuszami przejawia się w tym, że w scenariuszu podziału wewnątrzsesyjnego, cechy sygnału EEG są wyodrębniane z każdej sesji pomiarowej, zatem oprócz stałych cech biometrycznych znajdują się w nich informacje zależne od aktualnego stanu osoby weryfikowanej oraz jej otoczenia, np. poziomu zakłóceń pochodzenia technicznego w pobliżu tej osoby. Cechy, znajdujące się w zbiorze testowym utworzonym z wykorzystaniem segmentów z tej samej sesji również posiadają te informacje.

Do weryfikacji tożsamości osób na podstawie cech zawartych w sygnale EEG powinno się jednak używać cech niezmiennych w czasie. W scenariuszu podziału międzysesyjnego zbiory treningowe i testowe tworzone są na podstawie różnych sesji pomiarowych sygnału EEG, zatem wyekstrahowane z sygnału cechy znajdujące się w zbiorze testowym nie zawierają tych samych informacji zależnych od stanu osoby weryfikowanej oraz jej otoczenia, które mógł

zawierać zbiór sesji treningowych. Z użyciem scenariusza międzysesyjnego możliwe jest rzetelniejsze określenie, czy weryfikacji podlegają stałe cechy biometryczne.

Z tych powodów badania opisane w dalszej części rozprawy zostały oparte na podejściu reprezentowanym przez scenariusz podziału międzysesyjnego. Scenariusz podziału wewnątrzsesyjnego może być traktowany jako odniesienie sprawdzające możliwości weryfikacji tożsamości osób na podstawie sygnału EEG – jeżeli system nie będzie w stanie z wysoką dokładnością zaklasyfikować danych w zbiorze testowym przy użyciu tego scenariusza, prawdopodobnie nie zrobi tego również w przypadku wykorzystania scenariusza podziału międzysesyjnego.

Sposób podziału danych do badań przedstawionych w dalszej części rozprawy został pokazany na rysunku 18. W większości analiz liczba sesji osoby weryfikowanej użytych do treningu klasyfikatora zmieniała się od 1 do 15, a zbiór testowy składał się z wektorów cech wyodrębnionych z jej pięciu ostatnich sesji pomiarowych. Podobnie jak w przypadku scenariusza podziału międzysesyjnego przedstawionego na rysunku 17a, ze zbioru rejestracji pozostałych 28 osób losowano tyle samo wektorów cech z pierwszych od 1 do 15 sesji do zbioru treningowego i z ostatnich 5 sesji do zbioru testowego. Losowanie indeksów wektorów cech przeprowadzono tylko raz. Wylosowane indeksy wektorów cech pochodzących od pozostałych 28 osób zostały zapisane i były używane we wszystkich przeprowadzonych badaniach. Miało to na celu ograniczenie wpływu ich losowania na porównanie jakości weryfikacji tożsamości osób dla różnych metod. Sposób przeprowadzania 8-krotnej krosvalidacji i doboru najlepszych klasyfikatorów był taki sam jak w przypadku scenariusza podziału międzysesyjnego przedstawionego na rysunku 17a.



Rysunek 18. Sposób podziału danych przyjęty w rozprawie dla każdej osoby weryfikowanej. Liniami przerywanymi oznaczono zbiór treningowy z różną liczbą sesji pomiarowych sygnału EEG osoby, dla której trenowano klasyfikator.

5.1.2. Wnioski

W punkcie przedstawiono wyniki badań nad podziałem danych na zbiory treningowe i testowe. W tym celu przeanalizowano dwa scenariusze podziału danych: międzysesyjny, w którym zbiory treningowe i testowe pochodziły z różnych, rozdzielonych w czasie sesji pomiarowych sygnału EEG oraz wewnątrzsesyjny, w którym oba zbiory pochodziły z różnych części tych samych sesji pomiarowych. Pokazano wyniki badań zarówno dla cech będących współczynnikami gęstości widmowej mocy oraz dla sparametryzowanych cech podpasem widma sygnału EEG.

W obu przypadkach dla całego rozpatrywanego pasma sygnału EEG wartości dokładności i czułości okazały się istotnie statystycznie lepsze dla scenariusza podziału wewnątrzsesyjnego, jednak występowania takich różnic nie znaleziono dla swoistości i precyzji. Podczas korzystania ze scenariusza wewnątrzsesyjnego, otrzymane wektory cech pochodzą z każdej sesji pomiarowej, dostarczając zarówno dla zbioru treningowego, jak i testowego danych na temat aktualnego sygnału EEG. Oprócz stałych cech biometrycznych mogą znajdować się w nich informacje zależne od aktualnego stanu osoby weryfikowanej oraz jej otoczenia. Te informacje z kolei nie są współdzielone przez zbiory treningowe i testowe w przypadku scenariusza podziału międzysesyjnego.

Z tych powodów dalszą część badań przeprowadzono w oparciu o scenariusz podziału międzysesyjnego. Z jego wykorzystaniem możliwe jest rzetelniesze określenie czy weryfikacji podlegają stałe cechy biometryczne obecne w sygnale EEG.

5.2. Wpływ skalowania współczynników widmowej gęstości mocy

Badania, których wyniki przedstawiono w tym punkcie są powiązane z dwoma artykułami, których autorka niniejszej rozprawy była główną autorką. W pierwszym z nich [60] zademonstrowano zalety wyrażenia współczynników widmowej gęstości mocy w skali decybelowej w kontekście uzyskiwanych wyników weryfikacji tożsamości. W drugiej publikacji [61] przeprowadzono analizę wpływu wybranych metod skalowania współczynników widmowej gęstości mocy na skuteczność weryfikacji tożsamości osób.

5.2.1. Przeprowadzone badania

Wyniki miar jakości weryfikacji tożsamości otrzymane z wykorzystaniem cech będących nieskalowanymi współczynnikami gęstości widmowej mocy zostały porównane do wyników otrzymanych z użyciem cech będących współczynnikami znormalizowanymi w sposób opisany w artykule [54] oraz dla cech będących współczynnikami wyrażonymi w skali decybelowej.

Rozpatrzono cechy będące współczynnikami znormalizowanymi względem sumy badanego zakresu mocy (powNorm), zob. wzór (14) oraz współczynnikami standaryzowanymi, będącymi różnicami pomiędzy współczynnikami gęstości widmowej mocy, a ich wartościami średnimi, unormowanymi względem odchyłeń standardowych (zNorm) (15). Zbadano również wpływ normalizacji współczynników z wykorzystaniem percentyli na efektywność weryfikacji tożsamości. Od wektora zawierającego nieskalowane współczynniki gęstości widmowej mocy odejmowano wartość 5 percentyla wartości współczynników gęstości widmowej mocy, a następnie dzielono otrzymany wynik przez różnicę pomiędzy wartością 95 percentyla i piątego percentyla (prcNorm) (16). W ten sam sposób znormalizowano współczynniki gęstości widmowej mocy z wykorzystaniem 25 i 75 percentyla (iqrNorm) (17). Różnica pomiędzy 75 a 25 percentylem nosi nazwę rozstępu międzykwartylowego i względem niego została unormowana różnica pomiędzy współczynnikami gęstości widmowej mocy, a ich medianą (rNorm) (18). Ostatnią metodą skalowania współczynników widma gęstości mocy było wyrażenie ich w skali decybelowej (dBScale) (19). Użycie tej metody skalowania i zbadanie jej wpływu na zwiększenie miar oceny jakości weryfikacji oraz na liczbę sesji pomiarowych sygnału EEG potrzebnych do treningu klasyfikatora stanowi jedną z oryginalnych koncepcji rozprawy.

Analizowane sposoby skalowania widma mocy sygnału EEG zostały wyrażone poniższymi wzorami:

$$\text{powNorm: } \tilde{P}_i = \frac{P_i}{P_{tot}}, \quad (14)$$

$$\text{zNorm: } \tilde{P}_i = \frac{P_i - \bar{P}}{\sqrt{\sigma_P}}, \quad (15)$$

$$\text{prcNorm: } \tilde{P}_i = \frac{P_i - P_{5\%}}{P_{95\%} - P_{5\%}}, \quad (16)$$

$$\text{iqrNorm: } \tilde{P}_i = \frac{P_i - P_{25\%}}{P_{75\%} - P_{25\%}}, \quad (17)$$

$$\text{rNorm: } \tilde{P}_i = \frac{P_i - \hat{P}}{P_{75\%} - P_{25\%}}, \quad (18)$$

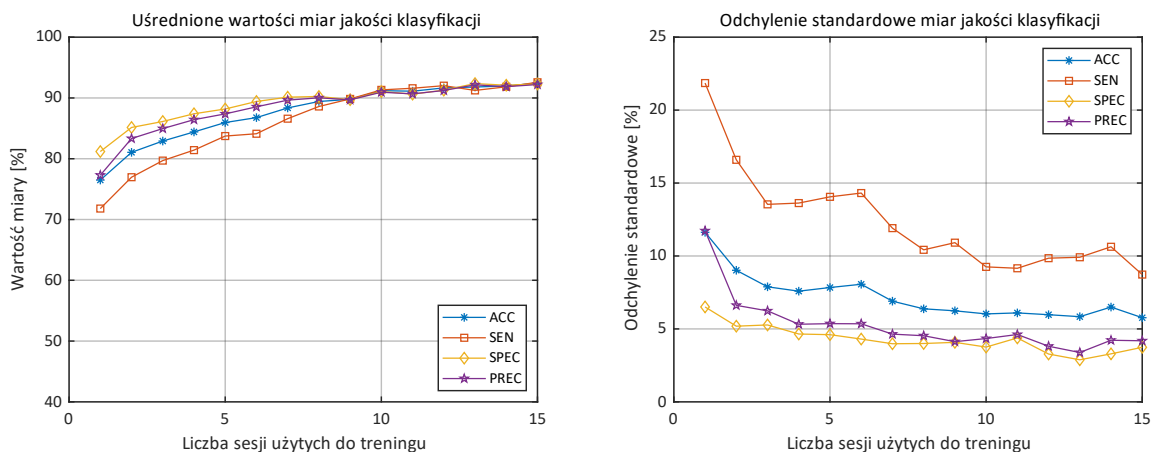
$$\text{dBScale: } \tilde{P}_i = 10 \cdot \log_{10} P_i, \quad (19)$$

gdzie:



- P_i – wektor nieskalowanych współczynników gęstości widmowej mocy,
- \tilde{P}_i – wektor przeskalowanych współczynników gęstości widmowej mocy,
- \hat{P} – mediana nieskalowanych współczynników gęstości widmowej mocy,
- P_{tot} – suma nieskalowanych współczynników gęstości widmowej mocy,
- \bar{P} – średnia nieskalowanych współczynników gęstości widmowej mocy,

- σ_p – odchylenie standardowe nieskalowanych współczynników gęstości widmowej mocy,
- $P_{n\%}$ – moc n -tego percentyla w zbiorze nieskalowanych współczynników gęstości widmowej mocy,
- i – wskaźnik częstotliwości, dla której obliczana jest wartość gęstości widmowej mocy (1-45 Hz).



Na rysunku 19 zamieszczono uśrednione w zbiorze 29 osób wartości miar jakości klasyfikacji oraz ich odchylenia standardowe uzyskane dla cech będących nieskalowanymi współczynnikami gęstości widmowej mocy. Na rysunkach 20-25 przedstawiono wyniki uzyskane dla cech będących współczynnikami gęstości widmowej mocy przeskalowanych za pomocą wyżej wymienionych sposobów. Kolorem niebieskim oznaczono dokładność ACC (1), czerwonym czułość SEN (2), żółtym swoistość SPEC (3), a fioletowym precyzję PREC (4). Analizy prowadzono dla współczynników gęstości widmowej mocy uzyskanych w paśmie 1-45 Hz i dla 19 elektrod, które zostały rozmieszczone zgodnie z systemem 10-20 (rysunek 5). Na osi pionowej znajdują się uśrednione w zbiorze osób wybrane wartości miar oceny jakości klasyfikacji wyrażone w procentach. Wzdłuż osi poziomej oznaczono liczbę sesji pomiarowych sygnału EEG, używanych do trenowania sztucznej sieci neuronowej. Żeby zwiększyć czytelność rysunków osie rzędnych wykresów ograniczono do zakresu 40-100 % dla miar oceny jakości weryfikacji oraz do 0-25 % dla odchyłeń standardowych tych miar.





Rysunek 19. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe dla nieskalowanych współczynników gęstości widmowej mocy.





Rysunek 20. *Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji współczynników PSD powNorm.*



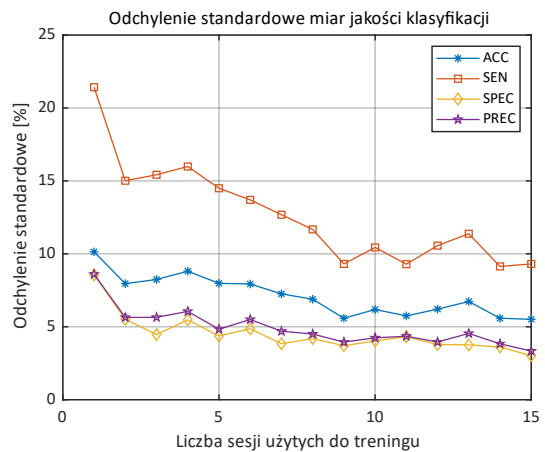

Rysunek 21. *Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji współczynników PSD zNorm.*




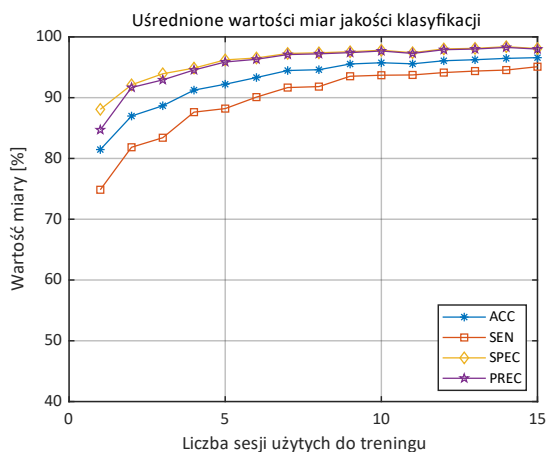
Rysunek 22. *Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji współczynników PSD prcNorm.*



Rysunek 23. *Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji współczynników PSD iqrNorm.*



Rysunek 24. *Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji współczynników PSD rNorm.*



Rysunek 25. *Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po wyrażeniu współczynników widmowej gęstości mocy w skali decybelowej (dBScale).*

Skrócone podsumowanie wyników przedstawionych na rysunkach 19-25 zostało umieszczone w tabeli 5. Zamieszczono tam uśrednione w zbiorze osób wyniki liczbowe miar oceny jakości klasyfikacji, które otrzymano w przypadku użycia 15 sesji pomiarowych

do treningu sztucznej sieci neuronowej, która uczyła się rozpoznawać daną osobę. Szczegółowe wyniki dla wszystkich liczb sesji treningowych zmieniających się od 1 do 15 zamieszczono w Dodatku A.

Tabela 5. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe w zależności od sposobu przeskalowania współczynników gęstości widmowej mocy. Wyniki dla 15 sesji treningowych i 5 testowych.

Sposób skalowania	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
bez skalowania	92,4±5,8	92,6±8,7	92,3±3,7	92,2±4,2	7,7±3,7	7,4±8,7
powNorm	89,7±5,8	88,6±8,8	90,8±4,3	90,6±4,6	9,2±4,3	11,4±8,8
zNorm	87,0±6,1	85,8±9,4	88,3±4,9	88,0±5,1	11,7±4,9	14,2±9,4
prcNorm	92,1±5,6	91,5±8,6	92,7±4,0	92,6±4,2	7,3±4,0	8,5±8,6
iqrNorm	94,0±5,4	93,1±8,7	95,0±3,3	94,9±3,5	5,0±3,3	6,9±8,7
rNorm	93,6±5,5	92,3±9,3	94,8±3,0	94,6±3,3	5,2±3,0	7,7±9,3
dBScale	96,6±4,2	95,1±8,0	98,1±0,9	98,0±1,1	1,9±0,9	4,9±8,0

Pokazane na rysunkach 19-25 oraz w tabeli 5 wyniki wskazują na wyraźny wpływ metody skalowania współczynników gęstości widmowej mocy na efektywność weryfikacji tożsamości. Próba normalizacji współczynników za pomocą metod powNorm, zNorm i prcNorm doprowadziła do pogorszenia otrzymanych miar jakości weryfikacji w stosunku do wartości otrzymanych w przypadku zastosowania nieskalowanych współczynników widmowej gęstości mocy. Normalizacja współczynników gęstości widmowej mocy za pomocą metod rNorm i iqrNorm wpłynęła na poprawę rozpatrywanych miar. Jednak najlepsze rezultaty otrzymano po wyrażeniu współczynników gęstości widmowej mocy w skali decybelowej dBScale – uśrednione wartości wszystkich miar jakości klasyfikacji uległy poprawie, również zmniejszyły się ich odchylenia standardowe.

Potwierdzeniem powyższego wniosku są przedstawione w tabeli 6 wyniki testu Wilcoxon dla par obserwacji. Za pomocą tego testu porównano wartości dokładności uzyskane dla metody opartej na wyrażeniu współczynników gęstości widmowej mocy w skali decybelowej dBScale z dokładnościami otrzymanymi dla pozostałych sposobów normalizacji. Porównanie przeprowadzono dla dokładności uzyskanych w przypadku 15 sesji treningowych. Otrzymane wyniki wskazują na to, że występują istotne różnice statystyczne ($p < 0,05$) pomiędzy dokładnością zaproponowanego sposobu skalowania współczynników gęstości widmowej mocy a pozostałymi rozpatrywanymi metodami normalizacji. Średnia dokładność otrzymana z jego wykorzystaniem okazała się być wyższa niż średnie dokładności uzyskane z wykorzystaniem innych przedstawionych w rozprawie sposobów skalowania współczynników gęstości widmowej mocy.

Tabela 6. Wyniki testu Wilcoxona dla par obserwacji (p-wartości) pomiędzy metodą dBScale, a pozostałymi sposobami normalizacji współczynników PSD. Porównanie pomiędzy wartościami dokładności uzyskanymi dla 15 sesji treningowych i 5 testowych.

Sposób skalowania	bez skalowania	powNorm	normNorm	zNorm	prcNorm	iqrNorm	rNorm
p	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	0,012	0,002

5.2.2. Wnioski

W niniejszym punkcie przeprowadzono badania mające na celu wybór sposobu przetwarzania współczynników gęstości widmowej mocy. Przeanalizowano osiem metod, w tym jedną zaproponowaną przez autorkę niniejszej rozprawy, która polegała na wykorzystaniu współczynników gęstości widmowej mocy wyrażonych w skali decybelowej. Dokładności uzyskane za pomocą tej metody różniły się statystycznie od dokładności uzyskanych z wykorzystaniem pozostałych metod, a średnia dokładność była wyższa niż w przypadku pozostałych miar. Z tego powodu zdecydowano się na zastosowanie tej metody w badaniach opisanych w dalszej części rozprawy.

5.3. Analiza zastosowania różnych klasyfikatorów

W tym punkcie przedstawiono analizy prowadzące do wyboru klasyfikatora wykorzystywanego do weryfikacji tożsamości osób. W badaniach przeprowadzonych w ramach rozprawy uwzględniono szereg różnych klasyfikatorów i ich parametrów, jednak w celu skupienia się na najbardziej interesujących i reprezentatywnych wynikach, ograniczono prezentację jedynie do pojedynczych modeli opisanych w punkcie 4.4. Skuteczność klasyfikacji oceniono na podstawie wymienionych w punkcie 3.2 miar oceny jakości klasyfikacji. Klasyfikatory trenowane były z wykorzystaniem 15 sesji pomiarowych sygnału EEG. Jakość klasyfikacji sprawdzano z użyciem 5 sesji testowych.

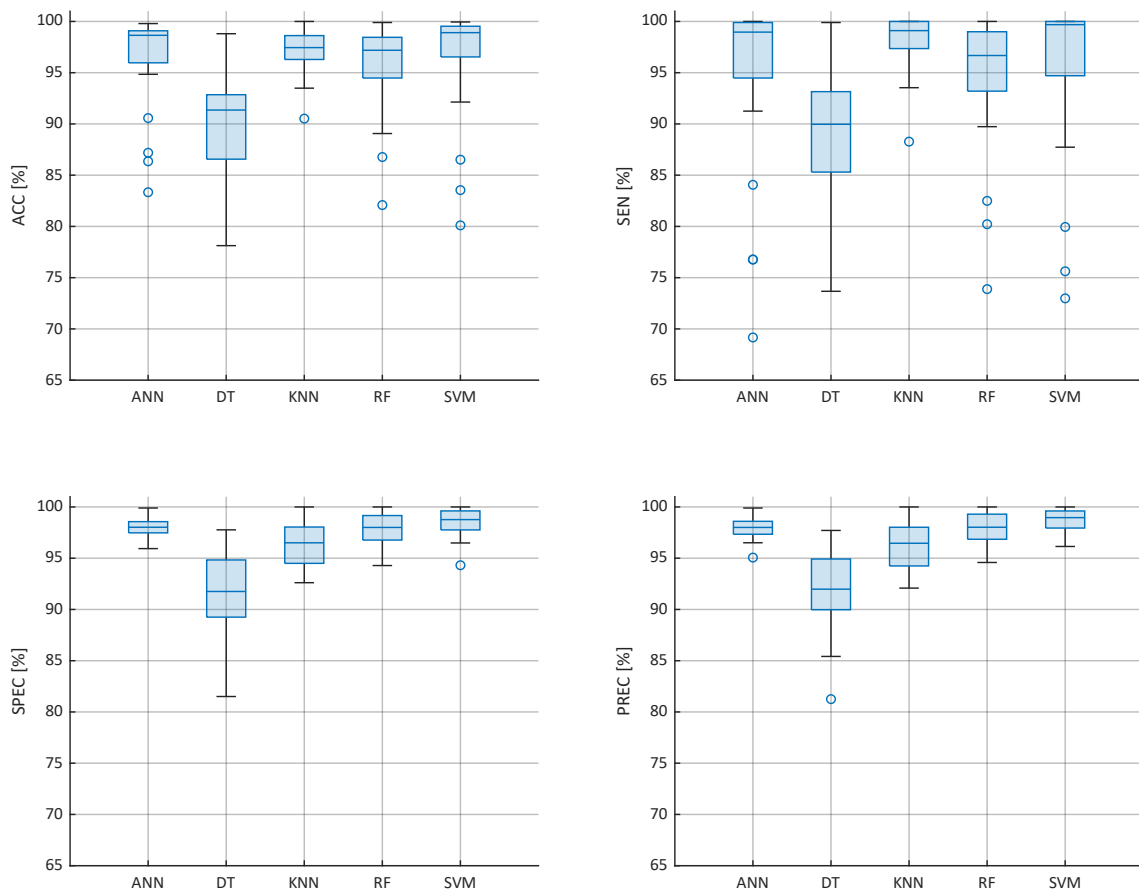
5.3.1. Porównanie klasyfikatorów

Na rysunku 26 zamieszczono wykresy pudełkowe uzyskane dla wybranych miar oceny jakości klasyfikacji – dokładności (ACC), czułości (SEN), swoistości (SPEC) i precyzji (PREC). Wykresy pudełkowe są graficzną reprezentacją cech statystycznych w danym zbiorze danych. Linie poziome wewnątrz prostokąta (pudełka) oznaczają wartość mediany w danym zbiorze danych. Końce prostokąta wyznaczają rozstęp międzykwartyłowy, czyli odpowiadają kolejno pierwszemu oraz trzeciemu kwartyłowi (25 i 75 procentyl). Od zakończeń pudełek rozciągają się wąsy określające zakres pomiędzy trzecim kwartyłem a największą wartością, która nie została uznana za wartość odstającą (jest mniejsza niż półtora rozstępu

międzykwartylowego) oraz zakres pomiędzy pierwszym kwartyłem, a najmniejszą wartością, która nie została uznana za wartość odstającą. Na rysunku kółkami oznaczono wartości odstające.

Porównywanymi ze sobą klasyfikatorami były: sztuczna sieć neuronowa (ANN), drzewo decyzyjne (DT), algorytm k-najbliższych sąsiadów (KNN), las losowy (RF) i maszyna wektorów nośnych (SVM). Podstawowe informacje dotyczące działania tych klasyfikatorów oraz wybrane parametry opisano w punktach 4.4.1-4.4.4.

Porównanie otrzymanych miar oceny jakości weryfikacji pomiędzy rozpatrywanymi algorytmami wykazało, że najlepsze wyniki zostały osiągnięte dla klasyfikacji za pomocą klasyfikatorów SVM, ANN i KNN, trochę gorsze dla RF (rysunek 26). Najniższe wyniki uzyskano dla klasyfikacji z wykorzystaniem DT. Stwierdzono brak występowania różnic istotnych statystycznie (we wszystkich przypadkach $p > 0,148$) pomiędzy dokładnościami uzyskanymi dla klasyfikacji za pomocą ANN, a dokładnościami uzyskanymi z wykorzystaniem klasyfikacji za pomocą KNN, RF i SVM. Wartości dokładności otrzymane dla każdego z klasyfikatorów były porównywane za pomocą testu Wilcoxon.



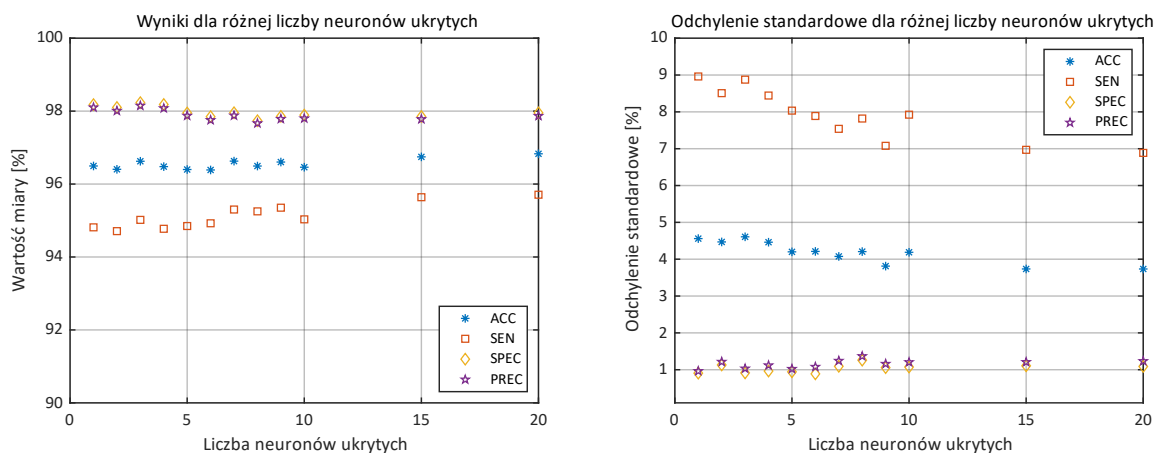
Rysunek 26. Wykresy pudełkowe uśrednionych miar jakości klasyfikacji dla rozpatrywanych klasyfikatorów.

Do analiz prezentowanych w dalszej części rozprawy wybrano klasyfikację z wykorzystaniem sztucznych sieci neuronowych. Jak przedstawiono na rysunku 26, wartości miar jakości klasyfikacji, a w szczególności dokładności, uzyskanych za pomocą tego klasyfikatora należały do jednych z najlepszych. O wyborze sztucznej sieci neuronowej zdecydował brak występowania istotnych różnic statystycznych w stosunku do innych najlepszych klasyfikatorów oraz elastyczność tego klasyfikatora wraz z jego zdolnością do adaptacji do różnego rodzaju danych [108].

5.3.2. Wyniki dla różnej liczby neuronów ukrytych


W tej części rozprawy przedstawiono wpływ liczby neuronów ukrytych w sztucznej sieci neuronowej na jakość weryfikacji tożsamości osób dla wybranych sparametryzowanych cech podpasm widma sygnału EEG oraz dla cech będących współczynnikami widmowej gęstości mocy wyrażonych w skali decybelowej. Wyniki analiz dla sparametryzowanych cech podpasm widma sygnału EEG (10)-(12) podawanych na wejście sieci zostały pokazane w artykule [59], którego autorka rozprawy była główną autorką. W przeprowadzonych badaniach, których wyniki przedstawiono we wspomnianej publikacji, liczba neuronów ukrytych zmieniała się od 1 do 10. Za pomocą dwuczynnikowej analizy wariancji ANOVA wykazano brak istotnego statystycznie wpływu liczby neuronów ukrytych w zakresie od 1 do 10 na otrzymane wartości dokładności ($p > 0.99$).

Poniżej przedstawiono wyniki badań przeprowadzonych w ramach rozprawy nad wpływem liczby neuronów ukrytych w sztucznej sieci neuronowej na jakość weryfikacji tożsamości osób z wykorzystaniem cech będących współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej. W tych analizach liczba neuronów ukrytych była zmieniana od 1 do 10, ponadto przeprowadzono również badania z wykorzystaniem 15 i 20 neuronów. Wpływ liczby neuronów ukrytych na wybrane miary jakości klasyfikacji został przedstawiony na rysunku 27. Wraz ze wzrostem liczby neuronów ukrytych miary jakości weryfikacji ulegały niewielkim zmianom, choć w przypadku odchylenia standardowego tych miar, w szczególności dla czułości, można dostrzec poprawę. Dokładności uzyskane przy wykorzystaniu sztucznej sieci neuronowej z 20 neuronami ukrytymi oraz sztucznej sieci neuronowej z jednym neuronem ukrytym zostały ze sobą porównane za pomocą testu Wilcoxon dla par obserwacji. Otrzymany wynik wskazał na brak istotnych różnic statystycznych pomiędzy nimi ($p = 0,838$).



Rysunek 27. Wpływ liczby neuronów ukrytych na wartości wybranych miar oceny jakości klasyfikacji.

W przeprowadzonych badaniach zwiększenie liczby neuronów ukrytych od 1 do 20 spowodowało znaczące (ponad 500-krotne) wydłużenie czasu trwania przeprowadzanych obliczeń i nie zapewniło istotnych statystycznie korzyści. Na rysunku 28 przedstawiono zmierzone średnie czasy trenowania pojedynczych sztucznych sieci neuronowych dla danej osoby w funkcji liczby neuronów ukrytych. Parametry komputera, na którym wykonywano obliczenia przedstawiono w punkcie 4.2.




Rysunek 28. Średni czas trwania trenowania pojedynczej sztucznej sieci neuronowej w funkcji liczby neuronów ukrytych dla jednej osoby. Niebieskie punkty odpowiadają otrzymanym czasom, czerwona linia została dopasowana do danych by podkreślić trend zmian średniego czasu trenowania sieci.

5.3.3. Uczenie zespołowe

W niniejszym punkcie przedstawiono wpływ zastosowania metod uczenia zespołowego (ang. *ensemble learning*) [104] użytych do klasyfikacji na jakość weryfikacji tożsamości osób. Metody te opierają się na łączeniu kilku podstawowych klasyfikatorów w celu otrzymania jednego złożonego klasyfikatora. Dzięki temu jest możliwe uzyskanie lepszej generalizacji klasyfikacji [104], co wiąże się z otrzymaniem dokładniejszych i stabilniejszych wyników oraz

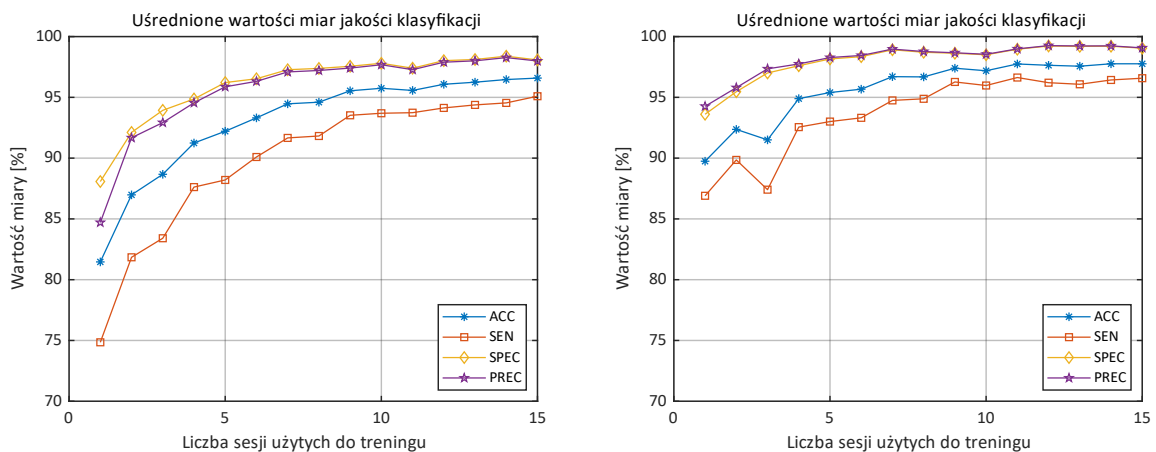
zmniejszeniem wariancji miar jakości klasyfikacji i problemu przeuczenia się klasyfikatorów. Jedną z technik uczenia zespołowego, której ideę wykorzystano w pracy, jest bagging (agregacja bootstrap ang. *bootstrap aggregating*). Metoda ta polega na niezależnej nauce kilku podstawowych klasyfikatorów, które uczą się równolegle na różnie podzielonych podzbiorach danych treningowych. Następnie wyuczone klasyfikatory dokonują prognozy dla każdego wektora cech zbioru testowego. Tak uzyskane klasyfikatory mogą generować różne wyniki dla tego samego zbioru testowego, dlatego jedną z metod podejmowania decyzji o przypisaniu wektora cech do odpowiedniej klasy jest wybranie jej na podstawie głosowania większościowego. Jedną z odmian baggingu jest subbagging [113], który od klasycznej wersji różni się tym, że podzbiory danych treningowych tworzone są bez zwracania, czyli w utworzonych podzbiorach danych treningowych, nie ma duplikatów, a każdy model jest uczony na unikalnym podzbiórze danych.

W przedstawionych w rozprawie badaniach przeprowadzano 8-krotną krosvalidację, której efektem było wyselekcjonowanie dla każdej z osób 8 sztucznych sieci neuronowych, zgodnie z opisem w punkcie 5.1. W analizach wykorzystywano cechy będące współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej. Każda z 8 sieci miała za zadanie zdecydować, czy podane na jej wejściu wektory cech ze zbioru testowego należą do osoby, którą sieć uczyła się rozpoznawać, czy należą do kogoś innego. Zależność współczynnika fałszywych akceptacji (FAR) i współczynnika fałszywych odrzuceń (FRR) od liczby sieci głosujących za tym, że podany na wejściu sieci wektor cech należy do osoby, którą sieć uczyła się weryfikować została zilustrowana na rysunku 29. Przedstawione na rysunku wyniki analiz zostały otrzymane z wykorzystaniem 15 sesji treningowych i 5 sesji testowych. Otrzymany błąd zrównoważony (EER), będący przecięciem krzywych FAR i FRR, wyniósł około 2 % dla trzech sieci neuronowych głosujących za tym, że osoba jest tą, którą sieć uczyła się weryfikować. W przypadku głosowania większościowego, czyli dla przyjętych pięciu sieci neuronowych wskazujących, że osoba jest tą, którą sieć uczyła się weryfikować, wartość FAR wyniosła 1 %, a FRR 3,4 %.




Rysunek 29. Zależność FAR i FRR od progu decyzyjnego.

Na rysunku 30 przedstawiono porównanie wyników uzyskanych bez głosowania większościowego i z głosowaniem większościowym. W celu zwiększenia czytelności rysunków, osie rzędnych wykresów uśrednionych miar jakości klasyfikacji zostały ograniczone do zakresu 70-100 %. Odchylenia standardowe uzyskanych wyników zostały pokazane na rysunku 31. Oś rzędnych w przypadku wyników uzyskanych bez głosowania większościowego została ograniczona do przedziału 0-25 %, a w przypadku wykorzystania głosowania większościowego do przedziału 0-10 %. Dla zwiększenia czytelności rozprawy i zwiększenia komfortu porównania rezultatów na znajdujących się po lewej stronie wykresach umieszczonych na rysunkach 30 i 31 powtórzono wyniki z rysunku 25, przedstawione wcześniej w punkcie 5.2. Otrzymane w tym punkcie wartości miar jakości weryfikacji tożsamości w formie liczbowej zostały przedstawione w tabelach 7 i 8.



Rysunek 30. Uśrednione wartości miar oceny jakości klasyfikacji uzyskane bez głosowania większościowego (z lewej) oraz z wykorzystaniem głosowania większościowego (z prawej).



Rysunek 31. Odchylenia standardowe wartości miar oceny jakości klasyfikacji uzyskane bez głosowania większościowego (z lewej) oraz z wykorzystaniem głosowania większościowego (z prawej).

Analizując wartości miar jakości klasyfikacji oraz ich odchylenia standardowe przedstawione na powyższych rysunkach, można zauważyć, że po zastosowaniu głosowania większościowego zwiększyły się średnie wartości miar jakości klasyfikacji oraz zmniejszyły się ich średnie odchylenia standardowe. Po zastosowaniu głosowania większościowego i wykorzystaniu 5 sesji testowych oraz 15 sesji treningowych średnia wartość dokładności wzrosła z 96,6 % do 97,8 %, jednocześnie średnie wartości odchyłeń standardowych zmalały z 4,2 % do 1,0 %. Największe różnice pomiędzy brakiem, a zastosowaniem głosowania większościowego można zaobserwować w przypadku mniejszej liczby sesji treningowych. Przykładowo przy wykorzystaniu do analiz 5 sesji testowych i jednej sesji treningowej po zastosowaniu głosowaniu większościowego średnia dokładność wzrosła z 81,5 % do 89,7 %, czułość z 74,8 % do 86,9 %, swoistość z 88,1 % do 93,6 % i precyzja z 84,7 % do 94,3 %. Średnie odchylenia standardowe z kolei zmniejszyły się dla dokładności z 11,2 % do 4,3 %, czułości z 22,5 % do 6,6 %, swoistości z 5,2 % do 1,3 % i precyzji z 8,2 % do 0,9 %.

Tabela 7. Średnie wartości miar oceny jakości klasyfikacji wraz z ich odchyleniami standardowymi uzyskane bez głosowania większościowego.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	81,5±11,2	74,8±22,5	88,1±5,2	84,7±8,2	11,9±5,2	25,2±22,5
2	87,0±7,6	81,8±14,8	92,1±5,4	91,7±4,7	7,9±5,4	18,2±14,8
3	88,7±8,4	83,4±16,8	93,9±2,8	92,9±3,6	6,1±2,8	16,6±16,8
4	91,2±7,2	87,6±14,2	94,9±2,6	94,6±2,8	5,1±2,6	12,4±14,2
5	92,2±7,0	88,2±13,7	96,2±1,7	95,9±2,0	3,8±1,7	11,8±13,7
6	93,3±5,9	90,1±11,3	96,5±1,7	96,3±1,9	3,5±1,7	9,9±11,3
7	94,5±5,5	91,7±10,3	97,3±1,3	97,1±1,6	2,7±1,3	8,3±10,3
8	94,6±5,4	91,8±10,4	97,4±1,3	97,2±1,5	2,6±1,3	8,2±10,4
9	95,5±4,8	93,5±8,7	97,6±1,6	97,4±1,8	2,4±1,6	6,5±8,7
10	95,7±4,6	93,7±8,6	97,8±1,2	97,7±1,3	2,2±1,2	6,3±8,6
11	95,6±4,7	93,7±8,5	97,4±1,4	97,3±1,6	2,6±1,4	6,3±8,5
12	96,1±5,5	94,1±10,5	98,0±0,8	97,9±1,0	2,0±0,8	5,9±10,5
13	96,2±4,6	94,4±8,6	98,1±1,0	98,0±1,2	1,9±1,0	5,6±8,6
14	96,5±4,6	94,5±8,5	98,4±1,0	98,3±1,2	1,6±1,0	5,5±8,5
15	96,6±4,2	95,1±8,0	98,1±0,9	98,0±1,1	1,9±0,9	4,9±8,0

Tabela 8. Średnie wartości miar oceny jakości klasyfikacji wraz z ich odchyleniami standardowymi uzyskane z wykorzystaniem głosowania większościowego.

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	89,7±4,3	86,9±6,6	93,6±1,3	94,3±0,9	6,4±1,3	13,1±6,6
2	92,4±2,9	89,9±4,6	95,5±1,1	95,8±1,0	4,5±1,1	10,1±4,6
3	91,5±3,1	87,4±4,3	97,0±0,9	97,3±0,8	3,0±0,9	12,6±4,3
4	94,9±1,9	92,6±3,0	97,6±0,9	97,7±0,8	2,4±0,9	7,4±3,0
5	95,4±1,8	93,0±2,9	98,2±0,4	98,3±0,3	1,8±0,4	7,0±2,9
6	95,7±1,3	93,3±2,2	98,3±0,4	98,4±0,3	1,7±0,4	6,7±2,2
7	96,7±1,6	94,7±2,7	98,9±0,3	99,0±0,3	1,1±0,3	5,3±2,7
8	96,7±1,5	94,9±2,7	98,7±0,3	98,8±0,3	1,3±0,3	5,1±2,7
9	97,4±1,3	96,3±2,2	98,6±0,3	98,7±0,3	1,4±0,3	3,7±2,2
10	97,2±0,9	96,0±1,7	98,5±0,3	98,5±0,3	1,5±0,3	4,0±1,7
11	97,7±1,2	96,6±2,1	99,0±0,3	99,0±0,3	1,0±0,3	3,4±2,1
12	97,6±1,5	96,2±2,6	99,2±0,3	99,3±0,3	0,8±0,3	3,8±2,6
13	97,6±1,3	96,1±2,3	99,2±0,3	99,2±0,2	0,8±0,3	3,9±2,3
14	97,8±1,1	96,4±2,0	99,2±0,2	99,2±0,2	0,8±0,2	3,6±2,0
15	97,8±1,0	96,6±1,9	99,0±0,2	99,1±0,2	1,0±0,2	3,4±1,9

5.3.4. Wnioski

W punkcie 5.3 przeanalizowano wpływ doboru klasyfikatora na jakość weryfikacji tożsamości osób. Najlepsze rezultaty uzyskano dla klasyfikacji za pomocą sztucznej sieci

neuronowej, algorytmu k-najbliższych sąsiadów oraz maszyny wektorów nośnych. Z uwagi na właściwości sieci neuronowych do dalszej części analiz przedstawionych w rozprawie wybrano sztuczną sieć neuronową, której dokładność nie różniła się statystycznie od innych najlepszych klasyfikatorów.

Następnie porównano wpływ liczby neuronów ukrytych na wartości miar jakości klasyfikacji uśrednionych w zbiorze weryfikowanych osób. Zauważono, że wraz ze zwiększaniem liczby neuronów ukrytych w sztucznej sieci neuronowej, nie następował istotny wzrost średniej dokładności. Duże różnice zaobserwowano w długości czasu nauczania sieci, który był ponad pięćset razy dłuższy dla sieci z dwudziestoma neuronami ukrytymi niż dla sieci z jednym neuronem ukrytym.

Ostatnia analiza przedstawiona w tym punkcie dotyczyła zastosowania klasyfikacji za pomocą głosowania większościowego. W porównaniu do wartości miar jakości klasyfikacji otrzymanych bez głosowania większościowego uzyskane średnie miary jakości weryfikacji uległy poprawie, a ich odchylenia standardowe zmalały.

5.4. Wpływ podpasm widma sygnału EEG


W tym punkcie przeanalizowano wpływ wyboru podpasm widma sygnału EEG na wartości miar jakości weryfikacji tożsamości osób. Przedstawione w niniejszym punkcie wyniki badań nawiązują do analiz przedstawionych w artykułach [58], [59], w których poszukiwano podpasm widma sygnału EEG mających najistotniejszy udział w weryfikacji tożsamości.

5.4.1. Przeprowadzone badania


Zawężenie analizowanego pasma częstotliwości i wybór odpowiedniej kombinacji podpasm ma bezpośredni wpływ na redukcję liczby cech podawanych na wejście klasyfikatora, co skraca czas jego trenowania oraz podejmowania decyzji. Wyrażenie współczynników widmowej gęstości mocy w skali decybelowej umożliwiło zwiększenie znaczenia składowych sygnału EEG, które niosą mniejszą ilość energii. Otrzymanie lepszych wyników po takiej konwersji może zatem świadczyć o tym, że informacje o danych osobniczych mogą znajdować się przede wszystkim w podpasmach odpowiadających rytmom o niskich amplitudach, m.in. β i γ .

Na poniższych rysunkach przedstawiono uśrednione w zbiorze osób wyniki miar jakości klasyfikacji uzyskane w przypadku wykorzystania podpasm widma sygnału EEG odpowiadających jego pojedynczym rytmom (rysunki 32-36). Uśrednione wartości miar jakości weryfikacji tożsamości osób dla rozpatrywanych podpasm wraz z ich odchyleniami standardowymi zostały zamieszczone w tabelach w Dodatku B. Klasyfikacja odbywała się



w sposób opisany w punkcie 5.3.3, a przyjęte w rozprawie zakresy częstotliwości odpowiadające poszczególnym rytmom sygnału EEG zostały określone w tabeli 1. Na rysunku 32, dolną granicą przedziału była wartość 55 %. Na rysunkach 33-36, na wykresach przedstawiających uśrednione wartości miar jakości klasyfikacji osie rzędnych zostały ograniczone do przedziału 65-100 %. Na wykresach odchyłeń standardowych osie zostały ograniczone do przedziału 0-10 %, by lepiej uwidocznili wpływ liczby sesji treningowych na obrazowane parametry. Kolorem niebieskim oznaczono dokładność (ACC), czerwonym czułość (SEN), żółtym swoistość (SPEC), a fioletowym precyzję (PREC).





Rysunek 32. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasma odpowiadającego rytmowi δ w zależności od liczby sesji treningowych.





Rysunek 33. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasma odpowiadającego rytmowi θ w zależności od liczby sesji treningowych.



Rysunek 34. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasma odpowiadającego rytmowi α w zależności od liczby sesji treningowych.



Rysunek 35. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasma odpowiadającego rytmowi β w zależności od liczby sesji treningowych.



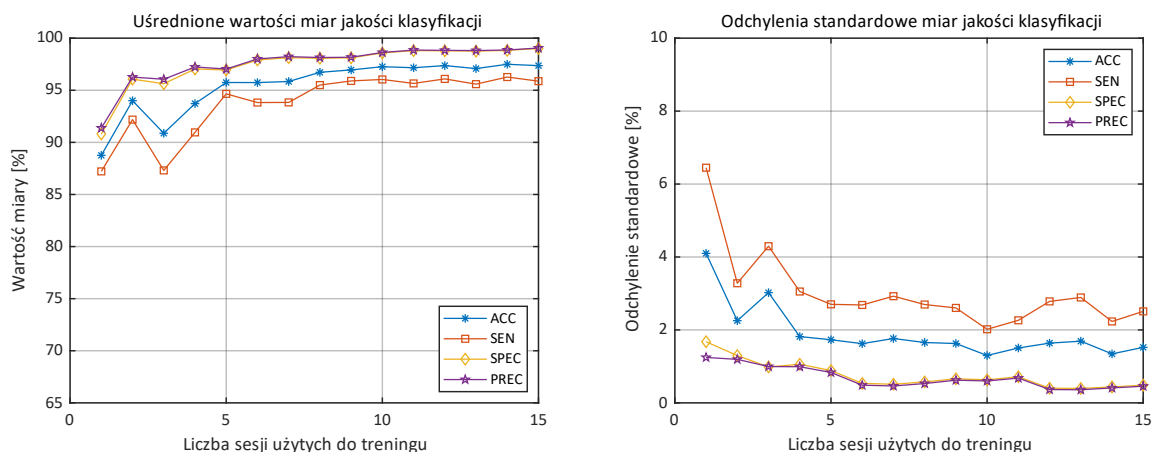
Rysunek 36. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasma odpowiadającego rytmowi γ w zależności od liczby sesji treningowych.

Najmniej stabilne wyniki uzyskano dla podpasma sygnału EEG odpowiadającego rytmowi δ (1-4 Hz). Osiągnięte miary jakości weryfikacji były najniższe, a wraz z liczbą sesji treningowych rosło średnie odchylenie standardowe czułości oraz średnie odchylenie



standardowe dokładności. Otrzymane wyniki świadczą o tym, że w tym podpaśmie znajduje się najwięcej krótkookresowych, niepowtarzalnych zakłóceń pochodzenia technicznego i biologicznego, które mogą częściowo ukrywać wpływ stałych cech osobniczych.

Wśród podpasz odpowiadających pojedynczym rytmom sygnału EEG najwyższe miary jakości weryfikacji otrzymano dla podpasma odpowiadającego rytmowi β (12-30 Hz), następnie dla α (8-12 Hz) oraz γ (30-45 Hz). Trochę gorsze wyniki otrzymano podczas analizy podpasma odpowiadającego rytmowi θ (4-8 Hz), chociaż w jego przypadku zauważono niskie i stabilne odchylenia standardowe dla wszystkich miar oceny jakości weryfikacji. Zaobserwowano, że wraz ze wzrostem liczby sesji treningowych miary jakości weryfikacji wykazywały tendencję do poprawy i zwiększała się ich wartość.



Na rysunkach 37-41 przedstawiono uśrednione wyniki miar jakości klasyfikacji dla podpasz widma sygnału EEG odpowiadających wybranym zestawom podpasz, które były tworzone poprzez łączenie podpasz odpowiadających pojedynczym rytmom sygnału EEG dla których uzyskano najwyższe wartości średniej dokładności. Podobnie, jak w przypadkach wyników uzyskanych dla podpasz widma sygnału EEG odpowiadających jego pojedynczym rytmom, uśrednione wartości miar jakości weryfikacji tożsamości osób dla wybranych zestawów podpasz oraz ich odchylenia standardowe zostały zamieszczone w tabelach w Dodatku B. Sposób prezentowania wyników był taki sam jak dla wyników otrzymanych dla podpasz widma sygnału EEG odpowiadających jego pojedynczym rytmom.





Rysunek 37. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasz odpowiadających rytmom $\alpha+\beta$ w zależności od liczby sesji treningowych.



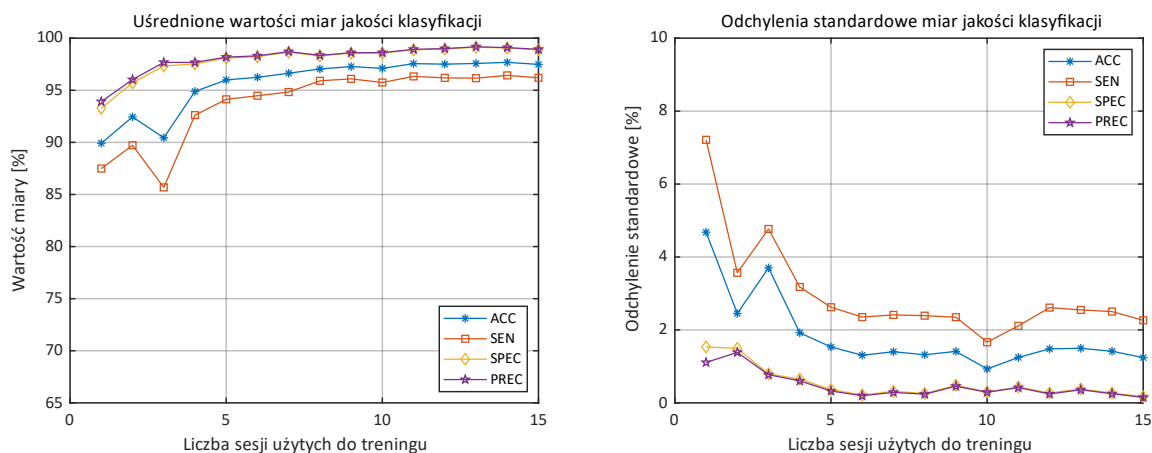
Rysunek 38. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasm odpowiadających rytmom $\beta+\gamma$ w zależności od liczby sesji treningowych.



Rysunek 39. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasm odpowiadających rytmom $\alpha+\beta+\gamma$ w zależności od liczby sesji treningowych.



Rysunek 40. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasm odpowiadających rytmom $\delta+\alpha+\beta+\gamma$ w zależności od liczby sesji treningowych.




Rysunek 41. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla podpasem odpowiadających rytmom $\theta+\alpha+\beta+\gamma$ w zależności od liczby sesji treningowych.

Zarówno w przypadku podpasem sygnału EEG odpowiadających pojedynczym rytmom, jak i w przypadku ich zestawów, można zauważyć, że wraz ze wzrostem liczby sesji treningowych wartości miar jakości klasyfikacji ulegały ogólnej poprawie. Największe różnice pomiędzy wykorzystaniem jednej, a piętnastu sesji treningowych można zaobserwować dla średnich wartości czułości i dokładności, a najmniejsze dla średnich wartości precyzji i swoistości. Warto podkreślić, że w każdym analizowanym zestawie podpasem sygnału EEG uzyskano średnią wartość dokładności przekraczającą wyniki uzyskane dla podpasem odpowiadających pojedynczym rytmom, choć nie odbiegały one wyraźnie od wyników dla podpasma rytmu β . W tabeli 9 przedstawiono uśrednione w zbiorze osób miary jakości oceny weryfikacji otrzymane dla każdego z analizowanych podpasem w przypadku wykorzystania 15 sesji treningowych.

Tabela 9. Średnie wyniki miar jakości klasyfikacji oraz ich odchylenia standardowe dla wybranych podpasem sygnału EEG. Wyniki pokazane dla 15 sesji treningowych.

Podpasmo	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
δ	82,3±3,4	80,3±5,0	84,9±1,7	86,1±1,1	15,1±1,7	19,7±5,0
θ	88,5±0,8	87,0±1,0	90,2±1,1	90,6±1,1	9,8±1,1	13,0±1,0
α	92,5±1,2	90,1±1,7	95,3±0,8	95,5±0,8	4,7±0,8	9,9±1,7
β	97,1±1,5	95,9±2,3	98,3±0,6	98,4±0,6	1,7±0,6	4,1±2,3
γ	91,7±2,0	90,1±3,1	93,4±0,8	93,7±0,6	6,6±0,8	9,9±3,1
$\alpha+\beta$	97,4±1,5	95,9±2,5	99,0±0,5	99,1±0,5	1,0±0,5	4,1±2,5
$\beta+\gamma$	97,4±1,2	96,1±1,9	98,8±0,5	98,8±0,4	1,2±0,5	3,9±1,9
$\alpha+\beta+\gamma$	97,3±1,2	96,0±2,3	98,7±0,2	98,7±0,2	1,3±0,2	4,0±2,3
$\delta+\alpha+\beta+\gamma$	97,8±1,1	96,7±2,1	99,0±0,1	99,0±0,1	1,0±0,1	3,3±2,1
$\theta+\alpha+\beta+\gamma$	97,5±1,2	96,2±2,3	98,9±0,2	98,9±0,2	1,1±0,2	3,8±2,3
całe pasmo	97,8±1,0	96,6±1,9	99,0±0,2	99,1±0,2	1,0±0,2	3,4±1,9

Na rysunku 42 pokazano otrzymane miary oceny jakości klasyfikacji uśrednione w zbiorze 29 osób w przypadku wykorzystania 15 sesji treningowych. Zostały one podzielone na dwa wykresy, gdzie lewy zawiera wyniki dla podpasem odpowiadających pojedynczym rytmom sygnału EEG, a prawy wykres przedstawia wyniki dla wybranych zestawów. Dla uwypuklenia różnic osie rzędnych wykresów zostały ograniczone do przedziału 70-100 %.



Rysunek 42. Miary jakości klasyfikacji uzyskane dla rozpatrywanych podpasem.

Aby określić, czy występują statystycznie istotne różnice w wartościach dokładności pomiędzy wynikami uzyskanymi z wykorzystaniem 15 sesji treningowych otrzymanymi dla rozpatrywanych podpasem widma sygnału EEG, przeprowadzono analizę za pomocą testu Wilcoxona dla par obserwacji. Otrzymane p-wartości zostały przedstawione w tabeli 10. Na czerwono zostały oznaczone przypadki wskazujące na występowanie istotnych statystycznie różnic w dokładnościach uzyskanych dla różnych podpasem widma sygnału EEG, na zielono p-wartości wskazujące na brak występowania istotnych statystycznie różnic.

Tabela 10. p-wartości uzyskane za pomocą testu Wilcoxona pomiędzy dokładnościami otrzymanymi dla wybranych podpasem widma sygnału EEG. Kolorem czerwonym oznaczono występowanie różnic istotnych statystycznie ($p < 0,05$), zielonym nieistotnych.

Podpasmo	θ	α	β	γ	$\alpha+\beta$	$\beta+\gamma$	$\alpha+\beta+\gamma$	$\delta+\alpha+\beta+\gamma$	$\theta+\alpha+\beta+\gamma$	całe pasmo
δ	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001
θ		<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001
α			<0,001	0,111	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001
β				<0,001	0,116	0,116	0,144	0,011	0,047	0,018
γ					<0,001	<0,001	<0,001	<0,001	<0,001	<0,001
$\alpha+\beta$						0,351	0,899	0,088	0,489	0,157
$\beta+\gamma$							0,539	0,031	0,608	0,019
$\alpha+\beta+\gamma$								0,013	0,226	0,019
$\delta+\alpha+\beta+\gamma$									0,065	0,905
$\theta+\alpha+\beta+\gamma$										0,125

Wśród podpasem odpowiadających pojedynczym rytmom sygnału EEG najlepsze wyniki uzyskano w przypadku wykorzystania podpasma β , a najgorsze wyniki zostały otrzymane w przypadku podpasem θ oraz δ . Zaobserwowano istotne statystycznie różnice w wartościach dokładności pomiędzy dokładnościami uzyskanymi dla wszystkich podpasem odpowiadających pojedynczym rytmom sygnału EEG, a dokładnościami otrzymanymi z wykorzystaniem wszystkimi ich zestawów. Wyjątkiem są wyniki otrzymane dla podpasma β , w przypadku którego wykorzystania nie znaleziono istotnych statystycznie różnic w dokładności dla tego podpasma, w porównaniu z parami jego połączeń z sąsiadującymi podpasemami ($\alpha+\beta$ i $\beta+\gamma$) i całą trójką tych podpasem ($\alpha+\beta+\gamma$).

Najmniejszym zestawem podpasem widma sygnału EEG, dla którego nie wykazano występowania istotnych różnic w uzyskanej dokładności względem całego rozpatrywanego pasma był zestaw złożony z podpasem $\alpha+\beta$. Natomiast w przypadku wykorzystania podpasem $\beta+\gamma$ i podpasem $\alpha+\beta+\gamma$ zaobserwowano wystąpienie różnic istotnych statystycznie w wartości dokładności w stosunku do dokładności otrzymanej dla całego pasma sygnału EEG. Z tych powodów w dalszej części pracy do porównań uwzględniano zestaw złożony z podpasem $\alpha+\beta$.

Podobne analizy statystyczne przedstawiono w artykule [59]. Zaprezentowano tam wyniki weryfikacji tożsamości dla wybranych sparametryzowanych cech podpasem widma sygnału EEG przedstawionych wzorami (10)-(12), obliczonych dla każdego z podpasem odpowiadających pojedynczym rytmom sygnału EEG oraz ich zestawów. W tej publikacji przedstawiono wartości miar jakości weryfikacji dla tych samych zestawów podpasem, które uwzględniono w rozprawie. Wśród podpasem odpowiadających pojedynczym rytmom sygnału EEG najwyższe miary oceny jakości weryfikacji zostały osiągnięte w przypadku wykorzystania podpasma β , a następnie podpasem α i γ . Analiza statystyczna wielokrotnych porównań par wartości średnich w grupach za pomocą testu Tukeya [112] wykazała, że w przypadku wykorzystania samego podpasma β oraz zestawów podpasem zawierających podpasmo β nie znaleziono istotnych statystycznie różnic pomiędzy wartościami dokładności weryfikacji tożsamości uzyskanymi dla nich a dokładnością otrzymaną dla całego analizowanego pasma sygnału EEG. Wyniki powyższych analiz w postaci p-wartości przedstawiono w tabeli 11.

Tabela 11. *p*-wartości otrzymane dla testu porównań wielokrotnych z wykorzystaniem metody Tukeya pomiędzy analizowanymi podpasмами. Wyniki zaznaczone na zielono wskazują brak występowania istotnych statystycznie różnic, na czerwono, że występują różnice ($p < 0,05$).

Źródło: [59].

EEG Bands	δ	θ	α	β	γ	$\beta \gamma$	$\alpha \beta$	$\alpha \beta \gamma$	$\delta \alpha \beta \gamma$	All
δ		0.99	0.97	0.02	0.99	1.7×10^{-5}	1.0×10^{-3}	1.8×10^{-6}	7.4×10^{-7}	5.5×10^{-7}
θ			0.39	2.2×10^{-4}	0.49	1.6×10^{-7}	5.6×10^{-6}	1.3×10^{-7}	1.3×10^{-7}	1.3×10^{-7}
α				0.42	1.00	4.8×10^{-3}	0.08	8.5×10^{-4}	3.9×10^{-4}	2.9×10^{-4}
β					0.32	0.86	1.00	0.59	0.47	0.43
γ						2.6×10^{-3}	0.05	4.2×10^{-4}	1.9×10^{-4}	1.4×10^{-4}
$\beta \gamma$							1.00	1.00	1.00	1.00
$\alpha \beta$								0.96	0.91	0.89
$\alpha \beta \gamma$									1.00	1.00
$\delta \alpha \beta \gamma$										1.00
All										

W artykule [59] przedstawiono wartości miar oceny jakości weryfikacji bez zastosowania metody głosowania większościowego. Uzyskane wyniki posiadały wysoką wariancję. Mogło to być przyczyną braku wystąpień istotnych statystycznie różnic pomiędzy dokładnością, gdy sparametryzowane cechy pochodziły wyłącznie z podpasma β , a dokładnością otrzymaną w przypadku, gdy wykorzystywano cechy ze wszystkich rozpatrywanych podpasm. Wyniki dla uśrednionych miar jakości klasyfikacji pokazano w tabeli 12.

Tabela 12. Wyniki dla uśrednionych miar jakości klasyfikacji dla sparametryzowanych cech podpasm widma sygnału EEG.

Źródło: [59].

EEG Bands	ACC (%)	SEN (%)	SPEC (%)	PREC (%)
δ	82.6 ± 9.2	81.0 ± 13.1	84.1 ± 8.3	83.5 ± 8.5
θ	80.6 ± 7.5	78.2 ± 11.7	83.0 ± 6.6	82.1 ± 6.7
α	84.8 ± 8.4	82.6 ± 14.2	87.1 ± 5.6	86.1 ± 7.1
β	89.0 ± 6.8	88.0 ± 10.7	89.9 ± 5.5	89.7 ± 5.8
γ	84.6 ± 7.4	82.1 ± 10.7	87.0 ± 6.0	86.2 ± 6.6
$\beta \gamma$	91.9 ± 4.9	91.0 ± 7.1	92.8 ± 4.0	92.6 ± 4.2
$\alpha \beta$	90.3 ± 7.7	88.8 ± 12.5	91.8 ± 4.6	91.3 ± 5.3
$\alpha \beta \gamma$	92.7 ± 5.1	91.6 ± 8.0	93.7 ± 3.9	93.5 ± 4.1
$\delta \alpha \beta \gamma$	93.0 ± 5.8	91.4 ± 9.3	94.5 ± 3.8	94.3 ± 4.1
All	93.1 ± 5.6	91.6 ± 9.0	94.6 ± 3.6	94.3 ± 3.9

Niezależnie od wykorzystywanych cech i metody klasyfikacji (tabela 9, tabela 12), wśród podpasm odpowiadających pojedynczym rytmom sygnału EEG najwyższe miary oceny jakości klasyfikacji zostały osiągnięte w przypadku wykorzystania podpasma β , które często jest uważane za fizjologiczny wskaźnik uwagi badanego [73], [114]. Miary oceny jakości klasyfikacji uzyskane w przypadku wykorzystania podpasm α i γ również były wysokie. Należy jednak zachować szczególną ostrożność podczas opierania systemu weryfikacji tożsamości osób na pojedynczych rytmach sygnału EEG, ponieważ podpasma widma sygnału EEG odpowiadające wyższym częstotliwościom (takie jak górna granica β lub γ) nakładają się na aktywność mięśniową [115], która może wpływać na odczyt tych rytmów [115]–[117].

5.4.2. Wnioski

W niniejszym punkcie przedstawiono rezultaty badań dotyczących wpływu podpasów widma sygnału EEG na jakość weryfikacji tożsamości osób. Najmniejszym zestawem podpasów, w przypadku którego wykazano, że otrzymane wartości dokładności weryfikacji tożsamości nie przejawiają istotnych różnic statystycznych względem dokładności otrzymanych po zastosowaniu całego pasma sygnału EEG było połączenie podpasów alfa i beta ($\alpha+\beta$). Zastosowanie tego zestawu spowodowało redukcję liczby rozpatrywanych cech z 45 do 23 dla każdej elektrody użytej do akwizycji sygnału EEG. W przypadku zastosowania 19 elektrod do akwizycji sygnału EEG, ograniczenie liczby podpasów do $\alpha+\beta$ umożliwiło zmniejszenie liczby wszystkich cech podawanych na wejście klasyfikatora z 855 do 437. Z tego powodu podpasmo obejmujące rytmy $\alpha+\beta$ będzie rozpatrywane w dalszej części pracy.

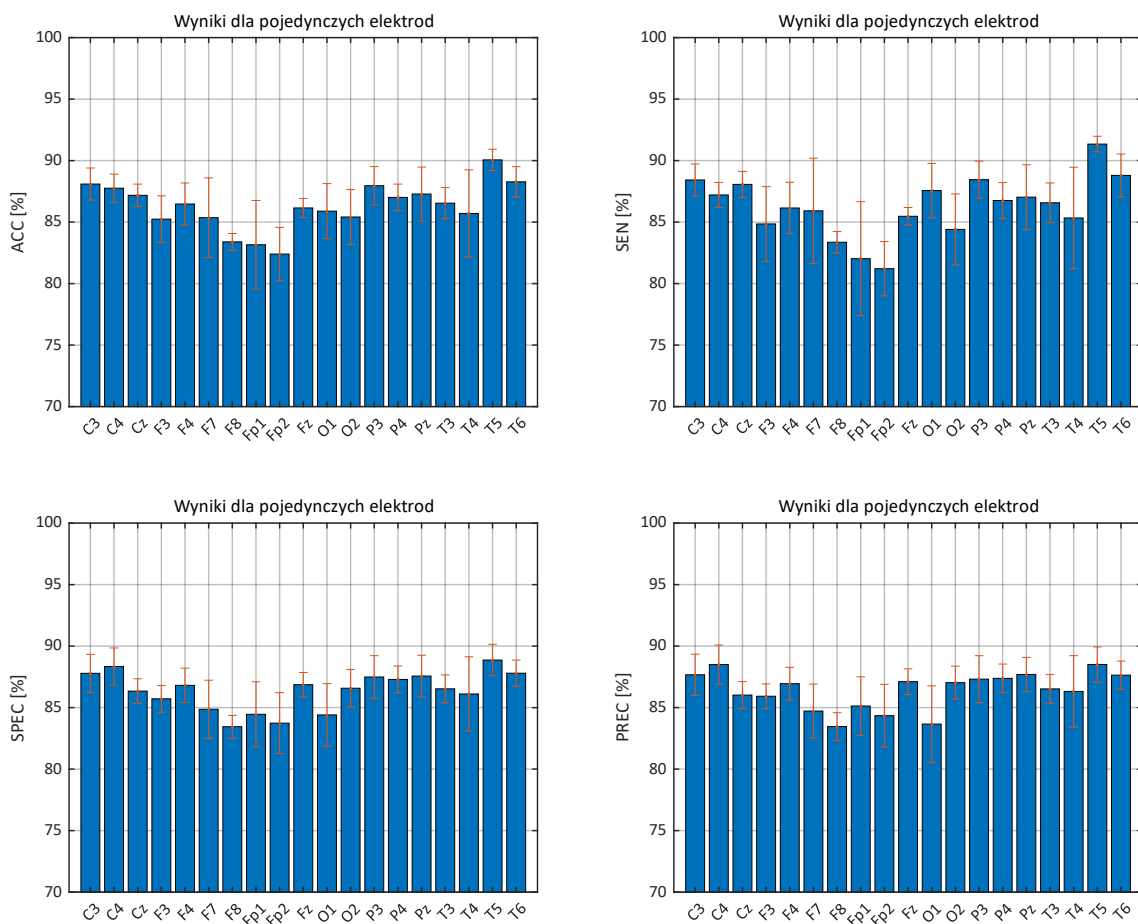
W dalszej części punktu przedstawiono wyniki opublikowane w artykule [59], w którym prezentowano średnie wartości miar jakości weryfikacji uzyskane z wykorzystaniem sparametryzowanych cech podpasów widma sygnału EEG. Wyniki uzyskane w ten sposób posiadały niższą średnią wartość dokładności oraz większą wariancję miar jakości weryfikacji tożsamości. Niezależnie od przyjętych cech i metody klasyfikacji wykazano, że zastosowanie w weryfikacji tożsamości osób podpasma β zapewnia lepsze wyniki w porównaniu do innych podpasów odpowiadających pojedynczym rytmom sygnału EEG.

5.5. Wpływ liczby oraz umiejscowienia elektrod

Praktyczna implementacja systemu do weryfikacji tożsamości osób powinna być względnie wygodna dla użytkownika w codziennym zastosowaniu. Można to osiągnąć m.in. poprzez zmniejszenie liczby elektrod używanych do akwizycji sygnału EEG, a tym samym skrócenie czasu wymaganego do przygotowania danej osoby do weryfikacji. Takie podejście umożliwiłoby również opracowanie dedykowanej opaski do akwizycji sygnału EEG, co jeszcze bardziej zredukowałoby czas przygotowania do rejestracji sygnału. Dodatkowo zmniejszenie liczby elektrod wiąże się ze zmniejszeniem liczby cech podawanych na wejście klasyfikatora, co umożliwia ograniczenie czasu jego trenowania i generowania odpowiedzi. Wstępne wyniki dotyczące tych badań zostały przedstawione w artykułach [62], [63], których pierwszą autorką była autorka tej rozprawy, a w których analizowano wpływ wybranych elektrod używanych do akwizycji sygnału EEG na jakość weryfikacji tożsamości osób. W ramach badań przedstawionych w rozprawie podjęto próbę ograniczenia liczby elektrod przynajmniej o połowę. Elektrody były umieszczane na głowach osób badanych zgodnie z układem elektrod 10-20, który przedstawiono na rysunku 5.

5.5.1. Przeprowadzone badania

Badania nad doбором zestawu elektrod do akwizycji sygnału EEG rozpoczęto od przeanalizowania wpływu pojedynczych elektrod na miary oceny jakości weryfikacji tożsamości osób. W tym celu przeprowadzono weryfikację tożsamości z wykorzystaniem każdej z elektrod oddzielnie. Analizie poddawano sygnały uzyskane z pojedynczych elektrod, z tego powodu nie stosowano filtra przestrzennego CAR (7). Uśrednione w zbiorze osób wartości dokładności ACC (1), czułości SEN (2), swoistości SPEC (3) i precyzji PREC (4) dla każdej z elektrod, przedstawiono na rysunku 43. Zaprezentowane wyniki dotyczą badań przeprowadzonych z wykorzystaniem 15 sesji treningowych, 5 testowych i cech pochodzących z całego rozpatrywanego pasma sygnału EEG. Klasyfikacja odbywała się z wykorzystaniem głosowania większościowego. Na rysunkach oś rzędnych została ograniczona do zakresu 70-100 %.



Rysunek 43. Uśrednione miary jakości klasyfikacji uzyskane dla weryfikacji z użyciem pojedynczych elektrod.

Analizując wyniki otrzymane dla pojedynczych elektrod, można zauważyć, że najwyższe miary jakości weryfikacji zostały osiągnięte dla elektrody T5 rejestrującej sygnał z tylnej





okolicy lewego płata skroniowego mózgu. Gorsze, choć również wysokie wyniki otrzymano dla elektrody T6 – umieszczonej nad tylną okolicą prawego płata skroniowego, elektrod C3 i C4 – znajdujących się nad granicą płata czołowego i ciemieniowego z lewej i prawej strony, P3 i P4 – nad płatem ciemieniowym z lewej i prawej strony oraz O1 i O2 – nad płatem potylicznym z lewej i prawej strony. Najsłabsze wyniki osiągnięto dla elektrod Fp1 i Fp2, umiejscowionych nad płatem czołowym z lewej i z prawej strony. Analiza otrzymanych wartości miar jakości klasyfikacji potwierdziła, że elektrody tworzą symetryczne pary, dla których otrzymano względnie zbliżone średnie dokładności. Podczas tworzenia zestawów elektrod do akwizycji sygnału EEG uwzględniono ich ułożenie oraz symetryczność. Elektrody, dla których osiągnięto najwyższe wartości dokładności zostały połączone w pary względem osi centralnej głowy, zgodnie ze sposobem umieszczenia elektrod 10-20 pokazanym na rysunku 5. Wybrane pary połączone w czwórki, szóstkę oraz w ósemkę. Elektrody znajdujące się na osi centralnej głowy (Fz, Cz, Pz) nie posiadały pary, dlatego zostały połączone ze sobą w trójkę. Podobny sposób dobierania zestawów elektrod został przedstawiony w artykule [62].

Dodatkowo w niniejszej rozprawie przedstawiono wyniki weryfikacji tożsamości osób na podstawie sygnałów EEG uzyskanych z połączonych ze sobą elektrod czołowych łącząc je w symetryczne pary oraz czwórki, podobnie jak w artykule [63]. Pojedyncze elektrody czołowe zapewniały najniższe miary jakości klasyfikacji, jednak zbadano je ze względu na łatwość akwizycji sygnału EEG z tych okolic oraz ich dostępność w komercyjnych opaskach EEG (przykłady komercyjnych opasek zamieszczono na rysunku 6). Wyniki dla wybranych zestawów elektrod dla całego analizowanego pasma sygnału EEG zostały pokazane na rysunku 44, a w przypadku wykorzystania podpasm $\alpha+\beta$, wybranych w punkcie 5.4, na rysunku 45. Przetwarzanie wstępne sygnałów z wielu elektrod uwzględniało filtrację CAR, w której wykorzystywano elektrody znajdujące się w analizowanym zestawie.

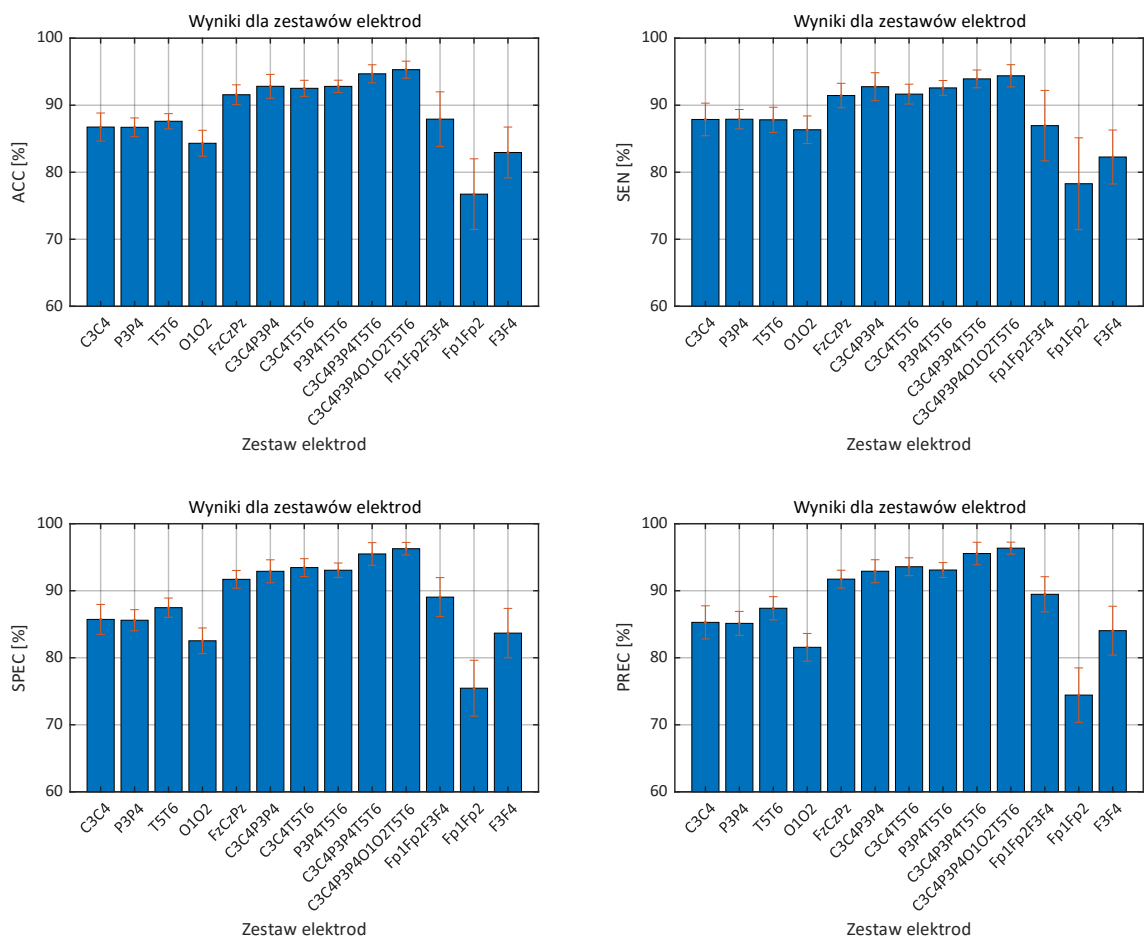
W tabeli 13 zamieszczono uśrednione w zbiorze 29 osób wartości dokładności (ACC) oraz ich odchylenia standardowe otrzymane dla każdego z rozpatrywanych zestawów elektrod. Wyniki w tabeli przedstawiono zarówno w przypadku wykorzystania cech z całego rozpatrywanego pasma sygnału EEG, jak również z wykorzystaniem wyznaczonego w punkcie 5.4 podpasma $\alpha+\beta$.

Tabela 13. Wartości dokładności klasyfikacji (ACC) i ich odchylenia standardowe uzyskane dla wybranych zestawów elektrod dla całego rozpatrywanego pasma sygnału EEG oraz dla podpasma $\alpha+\beta$.

Zestaw elektrod	ACC całego pasma [%]	ACC podpasma $\alpha+\beta$ [%]
C3C4	88,7±1,7	86,7±2,1
P3P4	88,6±1,1	86,7±1,4
T5T6	89,9±0,7	87,6±1,1
O1O2	86,3±2,6	84,3±1,9
FzCzPz	93,6±0,9	91,6±1,5
C3C4P3P4	93,2±1,2	92,8±1,8
C3C4T5T6	93,9±1,2	92,5±1,2
P3P4T5T6	93,7±0,7	92,8±0,9
C3C4P3P4T5T6	95,6±1,2	94,7±1,4
C3C4P3P4O1O2T5T6	96,0±1,1	95,3±1,3
Fp1Fp2F3F4	90,5±3,5	87,9±4,1
Fp1Fp2	80,7±5,4	76,7±5,3
F3F4	85,7±3,9	82,9±3,8



Rysunek 44. Uśrednione miary jakości klasyfikacji otrzymane dla analizowanych zestawów elektrod dla całego rozpatrywanego pasma widma sygnału EEG.




Rysunek 45. Uśrednione miary jakości klasyfikacji otrzymane dla analizowanych zestawów elektrod dla podpasma odpowiadających rytmom $\alpha + \beta$.

Analiza wyników uzyskanych dla całego pasma sygnału EEG wykazała, że w większości przypadków zwiększanie liczby elektrod w zestawie pozytywnie wpływało na jakość weryfikacji tożsamości osób (patrz rysunki 43 i 44). Średnia wartość dokładności weryfikacji tożsamości uzyskana dla par elektrod C3C4, P3P4 i O1O2 uległa poprawie w stosunku do pojedynczych elektrod w danej parze. W przypadku pary F3F4 średnia dokładność weryfikacji okazała się niższa niż dla samej elektrody F4 ($86,5 \pm 1,7 \%$). Dla żadnej z rozpatrywanych par elektrod nie osiągnięto wyższej średniej dokładności niż dla pojedynczej elektrody T5 ($90,1 \pm 0,9 \%$).

W przypadku pary elektrod Fp1Fp2 średnia wartość dokładności weryfikacji uległa pogorszeniu w stosunku do wyników otrzymanych dla pojedynczych elektrod Fp1 i Fp2. Dla pojedynczych elektrod Fp1 i Fp2 również uzyskano najniższe dokładności weryfikacji tożsamości. Wpływ na to mogła mieć metoda pomiarowa – analizowane w rozprawie sygnały EEG zostały zarejestrowane według protokołu badania spoczynkowego z otwartymi oczyma. Oznacza to, że artefakty od sygnału EOG (ruchu oczu) mogły mieć negatywny wpływ na weryfikację tożsamości osób.

Zestawienie trzech elektrod FzCzPz, znajdujących się na osi centralnej głowy, umożliwiło poprawę średniej wartości dokładności weryfikacji tożsamości w stosunku do wszystkich pojedynczych elektrod dla całego pasma sygnału EEG. Otrzymana z wykorzystaniem tych trzech elektrod średnia dokładność była porównywalna ze średnimi dokładnościami uzyskanymi dla zestawów czterech elektrod C3C4P3P4, P3P4T5T6 oraz C3C4T5T6. W zestawieniach czterech elektrod najgorsze wyniki otrzymano dla zestawu czterech elektrod czołowych Fp1Fp2F3F4, których średnia wartość dokładności była zbliżona do średniej wartości dokładności uzyskanej dla pojedynczej elektrody T5. Zwiększenie liczby elektrod w zestawie do sześciu i ośmiu umożliwiło poprawę miar jakości weryfikacji. Wśród rozpatrywanych zredukowanych zestawów elektrod najwyższą wartość średniej dokładności uzyskano dla zestawu złożonego z ośmiu elektrod C3C4P3P4O1O2T5T6, które zostały oznaczone na zielono na rysunku 46. Większy udział elektrod umiejscowionych w tylnej części głowy w stosunku do przedniej w weryfikacji tożsamości mógł być spowodowany naturą badanego sygnału – w analizach wykorzystywano sygnał EEG zarejestrowany w stanie spoczynku z otwartymi oczyma. Z tego powodu sygnały pochodzące z przedniej części głowy mogły nie zawierać cech użytecznych dla weryfikacji tożsamości osób.



Rysunek 46. Proponowany zestaw ośmiu elektrod C3C4P3P4O1O2T5T6.

Zgodnie z oczekiwaniami w większości przypadków zwiększenie liczby elektrod w zestawie zwykle poprawiało uzyskiwane wartości miar jakości weryfikacji. Decyzję o wykorzystaniu mniejszej lub większej liczby elektrod w celu weryfikacji tożsamości należy podjąć w zależności od potencjalnego zastosowania i tego, jak ważne w danym przypadku jest ograniczenie dotyczące liczby elektrod oraz przetwarzanych cech. Zaprezentowane wyniki świadczą o tym, że większy udział w weryfikacji tożsamości na podstawie sygnału EEG zarejestrowanego w stanie spoczynku z otwartymi oczyma mają elektrody umiejscowione w tylnej części głowy, niż w przedniej.

Zmniejszenie liczby elektrod z 19 do zestawu ośmiu elektrod C3C4P3P4O1O2T5T6 i redukcja całego pasma sygnału EEG do podpasm $\alpha+\beta$ umożliwiły ograniczenie liczby cech podawanych na wejście sieci neuronowej z 855 do 184. Dla 15 sesji treningowych zredukowanie rozmiaru wektora podawanego na wejście klasyfikatora spowodowało jednak spadek średniej dokładności weryfikacji tożsamości z $97,8 \pm 1,0$ % do $95,3 \pm 1,3$ %.

5.5.2. Wnioski

W niniejszym punkcie przeanalizowano wpływ liczby i umiejscowienia elektrod do akwizycji sygnału EEG na jakość weryfikacji tożsamości osób. W tym celu zbadano wpływ sygnałów zarejestrowanych z pojedynczych elektrod na miary jakości weryfikacji tożsamości. Elektrody, dla których otrzymano najwyższe średnie wartości dokładności, zostały połączone ze sobą w symetryczne względem osi centralnej głowy pary. Pary te były później łączone w czwórki, szóstkę oraz ósemkę. Dla porównania przeanalizowano również wyniki uzyskane dla trójki elektrod znajdujących się na osi centralnej głowy oraz dla zestawów elektrod czołowych, dla których uzyskano najniższe średnie wartości dokładności. Zauważono, że w przypadku weryfikacji tożsamości na podstawie sygnału EEG zarejestrowanego w stanie spoczynku z otwartymi oczyma, lepsze wyniki uzyskiwane są przy wykorzystaniu elektrod umiejscowionych w tylnej części głowy, niż w przedniej. Po zmniejszeniu liczby elektrod z 19 do 8, czyli użyciu zestawu elektrod C3C4P3P4O1O2T5T6 i redukcji cech zawartych w całym rozpatrywanym paśmie sygnału EEG do cech wyekstrahowanych z podpasm $\alpha+\beta$ zmniejszono rozmiar wektora cech podawanego na wejście sztucznej sieci neuronowej z 855 do 184. Przy wykorzystaniu 15 sesji treningowych spowodowało to spadek średniej wartości dokładności o około 2,5 %.

5.6. Wpływ liczby sesji pomiarowych sygnału EEG użytych do treningu


Żeby móc wykorzystać sygnał EEG jako źródło cech biometrycznych należy określić oraz używać niezmiennych w czasie cech zawartych w tym sygnale. Opracowane modele prezentowane w niektórych publikacjach oparte na ograniczonej liczbie sesji pomiarowych bądź nawet na pojedynczej rejestracji sygnału EEG podzielonej na dane treningowe oraz testowe mogą nie być miarodajne. Na przetwarzany sygnał wpływają chwilowe efekty środowiskowe, sposób umiejscowienia elektrod, aktualny stan psychofizyczny badanego lub inne zakłócenia pochodzenia fizjologicznego oraz technicznego. W skrajnych przypadkach opracowany model może zaadaptować się do zakłóceń lub spontanicznej aktywności mózgu zamiast do stałych cech biometrycznych obecnych w sygnale EEG. Sposobem, który

zapewniłby wiarygodniejszą ocenę proponowanych metod jest rozdzielenie zbiorów treningowych i testowych w ten sposób by pochodziły z różnych sesji pomiarowych sygnału EEG. W niniejszym punkcie przeanalizowano wpływ liczby sesji pomiarowych użytych do treningu sztucznej sieci neuronowej na jakość weryfikacji tożsamości osób. Istotnym elementem tych badań było to, że każda z sesji w zbiorze treningowym i testowym została zarejestrowana innego dnia.

Zaprezentowane w tej części rozprawy wyniki badań są zbliżone do rezultatów przedstawionych w artykule [60]. Zbadano w nim wpływ liczby sesji pomiarowych sygnału EEG potrzebnych do treningu sztucznych sieci neuronowych. W publikacji [61] przedstawiono wyniki dla różnych sposobów skalowania współczynników widmowej gęstości mocy w zależności od przeprowadzonej liczby sesji treningowych.

5.6.1. Przeprowadzone badania

W celu zbadania wpływu liczby sesji pomiarowych sygnału EEG na jakość weryfikacji tożsamości porównano wartości dokładności uśrednione w zbiorze 29 osób uzyskane z wykorzystaniem różnej liczby sesji treningowych. Na rysunku 47 przedstawiono otrzymane miary jakości weryfikacji obliczone w przypadku wykorzystania 5 sesji testowych i liczby sesji treningowych zmieniających się w zakresie od 1 do 15. Zarówno zawartość tego rysunku jak i otrzymane wartości miar jakości weryfikacji tożsamości zostały już przedstawione na rysunkach 30 i 31 oraz w tabeli 8, jednak zostały również zamieszczone tutaj w celu zwiększenia czytelności tekstu.



Rysunek 47. Uśrednione miary jakości klasyfikacji i ich odchylenia standardowe otrzymane dla całego rozpatrywanego pasma sygnału EEG w zależności od liczby sesji treningowych.

Na podstawie otrzymanych dokładności weryfikacji tożsamości wyznaczono najmniejszą liczbę sesji pomiarowych sygnału EEG potrzebnych do nauki klasyfikatora, po przekroczeniu

której otrzymane dokładności nie będą ulegały znacznej poprawie. W tabeli 14 zamieszczono p-wartości otrzymane dla serii porównań pomiędzy wartościami dokładności uzyskanymi w przypadku wykorzystania różnej liczby sesji treningowych dla cech wyznaczonych z całego rozpatrywanego pasma sygnału EEG i wszystkich elektrod. Wartości dokładności uzyskano przy wykorzystaniu metody głosowania większościowego.

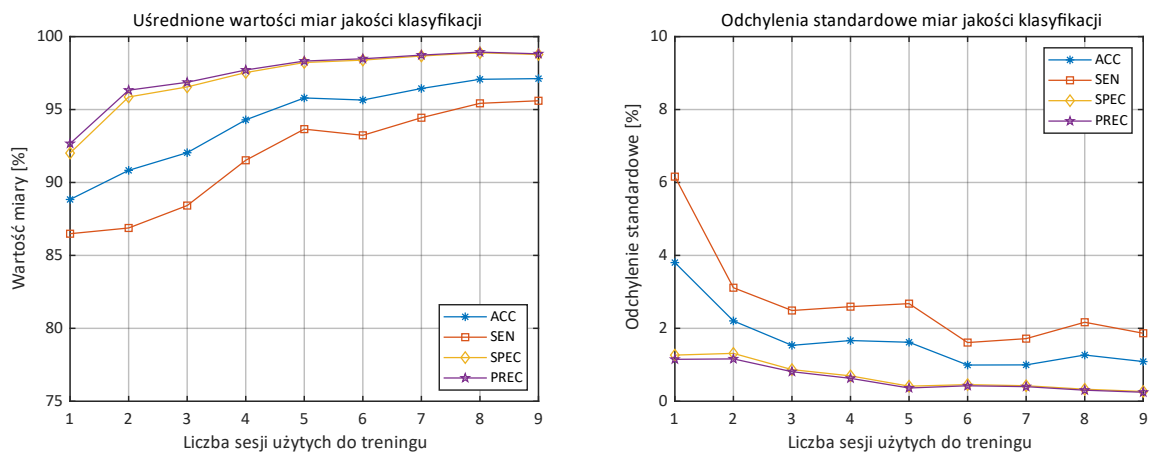
Tabela 14. p-wartości otrzymane z wykorzystaniem testu Wilcoxon dla par obserwacji pomiędzy dokładnościami uzyskanymi dla różnych liczb sesji treningowych. Na czerwono zaznaczono występowanie różnic istotnych statystycznie ($p < 0,05$), na zielono ich brak.

Liczba sesji	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0,013	0,069	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
2		0,749	0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
3			< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
4				0,069	0,026	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
5					0,077	0,004	0,004	< 0,001	0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
6						0,002	0,003	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
7							0,856	0,011	0,062	0,005	0,004	0,007	0,004	0,004
8								0,006	0,055	0,002	0,003	0,004	0,002	0,001
9									0,917	0,056	0,320	0,372	0,022	0,060
10										0,015	0,560	0,241	0,006	0,004
11											0,280	0,257	0,657	0,484
12												0,972	0,347	0,247
13													0,139	0,166
14														0,743

Analizując wyniki otrzymane w tabeli, można zauważyć, że 9 sesji treningowych było najmniejszą liczbą sesji, dla której nie wykazano wystąpień istotnych różnic w wartości dokładności w stosunku do wyników uzyskanych z wykorzystaniem 15 sesji treningowych. Chociaż uzyskano istotne statystycznie różnice pomiędzy 10 a 15 sesjami użytymi do treningu klasyfikatora, wynik ten mógł być spowodowany małymi wartościami odchyłeń standardowych uzyskanych miar jakości weryfikacji. Przy małych wariancjach różnice są łatwiej wykrywalne przez testy, a różnice pomiędzy otrzymanymi średnimi dokładnościami uzyskanymi dla obu sesji były mniejsze niż 1%. W przypadku wykorzystania 9 sesji treningowych średnia wartość dokładności wyniosła $97,4 \pm 1,3$ %, dla 10 sesji treningowych $97,2 \pm 0,9$ %, a dla 15 sesji treningowych $97,8 \pm 1,0$ %.

W celu sprawdzenia, czy po zmniejszeniu liczby sesji treningowych i zwiększeniu liczby rozdzielonych w czasie sesji testowych, otrzymane wartości miar jakości weryfikacji utrzymają się na podobnym poziomie, powtórzono badania w przypadku wykorzystania liczby sesji treningowych zmieniającej się od 1 do 9. Dla każdej osoby zarejestrowano 20 sesji pomiarowych, dlatego po zmniejszeniu maksymalnej liczby sesji pomiarowych w zbiorze treningowym do 9 sesji, możliwe było zwiększenie zbioru testowego do 11 sesji. Na rysunku 48 przedstawiono uśrednione miary jakości klasyfikacji otrzymane z wykorzystaniem 11 sesji

testowych, w zależności od liczby sesji treningowych, która zmieniała się od 1 do 9. Wyniki liczbowe zostały umieszczone w tabeli 15.



Rysunek 48. Średnione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu 19 elektrod.


Tabela 15. Średnione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu 19 elektrod.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	88,8±3,8	86,5±6,2	92,0±1,3	92,7±1,2	8,0±1,3	13,5±6,2
2	90,8±2,2	86,9±3,1	95,9±1,3	96,3±1,2	4,1±1,3	13,1±3,1
3	92,0±1,5	88,4±2,5	96,5±0,9	96,9±0,8	3,5±0,9	11,6±2,5
4	94,3±1,7	91,5±2,6	97,5±0,7	97,7±0,6	2,5±0,7	8,5±2,6
5	95,8±1,6	93,7±2,7	98,2±0,4	98,3±0,4	1,8±0,4	6,3±2,7
6	95,7±1,0	93,2±1,6	98,4±0,5	98,5±0,4	1,6±0,5	6,8±1,6
7	96,4±1,0	94,4±1,7	98,7±0,4	98,7±0,4	1,3±0,4	5,6±1,7
8	97,1±1,3	95,4±2,2	98,9±0,3	98,9±0,3	1,1±0,3	4,6±2,2
9	97,1±1,1	95,6±1,9	98,8±0,3	98,8±0,2	1,2±0,3	4,4±1,9

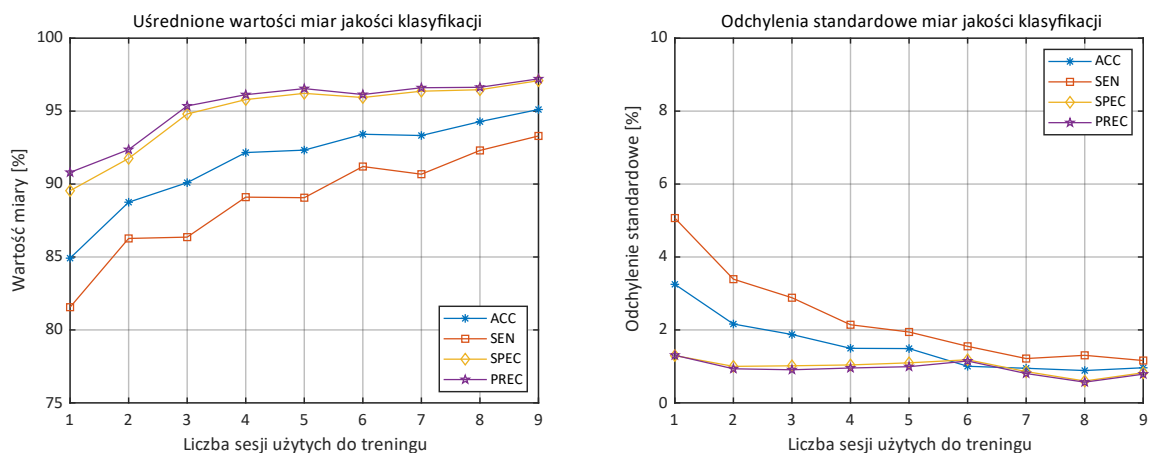
W celu sprawdzenia czy zwiększenie liczby sesji testowych spowoduje wystąpienie istotnych różnic statystycznych pomiędzy dokładnościami weryfikacji tożsamości przeprowadzono test Wilcoxa dla par obserwacji. Test ten nie wykazał występowania istotnych różnic statystycznych ($p = 0,347$) pomiędzy dokładnościami uzyskanymi z wykorzystaniem 9 sesji treningowych oraz 5 i 11 sesji testowych. Oznacza to, że zaproponowany model weryfikacji tożsamości dla danej liczby sesji treningowych poprawnie rozpoznaje przypisane do siebie osoby, również po zwiększeniu liczby sesji testowych. Świadczyć to może o stabilności zaproponowanych cech i sposobu ich przetwarzania. W stosunku do 15 sesji treningowych i 5 sesji testowych średnia wartość dokładności w przypadku wykorzystania 9 sesji treningowych i 11 sesji testowych obniżyła się

z $97,8 \pm 1,0$ % do $97,1 \pm 1,1$ %, a mediany z 97,1 % do 96,4 %. Zarówno w przypadku wartości średnich, jak i median, różnice te są mniejsze niż 1 %.

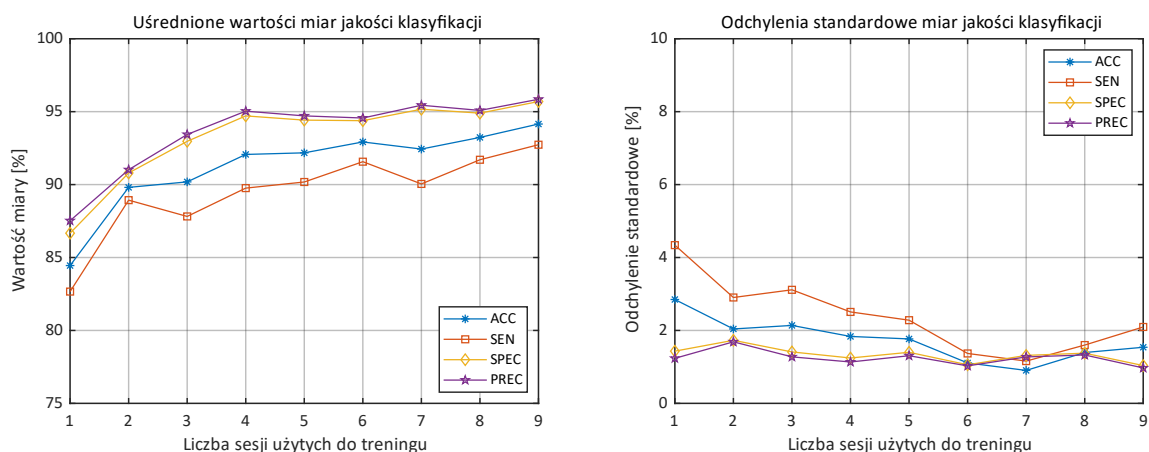
W przypadku wykorzystania 11 sesji testowych i maksymalnie 9 sesji treningowych przeprowadzono analizy dla wybranych w poprzednich punktach zestawów podpasów widma sygnału EEG i elektrod. Na rysunku 49 przedstawiono uśrednione miary jakości weryfikacji otrzymane z wykorzystaniem podpasów odpowiadających rytmom $\alpha+\beta$ oraz wszystkich elektrod używanych do akwizycji sygnału EEG. Na rysunku 50 pokazano uśrednione miary jakości klasyfikacji uzyskane z użyciem całego rozpatrywanego pasma sygnału EEG i sygnałów zarejestrowanych z zestawu ośmiu elektrod C3C4P3P4O1O2T5T6, dobranych w punkcie 5.5, a na rysunku 51 dla podpasma $\alpha+\beta$ i sygnałów zarejestrowanych z zestawu ośmiu elektrod C3C4P3P4O1O2T5T6. Wyniki liczbowe dla przedstawionych rysunków zostały pokazane odpowiednio w tabelach 16-18. W Dodatku C umieszczono odpowiedniki rysunków 48-51 i tabel 16-18 w przypadku wykorzystania 5 sesji testowych i liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Część umieszczonych w dodatku wyników jest nadmiarowa – ma to na celu zebranie otrzymanych rezultatów w jednym miejscu, żeby ułatwić czytelnikowi ich analizę.



Rysunek 49. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla podpasów odpowiadających rytmom $\alpha+\beta$ i zestawu 19 elektrod.



Rysunek 50. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.



Rysunek 51. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla podpasem odpowiadających rytmom $\alpha+\beta$ i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.

Tabela 16. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla podpasem odpowiadających rytmom $\alpha+\beta$ i zestawu 19 elektrod.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	88,9±3,9	87,4±5,7	90,7±2,1	91,2±1,7	9,3±2,1	12,6±5,7
2	92,5±1,9	91,0±2,8	94,3±1,7	94,5±1,6	5,7±1,7	9,0±2,8
3	90,5±2,7	86,2±4,0	96,3±1,3	96,7±1,2	3,7±1,3	13,8±4,0
4	93,9±1,4	91,3±2,4	97,1±0,8	97,3±0,8	2,9±0,8	8,7±2,4
5	95,6±1,8	93,9±2,9	97,6±0,6	97,7±0,6	2,4±0,6	6,1±2,9
6	95,4±1,2	93,3±1,8	97,8±0,8	97,9±0,8	2,2±0,8	6,7±1,8
7	95,8±1,2	93,7±1,9	98,1±0,6	98,2±0,6	1,9±0,6	6,3±1,9
8	96,0±1,3	94,3±2,0	97,9±0,7	98,0±0,6	2,1±0,7	5,7±2,0
9	96,6±1,0	95,2±1,6	98,0±0,4	98,1±0,4	2,0±0,4	4,8±1,6

Tabela 17. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	84,9±3,3	81,6±5,1	89,5±1,3	90,8±1,3	10,5±1,3	18,4±5,1
2	88,8±2,2	86,3±3,4	91,8±1,0	92,4±0,9	8,2±1,0	13,7±3,4
3	90,1±1,9	86,4±2,9	94,8±1,0	95,4±0,9	5,2±1,0	13,6±2,9
4	92,2±1,5	89,1±2,1	95,8±1,0	96,1±1,0	4,2±1,0	10,9±2,1
5	92,3±1,5	89,1±1,9	96,2±1,1	96,5±1,0	3,8±1,1	10,9±1,9
6	93,4±1,0	91,2±1,6	95,9±1,2	96,1±1,1	4,1±1,2	8,8±1,6
7	93,3±0,9	90,7±1,2	96,4±0,9	96,6±0,8	3,6±0,9	9,3±1,2
8	94,3±0,9	92,3±1,3	96,5±0,6	96,6±0,6	3,5±0,6	7,7±1,3
9	95,1±1,0	93,3±1,2	97,1±0,8	97,2±0,8	2,9±0,8	6,7±1,2

Tabela 18. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	84,4±2,8	82,7±4,3	86,7±1,4	87,5±1,2	13,3±1,4	17,3±4,3
2	89,8±2,0	88,9±2,9	90,8±1,7	91,0±1,7	9,2±1,7	11,1±2,9
3	90,2±2,1	87,8±3,1	93,0±1,4	93,4±1,3	7,0±1,4	12,2±3,1
4	92,1±1,8	89,8±2,5	94,7±1,2	95,0±1,1	5,3±1,2	10,2±2,5
5	92,2±1,8	90,2±2,3	94,4±1,4	94,7±1,3	5,6±1,4	9,8±2,3
6	92,9±1,1	91,6±1,4	94,4±1,1	94,6±1,0	5,6±1,1	8,4±1,4
7	92,4±0,9	90,0±1,2	95,2±1,3	95,4±1,3	4,8±1,3	10,0±1,2
8	93,2±1,4	91,7±1,6	94,9±1,4	95,1±1,3	5,1±1,4	8,3±1,6
9	94,2±1,5	92,7±2,1	95,7±1,0	95,8±1,0	4,3±1,0	7,3±2,1

Analizując otrzymane wyniki można zauważyć, że zmniejszanie liczby cech oraz liczby sesji treningowych powodowało, że uzyskane średnie wartości miar jakości weryfikacji stopniowo malały. W tabelach 19-21 zestawiono wartości średnich dokładności (ACC) i median oraz liczb cech uzyskanych dla rozpatrywanych przypadków, tj. w przypadku wykorzystania 15 sesji treningowych i 5 sesji testowych (tabela 19), 9 sesji treningowych i 5 testowych (tabela 20) oraz 9 sesji treningowych i 11 testowych (tabela 21). Wyniki przedstawiono w zależności od wykorzystywanych podpasm oraz elektrod. Oprócz średnich dokładności i median, pokazano również wyniki dotyczące liczby cech w pojedynczym wektorze cech oraz liczb wektorów cech użytych do treningu i testowania klasyfikatora.

Tabela 19. Wpływ zestawu parametrów na otrzymane wyniki. Wyniki dla 5 sesji testowych i 15 sesji treningowych.

Zestaw parametrów [podpasma, liczba elektrod]	Liczba cech w pojedynczym wektorze	Liczba wektorów użytych do treningu klasyfikatora	Liczba wektorów użytych do testowania klasyfikatora	Średnia ACC ± odch. stand. [%]	Mediana ACC [%]
całe pasmo, 19	855	720	240	97,8±1,0	97,10
α+β, 19	437	720	240	97,4±1,5	96,42
całe pasmo, 8	360	720	240	96,0±1,1	95,33
α+β, 8	184	720	240	95,3±1,3	94,54

Tabela 20. Wpływ zestawu parametrów na otrzymane wyniki. Wyniki dla 5 sesji testowych i 9 sesji treningowych.

Zestaw parametrów [podpasma, liczba elektrod]	Liczba cech w pojedynczym wektorze	Liczba wektorów użytych do treningu klasyfikatora	Liczba wektorów użytych do testowania klasyfikatora	Średnia ACC ± odch. stand. [%]	Mediana ACC [%]
całe pasmo, 19	855	432	240	97,4±1,3	96,67
α+β, 19	437	432	240	97,0±1,6	96,04
całe pasmo, 8	360	432	240	95,3±0,9	94,98
α+β, 8	184	432	240	95,2±1,8	94,17

Tabela 21. Wpływ zestawu parametrów na otrzymane wyniki. Wyniki dla 11 sesji testowych i 9 sesji treningowych.

Zestaw parametrów [podpasma, liczba elektrod]	Liczba cech w pojedynczym wektorze	Liczba wektorów użytych do treningu klasyfikatora	Liczba wektorów użytych do testowania klasyfikatora	Średnia ACC ± odch. stand. [%]	Mediana ACC [%]
całe pasmo, 19	855	432	528	97,1±1,1	96,40
α+β, 19	437	432	528	96,6±1,0	96,17
całe pasmo, 8	360	432	528	95,1±1,0	94,61
α+β, 8	184	432	528	94,2±1,5	93,31

W przypadku wykorzystania 15 sesji treningowych i 5 sesji testowych dla całego rozpatrywanego pasma sygnału EEG i 19 elektrod otrzymano dokładność na poziomie $97,8 \pm 1,0$ % oraz medianę równą 97,10 %. Po zmniejszeniu liczby sesji użytych do treningu z 15 do 9 i zwiększeniu liczby sesji testowych do 11 (rysunek 48, tabela 21) wynik ten obniżył się do wartości średniej $97,1 \pm 1,1$ % oraz mediany wynoszącej 96,40 %. Zmniejszenie liczby przykładów, którymi trenowano pojedynczą sieć neuronową z 720 (2 x 15 x 24) do 432 (2 x 9 x 24) spowodowało zmniejszenie średniej wartości dokładności o niecały 1 %. Na uwagę zasługuje fakt, że jednocześnie liczba przykładów testowych wzrosła ponad dwukrotnie z 240 (2 x 5 x 24) do 528 (2 x 11 x 24).

Redukcja liczby podpasem sygnału do α+β (z 45 do 23 cech dla każdej z elektrod) spowodowała zmniejszenie dokładności do $96,6 \pm 1,0$ % i jej mediany do 96,17 %. Oznacza to,

że dla zmniejszonej liczby przykładów treningowych, zwiększonej liczby przykładów testowych i prawie dwukrotnym zmniejszeniu rozmiaru wektora cech z 855 do 437, dokładność klasyfikacji spadła o około 1 %.

W przypadku wykorzystania 9 sesji treningowych, 11 sesji testowych i wybranego zestawu ośmiu elektrod, średnia dokładność zmalała do $95,1 \pm 1,0$ %, a mediana zmniejszyła się do 94,61 %. Ograniczenie liczby podpasm do podpasm odpowiadających rytmom $\alpha+\beta$ spowodowało zmniejszenie średniej dokładności weryfikacji tożsamości do $94,2 \pm 1,5$ % oraz jej mediany do 93,31 %.

W publikacji [60], której główną współautorką była autorka niniejszej rozprawy, porównywane były średnie dokładności weryfikacji tożsamości, jednak bez wykorzystania głosowania większościowego. W publikacji tej wykazano, że po przeprowadzeniu 8 sesji treningowych nie następuje już istotny statystycznie wzrost średniej dokładności weryfikacji tożsamości. Wynik ten odbiega od tego przedstawionego w rozprawie, czyli że potrzebne jest przeprowadzenie przynajmniej 9 sesji treningowych. Różnica ta spowodowana jest tym, że w rozprawie zaprezentowano sposób klasyfikacji wektorów cech za pomocą głosowania większościowego klasyfikatorów, które znacząco poprawiło jakość weryfikacji tożsamości oraz znacznie obniżyło jej wariancję. Poprawa dokładności była na tyle duża, że dla 19 elektrod uzyskana w rozprawie średnia dokładność weryfikacji tożsamości otrzymana dla całego pasma sygnału EEG z wykorzystaniem 9 sesji treningowych i 11 sesji testowych ($97,1 \pm 1,1$ %) okazała się wyższa, niż średnia dokładność weryfikacji tożsamości otrzymana w artykule z wykorzystaniem 15 sesji treningowych i 5 testowych ($96,7 \pm 4,2$ %).

5.6.2. Wnioski

W powyższym punkcie zbadano wpływ liczby sesji treningowych na jakość weryfikacji tożsamości. Analiza statystyczna przeprowadzona dla wyników uzyskanych z wykorzystaniem 5 sesji testowych wykazała brak istotnych różnic w otrzymanych dokładnościach pomiędzy użyciem 9 i 15 sesji treningowych. W wyniku przeprowadzonych analiz, do dalszych badań zdecydowano się przyjąć minimalną liczbę sesji treningowych równą 9. W przypadku wykorzystania tej liczby sesji treningowych i 11 sesji testowych zbadano wpływ ograniczenia liczby podpasm i liczby elektrod. Przy wykorzystaniu 9 sesji treningowych nie znaleziono istotnych różnic statystycznych pomiędzy dokładnością obliczoną na podstawie klasyfikacji cech pochodzących z 5 i 11 sesji testowych.

W porównaniu do najlepszych, referencyjnych wyników osiągniętych dla cech pochodzących z 19 elektrod, całego rozpatrywanego pasma sygnału EEG, 5 sesji testowych

i 15 sesji treningowych uzyskano wartość średnią dokładności niższą o około 3,6 % dla wybranego zestawu 8 elektrod, podpasma $\alpha+\beta$, 9 sesji treningowych 11 sesji testowych. Jednocześnie liczba przykładów użytych do treningu klasyfikatora zmniejszyła się z 720 do 432, a liczba przykładów do jego testowania wrosła ponad dwukrotnie z 240 do 528, co umożliwiło jego rzetelną ocenę. Dodatkowo liczba cech w pojedynczym wektorze podawanym na wejście klasyfikatora zmalała z 855 do 184. Otrzymane wyniki oznaczają, że możliwe jest określenie minimalnej liczby sesji pomiarowych sygnału EEG używanych w procesie uczenia klasyfikatora w celu skrócenia procesu przygotowywania systemu do użycia w praktyce.

5.7. Atak intruzów

W tej części rozprawy przetestowano podatność zaproponowanej metody weryfikacji tożsamości osób na atak intruzów. W tym celu wykorzystano zbiór 23 dodatkowych rejestracji sygnału EEG pochodzący od osób, które wcześniej nie były uwzględniane w treningach klasyfikatorów. Badania miały na celu sprawdzenie czy osoby, z którymi klasyfikatory nie miały wcześniej styczności, zostaną prawidłowo zaklasyfikowane jako intruzi. Wyniki podobnych badań zostały przedstawione w dwóch publikacjach [59], [60], których główną autorką była autorka niniejszej rozprawy.

5.7.1. Przeprowadzone badania

Przedstawione w niniejszym punkcie analizy przeprowadzono w przypadku wykorzystania liczby sesji treningowych klasyfikatorów zmieniającej się w zakresie od 1 do 15. Dla każdej liczby sesji treningowych, dla każdej weryfikowanej osoby, dla której utworzono klasyfikator zasymulowano 552 ataki (po 24 ataki od każdego z 23 intruzów), co w sumie dało 16008 ataków (klasyfikatory utworzone dla 29 zarejestrowanych osób zostały zaatakowane po 552 razy). W tabeli 22 przedstawiono współczynnik fałszywych akceptacji (FAR) uzyskany dla zasymulowanego ataku intruzów w zależności od liczby sesji treningowych i zestawu parametrów.

Najniższą liczbę fałszywie pozytywnie zweryfikowanych intruzów z wykorzystaniem 15 sesji treningowych otrzymano dla przypadku, w którym analizowano całe rozpatrywane pasmo sygnału EEG oraz zestaw 19 elektrod ($2,1 \pm 2,1$ %). Wraz z malejącą liczbą podawanych na wejście klasyfikatora cech, rosła wartość współczynnika fałszywych akceptacji. Drugi najniższy wynik z wykorzystaniem 15 sesji treningowych uzyskano dla zestawu 19 elektrod i podpasma $\alpha+\beta$ ($3,8 \pm 3,8$ %), trzeci dla zestawu całego pasma sygnału EEG i zestawu ośmiu

elektrod C3C4P3P4O1O2T5T6 ($5,3 \pm 4,2$ %). Najwyższe wartości współczynnika fałszywych akceptacji z wykorzystaniem 15 sesji treningowych uzyskano dla podpasma $\alpha+\beta$ i zestawu ośmiu elektrod ($7,5 \pm 5,2$ %). Analizując uzyskane wyniki, można zauważyć, że dla niektórych liczb wykorzystanych sesji treningowych (np. dla 14) otrzymane wartości współczynnika fałszywych akceptacji były nieznacznie mniejsze, niż w przypadku użycia 15 sesji treningowych. Można zauważyć, że w przypadku wszystkich rozpatrywanych zestawów parametrów już przy wykorzystaniu 7 sesji treningowych otrzymane wartości współczynnika fałszywych akceptacji różniły się o mniej niż 1 % w stosunku do wartości współczynnika fałszywych akceptacji otrzymanego z wykorzystaniem 15 sesji treningowych.

Tabela 22. Wartości współczynnika fałszywych akceptacji (FAR) otrzymane dla symulacji ataku intruzów dla wszystkich elektrod i podpasm w zależności od liczby sesji z wykorzystaniem głosowania większościowego.

Liczba sesji	FAR [%]			
	całe pasmo, wszystkie elektrody	podpasma $\alpha+\beta$, wszystkie elektrody	całe pasmo, elektrody C3C4P3P4O1O2T5T6	podpasma $\alpha+\beta$, elektrody C3C4P3P4O1O2T5T6
1	6,8±5,1	9,8±6,0	10,8±7,5	14,2±7,5
2	4,5±3,9	6,4±5,3	6,9±4,3	10,4±5,9
3	4,6±3,4	5,8±4,0	6,6±4,1	8,4±4,7
4	3,3±2,8	4,7±3,7	5,7±2,8	7,7±3,8
5	2,7±2,6	4,5±3,3	6,1±3,3	7,6±3,6
6	2,9±3,1	5,0±3,8	5,6±2,9	7,9±3,8
7	2,7±2,1	4,2±2,8	5,6±3,3	7,6±4,2
8	2,6±2,8	4,0±3,3	5,3±3,4	7,0±3,8
9	2,4±2,5	4,4±3,8	5,2±3,1	7,2±4,5
10	2,4±2,4	3,6±3,3	5,8±4,2	7,2±4,9
11	2,2±2,7	3,4±3,1	5,3±4,0	6,9±5,1
12	2,6±2,8	4,0±3,6	5,3±3,9	7,6±5,2
13	2,2±2,2	3,8±3,3	5,2±3,8	7,2±4,9
14	2,0±2,4	3,6±3,4	5,2±3,6	6,9±4,7
15	2,1±2,1	3,8±3,8	5,3±4,2	7,5±5,2

Dla porównania w tabeli 23 przedstawiono wartości współczynnika fałszywych akceptacji otrzymane dla symulowanego ataku intruzów przedstawione w artykule [60]. Wyniki te zostały otrzymane z wykorzystaniem cech podpasm widma sygnału EEG będących współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej dla 19 elektrod i całego rozpatrywanego pasma sygnału EEG. W porównaniu do badań prowadzonych w tym punkcie zostały one otrzymane bez użycia głosowania większościowego. Zaproponowany w rozprawie model weryfikacji tożsamości osób oparty o cechy będące współczynnikami widma gęstości

mocy wyrażonymi w skali decybelowej i głosowanie większościowe sztucznych sieci neuronowych osiągnęły niższe wartości współczynnika fałszywych akceptacji i jego odchylenia standardowe, niż model bez głosowania większościowego.

Tabela 23. Wyniki FAR uzyskane z wykorzystaniem cech podpasm widma sygnału EEG będących współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej uzyskane bez głosowania większościowego dla symulowanego ataku intruzów w zależności od liczby sesji treningowych.
Źródło: [60].

Session No.	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
FAR	13.9	8.5	7.1	6.3	5.3	4.4	4.6	4.4	3.9	3.9	3.7	3.5	3.5	3.6	3.1
[% ± SD]	±7.0	±4.6	±4.7	±3.7	±3.4	±3.3	±3.3	±2.5	±3.1	±2.7	±2.7	±2.8	±2.9	±3.1	±2.2

5.7.2. Wnioski

W niniejszym punkcie przedstawiono wyniki dotyczące symulowanego ataku intruzów na rozpatrywane modele weryfikacji tożsamości osób. Wraz ze wzrostem liczby sesji treningowych wykorzystywanych do uczenia sztucznych sieci neuronowych, wartość współczynnika fałszywych akceptacji malała. Najniższe wyniki uzyskano dla całego analizowanego zakresu pasma sygnału EEG oraz dla wszystkich elektrod ($2,1 \pm 2,1$ %), jednak zauważono, że już po 7 sesjach treningowych wyniki te stabilizują się i nie zmieniają w zakresie większym niż 1 %. Zmniejszenie liczby elektrod do zestawu ośmiu elektrod C3C4P3P4O1O2T5T6 oraz ograniczenie analizowanego pasma sygnału EEG do podpasm odpowiadających rytmom $\alpha+\beta$ spowodowało wzrost wartości współczynnika fałszywych akceptacji do $7,5 \pm 5,2$ %.

5.8. Sparametryzowane cechy podpasm widma sygnału EEG


W końcowej części rozprawy przedstawiono wyniki uzyskane dla sparametryzowanych cech podpasm widma sygnału EEG, zaproponowanych w punkcie 4.3. Analizowane segmenty sygnału EEG były normalizowane w zakresie od -1 do 1, a następnie cechy były wyznaczane na podstawie sparametryzowanych współczynników gęstości widmowej mocy obliczonych z wykorzystaniem wzorów (10)-(12). Wyniki badań z wykorzystaniem między innymi tych cech przedstawiono w publikacjach [58], [59], [62], [63], których główną autorką była autorka niniejszej rozprawy. W tych badaniach analizowano wpływ podziału danych na zbiory treningowe i testowe [58], [59] oraz wpływ doboru elektrod [62], [63] na jakość weryfikacji tożsamości osób. Najważniejszymi czynnikami, które odróżniają badania przedstawione w rozprawie od opisanych w publikacjach są obliczenie sparametryzowanych cech

dla współczynników gęstości widmowej mocy wyrażonych w skali decybelowej oraz wykorzystanie metod uczenia zespołowego w postaci głosowania większościowego.



5.8.1. Przeprowadzone badania

W niniejszym punkcie przeprowadzono analizy dla sparametryzowanych cech podpasm widma sygnału EEG. Badania zostały przeprowadzone w celu porównania z wynikami uzyskanymi dla cech będących współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej. Na rysunkach 52-55 przedstawiono wyniki uśrednione w zbiorze 29 weryfikowanych osób uzyskane z wykorzystaniem 15 sesji treningowych i 5 sesji testowych, kolejno dla całego pasma sygnału EEG oraz podpasm odpowiadających rytmom $\alpha+\beta$. Przedstawione wyniki otrzymano z wykorzystaniem wszystkich 19 elektrod używanych do akwizycji sygnału EEG oraz dla zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.



W Dodatku C przedstawiono odpowiedniki przedstawionych w tym punkcie wyników otrzymane z wykorzystaniem cech będących współczynnikami widmowej gęstości mocy wyrażonymi w skali decybelowej. W Dodatku D znajduje się liczbowe przedstawienie otrzymanych w tym punkcie wyników w postaci tabel.





Rysunek 52. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu 19 elektrod.



Rysunek 53. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu 19 elektrod.



Rysunek 54. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.





Rysunek 55. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.



Zgodnie z przewidywaniami najwyższe miary jakości weryfikacji tożsamości osób osiągnięto dla całego pasma sygnału EEG i wszystkich elektrod używanych do akwizycji tego sygnału. Wyniki odpowiadające powyższym rysunkom otrzymane z wykorzystaniem przedstawionych w poprzednich punktach cech będących współczynnikami widmowej gęstości mocy wyrażonymi w skali decybelowej zostały przedstawione w Dodatku C.

Na przedstawionych powyżej rysunkach można zauważyć, że zarówno średnie wartości swoistości, jak i precyzji wraz ze zwiększaniem się liczby sesji treningowych dosyć szybko osiągały wartość, wokół której wahały się nieznacznie i nie ulegały już wyraźnej poprawie bądź pogorszeniu. W porównaniu do tych miar jakości weryfikacji, czułość wraz ze wzrostem liczby sesji treningowych niemal cały czas ulegała widocznej poprawie. Przedstawione wyniki dla sparametryzowanych cech podpasm widma sygnału EEG okazały się niższe niż dla cech będących współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej. Z drugiej strony zastosowanie sparametryzowanych cech podpasm widma sygnału EEG umożliwiło znaczące zmniejszenie liczby cech podawanych na wejście sztucznej sieci neuronowej. W przypadku wykorzystania całego rozpatrywanego pasma sygnału EEG i wszystkich elektrod średnia wartość dokładności w przypadku wykorzystania 15 sesji treningowych i 5 sesji testowych spadła z $97,8 \pm 1,0$ % do $96,6 \pm 1,5$ %. Jednocześnie rozmiar pojedynczego wektora cech zmniejszył się z 855 do 285. Dla podpasm odpowiadających rytmom $\alpha+\beta$ wartość ta zmieniła się z $97,4 \pm 1,5$ % do $95,6 \pm 2,0$ %. Jednocześnie rozmiar wektora cech zmalał z 437 do 114. Po zredukowaniu liczby elektrod do akwizycji sygnału EEG do zestawu ośmiu elektrod C3C4P3P4O1O2T5T6 i całego rozpatrywanego pasma nastąpił spadek średniej wartości dokładności z $96,0 \pm 1,1$ % do $93,0$ % przy odchyleniu standardowym równym $1,5$ % i zredukowanie rozmiaru wektora cech z 360 do 120. Dla podpasm odpowiadających rytmom $\alpha+\beta$ nastąpił spadek z $95,3 \pm 1,3$ % do $91,3 \pm 2,2$ % i zmniejszenie rozmiaru wektora cech z 184 do 48.



Na rysunkach 56-59 przedstawiono wyniki uzyskane po zmniejszeniu liczby sesji treningowych do maksymalnie 9 i zwiększeniu liczby sesji testowych do 11, podobnie jak w punkcie 5.5.1. Analogiczne wyniki dla cech będących współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej znajdują się na rysunkach 48-51 i w tabelach 15-18.




Rysunek 56. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu 19 elektrod.



Rysunek 57. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu 19 elektrod.



Rysunek 58. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.



Rysunek 59. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla podpasem odpowiadających rytmom $\alpha+\beta$ i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.

Wyniki uzyskane z wykorzystaniem sparametryzowanych cech podpasem widma sygnału EEG są gorsze niż odpowiadające im wyniki uzyskane dla współczynników gęstości widmowej mocy wyrażonych w skali decybelowej. We wszystkich przypadkach wraz ze wzrostem liczby sesji treningowych poprawiały się miary jakości weryfikacji tożsamości. Największe różnice pomiędzy wykorzystaniem 1 a 9 sesji można zaobserwować w średnich wartościach czułości i dokładności. Już po kilku sesjach treningowych wartości precyzji i swoistości osiągały poziom, wokół którego wahały się nieznacznie niezależnie od dalszego zwiększania liczby sesji treningowych.

Ostatnią analizą wykonaną z wykorzystaniem sparametryzowanych cech podpasem widma sygnału EEG było zasymulowanie ataku intruzów, podobnie jak w punkcie 5.7. Wyniki przedstawiono w tabeli 24. Najniższą wartość współczynnika fałszywych akceptacji (FAR) uzyskano dla zestawu składającego się z cech odpowiadającym całemu pasmu sygnału EEG i z wykorzystaniem wszystkich 19 elektrod do akwizycji sygnału EEG. Wraz ze zmniejszaniem się liczby cech podawanych na wejście sztucznej sieci neuronowej, liczba fałszywie pozytywnie zweryfikowanych intruzów rosła. W porównaniu do wyników przedstawionych w tabeli 22, w której współczynniki fałszywych akceptacji otrzymane z wykorzystaniem cech będących wartościami współczynników widmowej gęstości mocy wyrażonymi w skali decybelowej otrzymano gorsze wyniki, tj. są wyższe i mają większe odchylenia standardowe.

Tabela 24. Wartości FAR otrzymane dla symulacji ataku intruzów dla wszystkich rozpatrywanych zestawów elektrod i podpasm sygnału EEG w zależności od liczby sesji z wykorzystaniem głosowania większościowego.

Liczba sesji	FAR [%]			
	całe pasmo, wszystkie elektrody	podpasmo $\alpha+\beta$, wszystkie elektrody	całe pasmo, elektrody C3C4P3P4O1O2T5T6	podpasmo $\alpha+\beta$, elektrody C3C4P3P4O1O2T5T6
1	6,5±4,3	12,1±8,9	12,8±7,7	18,6±10,5
2	5,8±4,0	11,2±7,1	10,2±5,5	15,7±8,4
3	4,6±3,6	8,3±4,8	9,1±4,5	13,7±6,8
4	5,2±4,0	8,7±5,7	9,2±4,9	13,3±6,6
5	5,6±4,0	8,6±5,0	9,1±4,5	13,2±7,0
6	5,3±3,6	7,8±5,7	9,1±5,3	12,2±6,3
7	4,4±3,5	6,6±4,6	8,0±5,5	11,9±7,1
8	4,5±3,6	6,7±4,7	8,3±5,2	12,0±5,7
9	3,8±3,1	5,8±4,8	8,1±5,5	11,8±6,5
10	4,4±3,6	6,4±4,7	8,0±4,9	11,9±6,5
11	4,0±3,3	6,0±5,1	8,0±5,7	12,7±7,9
12	4,4±3,0	6,6±4,5	8,0±5,4	11,8±7,1
13	3,8±2,8	6,3±5,0	7,9±5,6	11,4±6,7
14	4,0±3,1	6,2±4,8	8,0±5,5	12,4±6,9
15	3,9±2,7	6,4±4,3	7,9±5,0	12,5±7,3

5.8.2. Wnioski

W niniejszym punkcie przedstawiono wyniki uzyskane dla sparametryzowanych cech podpasm widma sygnału EEG. Analizy wykonano dla wybranych w poprzednich punktach zestawów parametrów. W porównaniu do wartości otrzymanych dla cech będących współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej, miary jakości weryfikacji otrzymane w tym punkcie okazały się gorsze, przykładowo w przypadku wykorzystania 15 sesji treningowych, 5 testowych, 19 elektrod i całego rozpatrywanego pasma sygnału EEG dokładność zmalała z $97,8 \pm 1,0$ % do $96,6 \pm 1,5$ %. Z drugiej strony znacznie zmalała liczba cech podawanych na wejście sztucznej sieci neuronowej z 855 do 285.

Mimo otrzymania niższych wartości miar jakości weryfikacji, zaproponowane sparametryzowane cechy podpasm widma sygnału EEG mogą okazać się użyteczne w zastosowaniach, w których ważniejsze od wysokiego wyniku weryfikacji tożsamości jest ograniczenie liczby cech podawanych na wejście klasyfikatora, a tym samym skrócenie jego czasu trenowania oraz odpowiedzi. Rozwiązania takie można zastosować na przykład jako funkcję coraz popularniejszych gier komputerowych, dostosowujących swoją treść do stanu

emocjonalnego użytkownika, np. gry horrorowe. Gdyby stan gracza, przykładowo jego poziom stresu w tego typu grze był określany na podstawie sygnału EEG, taki system weryfikacji tożsamości, wykorzystujący zmniejszony rozmiar wektora cech, mógłby przy okazji w tle gry bez większego wpływu na jakość rozgrywki z powodzeniem potwierdzać, że osobą grającą jest osoba, do której należy profil gracza.

6. Podsumowanie i wnioski końcowe

6.1. Podsumowanie przeprowadzonych badań

Zgodnie z celem badań przedstawionych w rozprawie opracowano nowe rozwiązania zwiększające jakość weryfikacji tożsamości osób na podstawie analizy widmowej sygnału EEG z wykorzystaniem metod uczenia maszynowego. Zastosowane metody zapewniają niezależność wyników weryfikacji tożsamości od dziennych lub długookresowych zmian w sygnale EEG i uzyskanie wysokich miar oceny jakości klasyfikacji, w szczególności dokładności i swoistości. W rozprawie dokładność była interpretowana jako stosunek prawidłowo zaklasyfikowanych odpowiedzi klasyfikatora do wszystkich podjętych prób przeprowadzenia weryfikacji, a swoistość jako stosunek prawidłowych odrzuceń ataków intruzów do wszystkich ataków intruzów poddawanych weryfikacji.

Ocenę opracowanych metod przeprowadzono na obszernym zbiorze rejestracji sygnałów EEG, które zostały skompletowane przez autorkę we współpracy z zespołem z Instytutu Biologii Doświadczalnej PAN im. Marcelego Nenckiego w Warszawie. Zbiór rejestracji sygnałów EEG składał się z 20 rozdzielonych w czasie sesji dla każdej z badanych 29 osób oraz pojedynczych sesji od dodatkowych 23 osób. W sumie zawierał 603 rejestracje. Zbiór ten posłużył do wyboru najlepszych rozwiązań i do potwierdzenia założeń samej metody, w tym zbadania stałości cech biometrycznych w czasie.

Opracowane w rozprawie metody weryfikacji tożsamości osób opierają się na wykorzystaniu cech spektralnych sygnału EEG, w szczególności współczynników gęstości widmowej mocy wyrażonych w skali decybelowej i ich klasyfikacji za pomocą głosowania większościowego z użyciem jednokierunkowych sztucznych sieci neuronowych. W początkowej fazie badań przeanalizowano sposób podziału danych na zbiory treningowe i testowe. Na tej podstawie zdecydowano o przeprowadzeniu dalszych analiz w oparciu o niezależne zbiory treningowe i testowe, tj. rozłączne w czasie.

Przeanalizowano wpływ skalowania współczynników widmowej gęstości mocy, podawanych na wejście klasyfikatora, na miary oceny jakości weryfikacji tożsamości. Na tej podstawie zaproponowano wyrażenie współczynników gęstości widmowej mocy w skali decybelowej co wpłynęło znacząco na poprawę miar oceny jakości klasyfikacji. Przykładowo w porównaniu do nieskalowanych współczynników widmowej gęstości mocy całego pasma sygnału EEG średnia wartość dokładności w przypadku wykorzystania 15 sesji treningowych, 5 sesji testowych i 19 elektrod wzrosła z 92,4 % przy odchyleniu standardowym równym 5,8 % do 96,6 % przy odchyleniu standardowym równym 4,2 %.

Po analizie wpływu na jakość weryfikacji tożsamości wybranych klasyfikatorów, jakimi były drzewa decyzyjne, lasy losowe, metoda k-najbliższych sąsiadów, maszyna wektorów nośnych oraz sztuczna sieć neuronowa, zdecydowano o przeprowadzeniu dalszych badań z udziałem sztucznych sieci neuronowych, jednak w przyszłości warto by było zweryfikować dokładniej zaproponowane metody również przy wykorzystaniu innych klasyfikatorów. W przypadku wykorzystania 15 sesji treningowych, 5 testowych i 19 elektrod, nie zauważono poprawy miar jakości klasyfikacji po zwiększeniu liczby neuronów z jednego do 20 w warstwie ukrytej sztucznej sieci neuronowej, choć wraz ze wzrostem liczby neuronów ukrytych szybko rósł czas potrzebny do nauki klasyfikatora (dla 20 neuronów ukrytych czas wzrósł ponad 500-krotnie w stosunku do jednego neuronu). Po porównaniu otrzymanych miar jakości weryfikacji tożsamości z i bez uczenia zespołowego, dalsze badania prowadzono z wykorzystaniem głosowania większościowego. Wykorzystanie głosowania większościowego w stosunku do jego braku umożliwiło wzrost średnich dokładności weryfikacji tożsamości z 96,6 % do 97,8 % oraz zmniejszenie odchyłeń standardowych z 4,2 % do 1,0 %.

Dla tak opracowanej metody, dla całego rozpatrywanego pasma widma sygnału EEG, przy zastosowaniu 19 elektrod, 15 sesji treningowych i 5 sesji testowych osiągnięto średnią wartość dokładności weryfikacji równą 97,8 % przy odchyleniu standardowym równym 1,0 % oraz średnią wartość swoistości równą 99,0 % przy odchyleniu standardowym równym 0,2 %. Dowodzi to **pierwszej tezy** postawionej w niniejszej rozprawie, że możliwe jest opracowanie metody weryfikacji tożsamości osób na podstawie analizy widmowej sygnału EEG z wykorzystaniem metod uczenia maszynowego, niezależnej od chwilowych lub dziennych zmian w sygnale EEG, która zapewniałaby uzyskanie wysokich miar oceny jakości klasyfikacji, w szczególności dokładności i swoistości.

W celu redukcji liczby danych pomiarowych, a przez to skrócenia czasu wykonywania potrzebnych obliczeń określono podpasma widma sygnału EEG umożliwiające uzyskanie wyników weryfikacji tożsamości na podobnym poziomie jak dla całego pasma widma sygnału EEG. Testy statystyczne z wykorzystaniem 15 sesji treningowych wykazały brak istotnych różnic pomiędzy dokładnością weryfikacji tożsamości otrzymaną z użyciem całego rozpatrywanego pasma sygnału EEG, a dokładnością uzyskaną jedynie z wykorzystaniem podpasem odpowiadających rytmom alfa i beta sygnału EEG ($97,4 \pm 1,5$ %). Wśród podpasem widma odpowiadającym pojedynczym rytmom sygnału EEG najwyższą dokładność otrzymano dla podpasma beta ($97,1 \pm 1,5$ %). Jest to potwierdzenie **drugiej tezy** postawionej w rozprawie, że możliwa jest redukcja liczby analizowanych podpasem widma sygnału EEG, które zapewnią

uzyskanie parametrów weryfikacji tożsamości na podobnym poziomie jak dla całego rozpatrywanego pasma sygnału EEG.

W ramach prób skrócenia czasu przygotowania weryfikowanej osoby do rejestracji sygnału EEG i zmniejszenia liczby przetwarzanych cech, zbadano wpływ doboru liczby i miejsca umieszczenia elektrod na jakość weryfikacji tożsamości osób. Analizując wartości miar jakości klasyfikacji z wykorzystaniem 15 sesji treningowych i 5 sesji testowych, zauważono, że wśród pojedynczych elektrod najlepszy wynik uzyskano dla elektrody T5, rejestrującej sygnał z tylnej okolicy płata skroniowego mózgu. Następnie przeanalizowano zestawy dwóch, czterech i ośmiu elektrod, porównując ich miary jakości weryfikacji. Dostrzeżono, że większy udział w weryfikacji tożsamości osób miały sygnały z elektrod umiejscowionych w tylnej części głowy, niż w przedniej. W wyniku przeprowadzonych analiz zaproponowano zestaw ośmiu elektrod C3C4P3P4O1O2T5T6, dla którego średnia dokładność weryfikacji tożsamości w całym paśmie widma sygnału EEG wyniosła 96,0 % przy odchyleniu standardowym równym 1,1 % i była niewiele niższa niż średnia dokładność otrzymana w przypadku wykorzystania wszystkich 19 elektrod. Oznacza to, że możliwe jest zmniejszenie liczby elektrod do akwizycji sygnału EEG oraz określenie zestawu elektrod wygodnego do zastosowania z punktu widzenia osób weryfikowanych, zapewniającego uzyskanie jakości weryfikacji na stosunkowo wysokim poziomie, co jest potwierdzeniem **trzeciej tezy** sformułowanej w rozprawie. Przeanalizowano również wpływ zawężenia pasma widma gęstości mocy do podpasem $\alpha+\beta$ dla zaproponowanego zestawu ośmiu elektrod na jakość weryfikacji tożsamości. W stosunku do 19 elektrod uzyskano spadek średniej dokładności weryfikacji o 2,1 %.

W proponowanych w rozprawie rozwiązaniach, przed przeprowadzeniem weryfikacji tożsamości niezbędne jest nauczenie sztucznych sieci neuronowych rozpoznawania danej osoby. Odbywa się to poprzez stworzenie jej biometrycznego wzorca w postaci wag połączeń między neuronami. Początkowo wykorzystywano do tego celu 15 sesji treningowych, odbywających się w różnych dniach. Zebranie tak dużej liczby pomiarów od wielu osób może jednak sprawiać problemy organizacyjne, dlatego podjęto próbę zmniejszenia liczby sesji treningowych. W rozprawie wykazano brak wystąpień istotnych statystycznie różnic w dokładności weryfikacji po zmniejszeniu liczby sesji treningowych z 15 ($97,8 \pm 1,0$ %) do 9 ($97,4 \pm 1,3$ %), przy wykorzystaniu 5 sesji testowych i 19 elektrod do akwizycji sygnału EEG. Następnie sprawdzono stabilność tego rozwiązania poprzez zwiększenie liczby sesji testowych. W przypadku wykorzystania 9 sesji treningowych po ponad dwukrotnym zwiększeniu liczby sesji testowych (z 5 do 11) otrzymano średnią dokładność równą 97,1 % przy odchyleniu standardowym równym 1,1 %. Na podstawie tych wyników stwierdzono,

że dalsze zwiększanie liczby sesji treningowych nie zapewnia znacząco lepszych wyników, co dowodzi **tezy czwartej**, czyli możliwości określenia minimalnej liczby sesji pomiarowych sygnału EEG używanych w procesie uczenia klasyfikatora w celu skrócenia procesu przygotowywania systemu do użycia w praktyce. Rozwiązanie to sprawdzono również dla całego pasma sygnału EEG i wybranego zestawu ośmiu elektrod C3C4P3P4O1O2T5T6 oraz dla zestawu podpasm $\alpha+\beta$ z pełną i zmniejszoną liczbą elektrod.

Omawiana metoda weryfikacji tożsamości, oparta na analizie widmowej sygnału EEG, okazała się również odporna na atak intruzów. Dla całego pasma sygnału EEG i 19 elektrod już po 9 sesjach treningowych średnia wartość współczynnika fałszywych akceptacji wynosiła 2,4 % przy odchyleniu standardowym równym 2,5 %, a po 15 sesjach treningowych 2,1 % przy odchyleniu standardowym 2,1 %. Badania przeprowadzono zarówno dla całego pasma sygnału EEG, jak i wszystkich oraz zmniejszonej liczby elektrod, dodatkowo pokazano wyniki analiz dla podpasm $\alpha+\beta$ z tymi samymi zestawami elektrod. Zauważono, że dla wszystkich rozpatrywanych przypadków już po 7 sesjach treningowych współczynnik fałszywych akceptacji w porównaniu do wykorzystania 15 sesji treningowych nie poprawił się o więcej niż 1 %.

Ponadto dla dobranych w rozprawie podpasm, elektrod i liczby sesji treningowych zbadano skuteczność weryfikacji tożsamości osób dla zaproponowanych sparametryzowanych cech podpasm widma sygnału EEG. Choć osiągnięte wyniki były niższe w porównaniu do wyników uzyskanych z wykorzystaniem cech będących współczynnikami gęstości widmowej mocy wyrażonymi w skali decybelowej, możliwe było zmniejszenie rozmiaru wektora cech podawanego na wejście sztucznej sieci neuronowej z 855 do 285 przy zmianie średniej wartości dokładności weryfikacji z wykorzystaniem 15 sesji treningowych z 97,8 % przy odchyleniu standardowym równym 1,0 % na 96,6 % przy odchyleniu standardowym równym 1,5 %. W przypadku zastosowania podpasm $\alpha+\beta$ średnie dokładności zmalały z 97,4 % do 95,6 % przy odchyleniach standardowych równych odpowiednio 1,5 % i 2,0 %. W tym przypadku rozmiar wektora cech zmalał z 437 do 114. Po zmniejszeniu liczby elektrod do ośmiu (C3C4P3P4O1O2T5T6) średnia dokładność po wykorzystaniu cech sparametryzowanych zmalała z 96,0 % do 93,0 % przy odchyleniach standardowych równych odpowiednio 1,1 % i 1,5 % dla całego pasma sygnału EEG, a dla podpasm $\alpha+\beta$ z 95,3 % przy odchyleniu standardowym równym 1,3 % do 91,3 % przy odchyleniu standardowym równym 2,2 %. Rozmiary pojedynczych wektorów cech po wykorzystaniu całego pasma sygnału EEG i podpasm $\alpha+\beta$ zmieniły się odpowiednio z 360 do 120 i 184 do 48. Po zmniejszeniu rozmiaru wektora cech średnia wartość współczynnika fałszywych akceptacji podczas ataku intruzów

uległa pogorszeniu i wzrosła z 2,1 % przy odchyleniu standardowym 2,1 % do 3,9 % przy odchyleniu standardowym 2,7 %.

6.2. Ograniczenia

Z powodu różnych metod akwizycji sygnału EEG i sposobów testowania proponowanych rozwiązań do weryfikacji tożsamości osób na podstawie cech zawartych w sygnale EEG, trudno w sposób jednoznaczny porównać wyniki badań zaprezentowanych w rozprawie z wynikami osiągniętymi przez inne zespoły badawcze, m.in. opisanymi w punkcie 3.4. W rozprawie zastosowano rygorystyczny sposób testowania opracowanych rozwiązań poprzez zbadanie skuteczności weryfikacji tożsamości osób z użyciem sesji pomiarowych sygnału EEG przeprowadzonych w różnych dniach. Jest to niezwykle rzadkie podejście, gdyż w dziedzinie rozpoznawania tożsamości osób na podstawie sygnału EEG brakuje badań, w których zaproponowane rozwiązania byłyby oceniane na podstawie wielu rozdzielonych w czasie sesji, niezależnych od zbioru treningowego.

Wiele rozwiązań spotykanych w innych badaniach jest tworzone na podstawie zbiorów zawierających po jednej sesji dla każdej osoby. Niektóre z przedstawionych w literaturze wyników są lepsze niż przedstawione w rozprawie. Przykładowo dla sygnału EEG rejestrowanego w czasie spoczynku z otwartymi oczyma, w innych pracach błąd zrównoważony EER, czyli punkt w którym wartości współczynnika fałszywych akceptacji i odrzuceń są sobie równe wyniósł 1,04 % dla trzynastu elektrod [46]; 0,73 % dla 34 elektrod [118], 1,96 % dla 64 elektrod i 3,3 % dla 19 elektrod [47], podczas gdy w rozprawie uzyskano wartość EER dla 19 elektrod wynoszącą w przybliżeniu 2 %. Lepsze wyniki uzyskane w niektórych z cytowanych prac mogą być spowodowane tym, że użyte w nich zbiory testowe pochodziły z tych samych sesji co zbiory treningowe. W badaniach zawierających większą liczbę sesji pomiarowych wyniki okazywały się słabsze lub porównywalne do wyników prezentowanych w rozprawie. Przykładowo w pracy [119] przedstawiono badania nad zastosowaniem metod głębokiego uczenia do identyfikacji osób na podstawie sygnału EEG. Dla pięciu sesji sygnału zarejestrowanego w czasie spoczynku z otwartymi oczyma dla każdej z osób uzyskano wynik prawidłowo przeprowadzonych identyfikacji na poziomie 81,9 %.

Prezentowane w rozprawie metody posiadają jednak pewne ograniczenia związane z tym, że analizy zostały przeprowadzone na jednym, choć obszernym zbiorze zarejestrowanych sygnałów EEG oraz z wykorzystaniem tego samego sprzętu. Ponadto sygnały EEG były rejestrowane w jednym miejscu. Ograniczenie to można jednak potraktować jako próbę zbliżenia proponowanych w rozprawie metod do realnych warunków ich potencjalnego

zastosowania. Przykładowo grupa kilkunastu osób z jednej instytucji lub firmy może posiadać dostęp do wybranej usługi lub informacji. Sprzęt do ich weryfikacji i miejsce przeprowadzenia rejestracji będą wtedy takie same. Innym ograniczeniem jest to, że przeprowadzone badania mają charakter podstawowy i służą weryfikacji własnych koncepcji autorki. Z tego powodu w rozprawie nie rozpatrzono zagadnień związanych z błędami akwizycji sygnału oraz eliminacji artefaktów. Rejestracje były prowadzone w dobrych warunkach, prawdopodobnie nieco lepszych niż warunki, w których taki system byłby wykorzystywany.

W porównaniu do dłużej rozwijanych sposobów weryfikacji tożsamości opartych na innych cechach fizycznych i behawioralnych, badania nad zastosowaniem sygnału EEG w weryfikacji tożsamości osób wciąż są w stosunkowo wczesnej fazie rozwoju. Brakuje odpowiednich ogólnodostępnych zbiorów rejestracji EEG zawierających wiele sesji pomiarowych, na których można byłoby jednoznacznie porównać wyniki własnych prac z wynikami przedstawionymi w innych pracach.

6.3. Wnioski i kierunki dalszych badań

Zastosowanie zaproponowanych i opracowanych w rozprawie metod przyniosło pozytywne rezultaty i zapewniło osiągnięcie wysokich miar oceny jakości weryfikacji tożsamości osób. Możliwe jest dalsze doskonalenie proponowanych w rozprawie metod weryfikacji tożsamości, choć w wielu zastosowaniach osiągnięte wartości dokładności i swoistości mogą okazać się wystarczające.

W dalszych pracach należałoby przeanalizować możliwości przedstawionych metod z wykorzystaniem specjalnie opracowanych opasek służących do akwizycji sygnału EEG, obejmujących zaproponowane w rozprawie elektrody. Ciekawym kierunkiem dalszych prac byłoby również przeprowadzenie szerszych badań nad weryfikacją za pomocą różnych klasyfikatorów oraz dla różnych stanów osoby weryfikowanej, np. podczas chodzenia, rozmowy bądź pracy biurowej. Należałoby również przetestować wykorzystanie zaproponowanych metod w procesie identyfikacji tożsamości osób. Zwiększenie skuteczności i bezpieczeństwa metody mogłoby odbyć się poprzez zastosowanie biometrii opartej na EEG połączonej z innymi cechami fizycznymi i behawioralnymi. Badania nad rozpoznawaniem tożsamości osób zyskują coraz większe zainteresowanie, przykładowo polska firma ELMIKO BIOSIGNALS, będąca m.in. producentem aparatury i oprogramowania do akwizycji i analizy sygnału EEG oraz zajmująca się działalnością badawczo-rozwojową, wykazała zainteresowanie wynikami prac przedstawionymi w rozprawie.

Autorka żywi nadzieję, że przeprowadzone w rozprawie analizy oraz zaproponowane nowe rozwiązania dotyczące weryfikacji tożsamości osób na podstawie sygnału EEG przyczynią się do dalszego rozwoju tej dziedziny.

Bibliografia

- [1] K. Dzik, E. Gomulska, L. Naumowski i M. Plucińska, „Obszary zastosowań biometrii”, *Prace Naukowo-Badawcze Instytutu Maszyn Matematycznych*, tom 1, ss. 3–17, 2017, ISSN: 0209-1593.
- [2] M. Bugdol i A. W. Mitas, „Techniki biometryczne – podstawowe parametry jakościowe”, w *Techniki Komputerowe*, nr 1, Warszawa: Instytut Maszyn Matematycznych, 2007, ss. 29–38, ISSN: 0239-8044.
- [3] S. R. Borra, G. J. Reddy i E. S. Reddy, „A broad survey on fingerprint recognition systems”, w *2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*, 2016, ss. 1428–1434, doi: 10.1109/WiSPNET.2016.7566372.
- [4] A. Gielczyk, M. Choraś i R. Kozik, „Lightweight Verification Schema for Image-Based Palmprint Biometric Systems”, *Mobile Information Systems*, tom 2019:23258, 2019, doi: 10.1155/2019/2325891.
- [5] K. Shaheed, H. Liu, G. Yang, I. Qureshi, J. Gou i Y. Yin, „A systematic review of finger vein recognition techniques”, *Information*, tom 9, nr 9:213, 2018, doi: 10.3390/info9090213.
- [6] W. Wu, S. J. Elliott, S. Lin, S. Sun i Y. Tang, „Review of palm vein recognition”, *IET Biometrics*, tom 9, nr 1, ss. 1–10, 2020, doi: 10.1049/iet-bmt.2019.0034.
- [7] I. Adjabi, A. Ouahabi, A. Benzaoui i A. Taleb-Ahmed, „Past, Present, and Future of Face Recognition: A Review”, *Electronics*, tom 9, nr 8:1188, 2020, doi: 10.3390/electronics9081188.
- [8] M. Choraś, „Image Feature Extraction Methods for Ear Biometrics - A Survey”, w *6th International Conference on Computer Information Systems and Industrial Management Applications (CISIM'07)*, 2007, ss. 261–265, doi: 10.1109/CISIM.2007.40.
- [9] A. Czajka, D. Moreira, K. W. Bowyer i P. J. Flynn, „Domain-Specific Human-Inspired Binarized Statistical Image Features for Iris Recognition”, w *2019 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2019, ss. 959–967, doi: 10.1109/WACV.2019.00107.
- [10] J. A. Unar, W. C. Seng i A. Abbasi, „A review of biometric technology along with trends and prospects”, *Pattern Recognition*, tom 47, nr 8, ss. 2673–2688, 2014, doi: 10.1016/j.patcog.2014.01.016.
- [11] M. Rybnik, M. Tabedzki i K. Saeed, „A Keystroke Dynamics Based System for User

- Identification”, w *2008 7th Computer Information Systems and Industrial Management Applications*, 2008, ss. 225–230, doi: 10.1109/CISIM.2008.8.
- [12] C. Wan, L. Wang i V. V. Phoha, „A Survey on Gait Recognition”, *ACM Computing Surveys*, tom 51, nr 5:89, 2018, doi: 10.1145/3230633.
- [13] *ISO/IEC 2382-37:2022 Information technology — Vocabulary — Part 37: Biometrics*, 3. wyd. Geneva, Switzerland: ISO/IEC, 2022.
- [14] H.-L. Chan, P.-C. Kuo, C.-Y. Cheng i Y.-S. Chen, „Challenges and Future Perspectives on Electroencephalogram-Based Biometrics in Person Recognition”, *Frontiers in Neuroinformatics*, tom 12:66, 2018, doi: 10.3389/fninf.2018.00066.
- [15] M. Abo-Zahhad, S. M. Ahmed i S. N. Abbas, „State-of-the-art methods and future perspectives for personal recognition based on electroencephalogram signals”, *IET Biometrics*, tom 4, nr 3, ss. 179–190, 2015, doi: 10.1049/iet-bmt.2014.0040.
- [16] M. Wang, X. Yin, Y. Zhu i J. Hu, „Representation Learning and Pattern Recognition in Cognitive Biometrics: A Survey”, *Sensors*, tom 22, nr 14:5111, 2022, doi: 10.3390/s22145111.
- [17] M. Poulos, M. Rangoussi, V. Chrissikopoulos i A. Evangelou, „Parametric person identification from the EEG using computational geometry”, w *ICECS'99. Proceedings of ICECS '99. 6th IEEE International Conference on Electronics, Circuits and Systems (Cat. No.99EX357)*, 1999, tom 2, ss. 1005–1008, doi: 10.1109/ICECS.1999.813403.
- [18] M. Poulos, M. Rangoussi, V. Chrissikopoulos i A. Evangelou, „Person identification based on parametric processing of the EEG”, w *ICECS'99. Proceedings of ICECS '99. 6th IEEE International Conference on Electronics, Circuits and Systems (Cat. No.99EX357)*, 1999, tom 1, ss. 283–286, doi: 10.1109/ICECS.1999.812278.
- [19] M. Poulos, M. Rangoussi i N. Alexandris, „Neural network based person identification using EEG features”, w *1999 IEEE International Conference on Acoustics, Speech, and Signal Processing. Proceedings. ICASSP99 (Cat. No.99CH36258)*, 1999, tom 2, ss. 1117–1120, doi: 10.1109/ICASSP.1999.759940.
- [20] E. Solomon, L. Berg i D. Martin, *Biologia*, Warszawa: MULTICO Oficyna Wydawnicza, 2009, ss. 746–753, 773.
- [21] R. Soikkeli, J. Partanen, H. Riekkinen, A. Pääkkönen i P. Riekkinen, „Slowing of EEG in Parkinson's disease”, *Electroencephalography and Clinical Neurophysiology*, tom 79, nr 3, ss. 159–165, 1991, doi: 10.1016/0013-4694(91)90134-P.
- [22] S. J. M. Smith, „EEG in the diagnosis, classification, and management of patients with epilepsy”, *Journal of Neurology, Neurosurgery & Psychiatry*, tom 76, nr 2, ss. ii2–ii7,

- 2005, doi: 10.1136/jnnp.2005.069245.
- [23] E. A. Wolpert, „A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects”, *Archives of General Psychiatry*, tom 20, nr 2, ss. 246–247, 1969, doi: 10.1001/archpsyc.1969.01740140118016.
- [24] M. S. Aldrich, R. D. Chervin i B. A. Malow, „Value of the Multiple Sleep Latency Test (MSLT) for the Diagnosis of Narcolepsy”, *Sleep*, tom 20, nr 8, ss. 620–629, 1997, doi: 10.1093/sleep/20.8.620.
- [25] P. M. Keune *i in.*, „Exploring resting-state EEG brain oscillatory activity in relation to cognitive functioning in multiple sclerosis”, *Clinical Neurophysiology*, tom 128, nr 9, ss. 1746–1754, 2017, doi: 10.1016/j.clinph.2017.06.253.
- [26] E. P. Torres, E. A. Torres, M. Hernández-Álvarez i S. G. Yoo, „EEG-Based BCI Emotion Recognition: A Survey”, *Sensors*, tom 20, nr 18:5083, 2020, doi: 10.3390/s20185083.
- [27] M. K. Hazrati i A. Erfanian, „An online EEG-based brain-computer interface for controlling hand grasp using an adaptive probabilistic neural network”, *Medical Engineering & Physics*, tom 32, nr 7, ss. 730–739, 2010, doi: 10.1016/j.medengphy.2010.04.016.
- [28] A. Shoeibi *i in.*, „Automatic Diagnosis of Schizophrenia in EEG Signals Using CNN-LSTM Models”, *Frontiers in Neuroinformatics*, tom 15:777977, 2021, doi: 10.3389/fninf.2021.777977.
- [29] A. Sarkar, A. Singh i R. Chakraborty, „A deep learning-based comparative study to track mental depression from EEG data”, *Neuroscience Informatics*, tom 2, nr 4:100039, 2022, doi: 10.1016/j.neuri.2022.100039.
- [30] K. A. I. Aboalayon, M. Faezipour, W. S. Almuhammadi i S. Moslehpour, „Sleep Stage Classification Using EEG Signal Analysis: A Comprehensive Survey and New Investigation”, *Entropy*, tom 18, nr 9:272, 2016, doi: 10.3390/e18090272.
- [31] A. Malekzadeh, A. Zare, M. Yaghoobi, H.-R. Kobravi i R. Alizadehsani, „Epileptic Seizures Detection in EEG Signals Using Fusion Handcrafted and Deep Learning Features”, *Sensors*, tom 21, nr 22:7710, 2021, doi: 10.3390/s21227710.
- [32] U. R. Acharya, S. V. Sree, G. Swapna, R. J. Martis i J. S. Suri, „Automated EEG analysis of epilepsy: A review”, *Knowledge-Based Systems*, tom 45, ss. 147–165, 2013, doi: 10.1016/j.knosys.2013.02.014.
- [33] R. Plucińska, „Analiza metod cyfrowego przetwarzania sygnałów do efektywnego diagnozowania narkolepsji w rutynowym badaniu EEG”, Praca magisterska, Politechnika Warszawska, Wydział Elektroniki i Technik Informacyjnych, 2017.

- [34] R. Buettner, J. Fuhrmann i L. Kolb, „Towards high-performance differentiation between Narcolepsy and Idiopathic Hypersomnia in 10 minute EEG recordings using a Novel Machine Learning Approach”, w *2019 IEEE International Conference on E-health Networking, Application & Services (HealthCom)*, 2019, ss. 1–7, doi: 10.1109/HealthCom46333.2019.9009608.
- [35] S. L. Oh *i in.*, „A deep learning approach for Parkinson’s disease diagnosis from EEG signals”, *Neural Computing and Applications*, tom 32, nr 15, ss. 10927–10933, 2020, doi: 10.1007/s00521-018-3689-5.
- [36] L. Ma, J. W. Minett, T. Blu i W. S. Y.-Y. Wang, „Resting State EEG-based biometrics for individual identification using convolutional neural networks”, w *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2015, ss. 2848–2851, doi: 10.1109/EMBC.2015.7318985.
- [37] K. Jus i A. Jus, *Elektroencefalografia Kliniczna*, I., Warszawa: Państwowy Zakład Wydawnictw Lekarskich, 1967, ss. 11–17, 27–42.
- [38] P. Augustyniak, *Przetwarzanie Sygnałów Elektrodiagnostycznych*, Kraków: AGH Uczelniane Wydawnictwa Naukowo-Dydaktyczne, 2001, ss. 103–130.
- [39] M. Wang, H. El-Fiqi, J. Hu i H. A. Abbass, „Convolutional Neural Networks Using Dynamic Functional Connectivity for EEG-Based Person Identification in Diverse Human States”, *IEEE Transactions on Information Forensics and Security*, tom 14, nr 12, ss. 3359–3372, 2019, doi: 10.1109/TIFS.2019.2916403.
- [40] M. Wang, S. Wang i J. Hu, „Cancellable Template Design for Privacy-Preserving EEG Biometric Authentication Systems”, *IEEE Transactions on Information Forensics and Security*, tom 17, ss. 3350–3364, 2022, doi: 10.1109/TIFS.2022.3204222.
- [41] D. La Rocca *i in.*, „Human Brain Distinctiveness Based on EEG Spectral Coherence Connectivity”, *IEEE Transactions on Biomedical Engineering*, tom 61, nr 9, ss. 2406–2412, 2014, doi: 10.1109/TBME.2014.2317881.
- [42] R. Palaniappan i D. P. Mandic, „Biometrics from Brain Electrical Activity: A Machine Learning Approach”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, tom 29, nr 4, ss. 738–742, 2007, doi: 10.1109/TPAMI.2007.1013.
- [43] I. Jayarathne, M. Cohen i S. Amarakeerthi, „BrainID: Development of an EEG-based biometric authentication system”, w *2016 IEEE 7th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, 2016, ss. 1–6, doi: 10.1109/IEMCON.2016.7746325.
- [44] Y. Chen *i in.*, „A High-Security EEG-Based Login System with RSVP Stimuli and Dry

- Electrodes”, *IEEE Transactions on Information Forensics and Security*, tom 11, nr 12, ss. 2635–2647, 2016, doi: 10.1109/TIFS.2016.2577551.
- [45] M. K. Bashar, I. Chiaki i H. Yoshida, „Human identification from brain EEG signals using advanced machine learning method”, w *2016 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, 2016, ss. 475–479, doi: 10.1109/IECBES.2016.7843496.
- [46] C. M. Jijomon i A. P. Vinod, „EEG-based Biometric Identification using Frequently Occurring Maximum Power Spectral Features”, w *2018 IEEE Applied Signal Processing Conference (ASPCON)*, 2018, ss. 249–252, doi: 10.1109/ASPCON.2018.8748581.
- [47] K. P. Thomas i A. P. Vinod, „EEG-Based Biometric Authentication Using Gamma Band Power During Rest State”, *Circuits, Systems, and Signal Processing*, tom 37, nr 1, ss. 277–289, 2018, doi: 10.1007/s00034-017-0551-4.
- [48] M. V. Ruiz-Blondet, Z. Jin i S. Laszlo, „CEREBRE: A Novel Method for Very High Accuracy Event-Related Potential Biometric Identification”, *IEEE Transactions on Information Forensics and Security*, tom 11, nr 7, ss. 1618–1629, 2016, doi: 10.1109/TIFS.2016.2543524.
- [49] I. Nakanishi, S. Baba i C. Miyamoto, „EEG based biometric authentication using new spectral features”, w *2009 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)*, 2009, ss. 651–654, doi: 10.1109/ISPACS.2009.5383756.
- [50] M. K. Abdullah, K. S. Subari, J. L. C. Loong i N. N. Ahmad, „Analysis of the EEG Signal for a Practical Biometric System”, *World Academy of Science, Engineering and Technology, International Journal of Biomedical and Biological Engineering*, tom 4, nr 8, ss. 364–368, 2010, doi: 10.5281/zenodo.1055815.
- [51] E. Maiorana i P. Campisi, „Longitudinal Evaluation of EEG-Based Biometric Recognition”, *IEEE Transactions on Information Forensics and Security*, tom 13, nr 5, ss. 1123–1138, 2018, doi: 10.1109/TIFS.2017.2778010.
- [52] E. Maiorana, „Learning deep features for task-independent EEG-based biometric verification”, *Pattern Recognition Letters*, tom 143, ss. 122–129, 2021, doi: 10.1016/j.patrec.2021.01.004.
- [53] L. Yang, A. Libert i M. M. Van Hulle, „Chronic Study on Brainwave Authentication in a Real-Life Setting: An LSTM-Based Bagging Approach”, *Biosensors*, tom 11, nr 10:404, 2021, doi: 10.3390/bios11100404.
- [54] M. DelPozo-Banos, C. M. Travieso, C. T. Weidemann i J. B. Alonso, „EEG biometric

- identification: a thorough exploration of the time-frequency domain”, *Journal of Neural Engineering*, tom 12, nr 5:056019, 2015, doi: 10.1088/1741-2560/12/5/056019.
- [55] P. Campisi i D. La Rocca, „Brain waves for automatic biometric-based user recognition”, *IEEE Transactions on Information Forensics and Security*, tom 9, nr 5, ss. 782–800, 2014, doi: 10.1109/TIFS.2014.2308640.
- [56] S. Yang i F. Deravi, „On the Usability of Electroencephalographic Signals for Biometric Recognition: A Survey”, *IEEE Transactions on Human-Machine Systems*, tom 47, nr 6, ss. 958–969, 2017, doi: 10.1109/THMS.2017.2682115.
- [57] S. Kaufman, S. Rosset i C. Perlich, „Leakage in Data Mining: Formulation, Detection, and Avoidance”, *ACM Transactions on Knowledge Discovery from Data*, tom 6, nr 4, ss. 556–563, 2012, doi: 10.1145/2020408.2020496.
- [58] R. Plucińska, K. Jędrzejewski, J. Rogala, U. Malinowska i M. Waligóra, „Experimental studies on the efficiency of people authentication using EEG data from the same and different examinations”, w *2021 Signal Processing Symposium (SPSympo)*, 2021, ss. 216–219, doi: 10.1109/SPSympo51155.2020.9593800.
- [59] R. Plucińska, K. Jędrzejewski, M. Waligóra, U. Malinowska i J. Rogala, „Impact of EEG Frequency Bands and Data Separation on the Performance of Person Verification Employing Neural Networks”, *Sensors*, tom 22:5529, 2022, doi: 10.3390/s22155529.
- [60] R. Plucińska, K. Jędrzejewski, U. Malinowska i J. Rogala, „Leveraging Multiple Distinct EEG Training Sessions for Improvement of Spectral-Based Biometric Verification Results”, *Sensors*, tom 23, nr 4:2057, 2023, doi: 10.3390/s23042057.
- [61] R. Plucińska, K. Jędrzejewski, U. Malinowska i J. Rogala, „Influence of Feature Scaling and Number of Training Sessions on EEG Spectral-based Person Verification with Artificial Neural Networks”, w *2023 Signal Processing Symposium (SPSympo)* – referat przyjęty do druku.
- [62] R. Plucińska, K. Jędrzejewski, M. Waligóra i U. Malinowska, „EEG Signal Analysis for Human Verification using Neural Networks-Preliminary Experimental Results”, w *2020 Signal Processing Workshop (SPW)*, 2020, ss. 6–10, doi: 10.23919/SPW49079.2020.9259137.
- [63] R. Plucińska, K. Jędrzejewski, M. Waligóra i U. Malinowska, „Experimental studies on the possibility of people verification using few frontal EEG derivations”, w *Photonics Applications in Astronomy, Communications, Industry, and High Energy Physics Experiments 2020*, 2020, 115811B, doi: 10.1117/12.2580597.
- [64] Q. Gui, M. V. Ruiz-Blondet, S. Laszlo i Z. Jin, „A survey on brain biometrics”, *ACM*

- Computing Surveys*, tom 51, nr 6:112, ss. 1–38, 2019, doi: 10.1145/3230632.
- [65] H. Berger, „Über das Elektrenkephalogramm des Menschen”, *Archiv für Psychiatrie und Nervenkrankheiten*, tom 87, nr 1, ss. 527–570, 1929, doi: 10.1007/BF01797193.
- [66] E. N. Marieb i K. Hoehn, *Human Anatomy & Physiology*, 9. wyd., Pearson, 2013, s. 411.
- [67] A. Sobieszek, „Neurofizjologiczne podstawy elektroencefalografii”, w *Elektroencefalografia kliniczna*, J. Majkowski, Red. Warszawa: Państwowy Zakład Wydawnictw Lekarskich, 1989, ss. 20–22.
- [68] H. H. Jasper, „Report of the committee on methods of clinical examination in electroencephalography: 1957”, *Electroencephalography and Clinical Neurophysiology*, tom 10, nr 2, ss. 370–375, 1958, doi: 10.1016/0013-4694(58)90053-1.
- [69] R. Plucińska i K. Jędrzejewski, „Evaluation of adaptive algorithms effectiveness for cancellation of power line interferences in gamma waves band of EEG signal”, w *2019 Signal Processing Symposium (SPSymo)*, 2019, ss. 115–120, doi: 10.1109/SPS.2019.8882014.
- [70] J. Majkowski, „Podstawy i technika rejestracji czynności bioelektrycznej mózgu”, w *Elektroencefalografia kliniczna*, Warszawa: Państwowy Zakład Wydawnictw Lekarskich, 1989, ss. 47–50.
- [71] J. Majkowski, „EEG zdrowego dorosłego człowieka”, w *Elektroencefalografia kliniczna*, J. Majkowski, Red. Warszawa: Państwowy Zakład Wydawnictw Lekarskich, 1989, ss. 61–75.
- [72] P. Durka i in., „Elektryczny Ślad Myśli – Podręcznik wspierany przez Fundusz Innowacji Dydaktycznych Uniwersytetu Warszawskiego”.
https://brain.fuw.edu.pl/edu/index.php/Elektroencefalografia/Metody_analazy_sygnałów_w_EEG_-_analiza_w_dziedzinie_czasu, [online] dostęp: 26.03.2023.
- [73] A. Wróbel, „Beta activity: a carrier for visual attention”, *Acta neurobiologiae experimentalis (Wars)*, tom 60, nr 2, ss. 247–260, 2000, PMID: 10909182.
- [74] „Słownik języka polskiego PWN”. <https://sjp.pwn.pl/sjp/biometria;2444846.html> [online] dostęp: 26.03.2023.
- [75] H. Y. Yap, Y.-H. Choo, Z. I. M. Yusoh i W. H. Khoh, „Person authentication based on eye-closed and visual stimulation using EEG signals”, *Brain Informatics*, tom 8, nr 1:21, 2021, doi: 10.1186/s40708-021-00142-4.
- [76] A. K. Jain i A. Ross, „Introduction to Biometrics”, w *Handbook of Biometrics*, A. K. Jain, P. Flynn i A. Ross, Red. New York: Springer, 2007, ss. 1–22.

- [77] R. Damaševičius, R. Maskeliūnas, E. Kazanavičius i M. Woźniak, „Combining Cryptography with EEG Biometrics”, *Computational Intelligence and Neuroscience*, tom 2018:18675, 2018, doi: 10.1155/2018/1867548.
- [78] GIODO, „INFORMACJA Generalnego Inspektora Ochrony Danych Osobowych o zagrożeniach płynących z upowszechnienia danych biometrycznych w kontaktach obywateli z instytucjami publicznymi i prywatnymi.”, 2017. <https://archiwum.giodo.gov.pl/pl/file/12478> [online] dostęp: 26.03.2023.
- [79] C. E. M. van Beijsterveldt, P. C. M. Molenaar, E. J. C. de Geus i D. I. Boomsma, „Heritability of human brain functioning as assessed by electroencephalography”, *American Journal of Human Genetics*, tom 58, nr 3, ss. 562–573, 1996, PMID: 8644716.
- [80] D. J. A. Smit, C. J. Stam, D. Posthuma, D. I. Boomsma i E. J. C. de Geus, „Heritability of ‘‘Small-World’’ Networks in the Brain: A Graph Theoretical Analysis of Resting-State EEG Functional Connectivity”, *Human Brain Mapping*, tom 29, nr 12, ss. 1368–1378, 2008, doi: 10.1002/hbm.20468.
- [81] P. Arias-Cabarcos, T. Habrich, K. Becker, C. Becker i T. Strufe, „Inexpensive Brainwave Authentication: New Techniques and Insights on User Acceptance”, w *30th USENIX Security Symposium (USENIX Security 21)*, 2021, ss. 55–72, ISBN: 978-1-939133-24-3.
- [82] M. Wang, J. Hu i H. A. Abbass, „BrainPrint: EEG biometric identification based on analyzing brain connectivity graphs”, *Pattern Recognition*, tom 105:107381, 2020, doi: 10.1016/j.patcog.2020.107381.
- [83] R. Das, E. Maiorana i P. Campisi, „EEG Biometrics Using Visual Stimuli: A Longitudinal Study”, *IEEE Signal Processing Letters*, tom 23, nr 3, ss. 341–345, 2016, doi: 10.1109/LSP.2016.2516043.
- [84] J. Chuang, H. Nguyen, C. Wang i B. Johnson, „I Think, Therefore I Am: Usability and Security of Authentication Using Brainwaves”, w *International Conference on Financial Cryptography and Data Security*, 2013, ss. 1–16, doi: 10.1007/978-3-642-41320-9_1.
- [85] E. Maiorana, D. La Rocca i P. Campisi, „Eigenbrains and Eigentensorbrains: Parsimonious bases for EEG biometrics”, *Neurocomputing*, tom 171, ss. 638–648, 2016, doi: 10.1016/j.neucom.2015.07.005.
- [86] R. B. Paranjape, J. Mahovsky, L. Benedicenti i Z. Koles, „The electroencephalogram as a biometric”, *Canadian Conference on Electrical and Computer Engineering 2001. Conference Proceedings (Cat. No.01TH8555)*, tom 2, ss. 1363–1366, 2001, doi: 10.1109/CCECE.2001.933649.

- [87] A. Miladinović *i in.*, „Effect of power feature covariance shift on BCI spatial-filtering techniques: A comparative study”, *Computer Methods and Programs in Biomedicine*, tom 198:105808, 2021, doi: 10.1016/j.cmpb.2020.105808.
- [88] H. Raza, D. Rathee, S.-M. Zhou, H. Cecotti i G. Prasad, „Covariate shift estimation based adaptive ensemble learning for handling non-stationarity in motor imagery related EEG-based brain-computer interface”, *Neurocomputing*, tom 343, ss. 154–166, 2019, doi: 10.1016/j.neucom.2018.04.087.
- [89] S. Marcel i J. del R. Millan, „Person Authentication Using Brainwaves (EEG) and Maximum A Posteriori Model Adaptation”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, tom 29, nr 4, ss. 743–748, 2007, doi: 10.1109/TPAMI.2007.1012.
- [90] B. Hu, Q. Liu, Q. Zhao, Y. Qi i H. Peng, „A Real-Time Electroencephalogram (EEG) Based Individual Identification Interface for Mobile Security in Ubiquitous Environment”, w *2011 IEEE Asia-Pacific Services Computing Conference*, 2011, ss. 436–441, doi: 10.1109/APSCC.2011.87.
- [91] W. T. Blume, „Drug effects on EEG”, *Journal of Clinical Neurophysiology*, tom 23, nr 4, ss. 306–311, 2006, doi: 10.1097/01.wnp.0000229137.94384.fa.
- [92] J. Meng *i in.*, „Effects of Soft Drinks on Resting State EEG and Brain-Computer Interface Performance”, *IEEE Access*, tom 5, ss. 18756–18764, 2017, doi: 10.1109/ACCESS.2017.2751069.
- [93] S. Kähkönen, J. Wilenius, V. V. Nikulin, M. Ollikainen i R. J. Ilmoniemi, „Alcohol reduces prefrontal cortical excitability in humans: A combined TMS and EEG study”, *Neuropsychopharmacology*, tom 28, nr 4, ss. 747–754, 2003, doi: 10.1038/sj.npp.1300099.
- [94] ELMIKO BIOSIGNALS sp. z o.o., <https://www.elmiko.pl/pl/> [online] dostęp: 26.03.2023.
- [95] D. J. McFarland, L. M. McCane, S. V. David i J. R. Wolpaw, „Spatial filter selection for EEG-based communication”, *Electroencephalography and Clinical Neurophysiology*, tom 103, nr 3, ss. 386–394, 1997, doi: 10.1016/S0013-4694(97)00022-2.
- [96] M. Kołodziej, „Przetwarzanie, analiza i klasyfikacja sygnału EEG na użytek interfejsu mózg-komputer”, Rozprawa doktorska, Politechnika Warszawska, Wydział Elektryczny, 2011, ss. 60-61.
- [97] M. C. Salinsky, B. S. Oken i L. Morehead, „Test-retest reliability in EEG frequency analysis”, *Electroencephalography and Clinical Neurophysiology*, tom 79, nr 5, ss. 382–392, 1991, doi: 10.1016/0013-4694(91)90203-G.

- [98] M. Näpflin, M. Wildi i J. Sarnthein, „Test-retest reliability of resting EEG spectra validates a statistical signature of persons”, *Clinical Neurophysiology*, tom 118, nr 11, ss. 2519–2524, 2007, doi: 10.1016/j.clinph.2007.07.022.
- [99] T. Popov, M. Tröndle, Z. Baranczuk-Turska, C. Pfeiffer, S. Haufe i N. Langer, „Test–retest reliability of resting-state EEG in young and older adults”, *Psychophysiology*, tom 60, nr 7:e14268, 2023, doi: 10.1111/psyp.14268.
- [100] T. Gasser, P. Bächer i H. Steinberg, „Test-retest reliability of spectral parameters of the EEG”, *Electroencephalography and Clinical Neurophysiology*, tom 60, nr 4, ss. 312–319, 1985, doi: 10.1016/0013-4694(85)90005-7.
- [101] R. Plucińska, „Podatność pasma beta w EEG na zmiany podczas treningu w warunkach wirtualnej rzeczywistości”, Praca licencjacka, Uniwersytet Warszawski, Wydział Filozofii, 2021.
- [102] P. Welch, „The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms”, *IEEE Transactions on Audio and Electroacoustics*, tom 15, nr 2, ss. 70–73, 1967, doi: 10.1109/TAU.1967.1161901.
- [103] R. G. Lyons, *Wprowadzenie do cyfrowego przetwarzania sygnałów*, 2. wyd., Warszawa: Wydawnictwa Komunikacji i Łączności, 2010, ss. 62–107, 137–139.
- [104] Z.-H. Zhou, *Machine learning*, Springer Singapore, 2021, ss. 2–23, 79–152, 181–209, 242–243.
- [105] C. Kingsford i S. L. Salzberg, „What are decision trees?”, *Nature Biotechnology*, tom 26, ss. 1011–1013, 2008, doi: 10.1038/nbt0908-1011.
- [106] W. Y. Loh, „Regression trees with unbiased variable selection and interaction detection”, *Statistica Sinica*, tom 12, nr 2, ss. 361–386, 2002.
- [107] T. K. Ho, „Random decision forests”, w *Proceedings of 3rd International Conference on Document Analysis and Recognition*, 1995, tom 1, ss. 278–282, doi: 10.1109/ICDAR.1995.598994.
- [108] I. A. Basheer i M. Hajmeer, „Artificial neural networks: fundamentals, computing, design, and application”, *Journal of Microbiological Methods*, tom 43, nr 1, ss. 3–31, 2000, doi: 10.1016/S0167-7012(00)00201-3.
- [109] M. T. Hagan i M. B. Menhaj, „Training feedforward networks with the Marquardt algorithm”, *IEEE Transactions on Neural Networks*, tom 5, nr 6, ss. 989–993, 1994, doi: 10.1109/72.329697.
- [110] R. Tadeusiewicz i M. Szaleniec, „Leksykon sieci neuronowych”, Wrocław:

Wydawnictwo Fundacji „Projekt Nauka”, 2015, ss. 34, 59, 64.

- [111] D. Berrar, „Cross-Validation”, *Encyclopedia of Bioinformatics and Computational Biology*, tom 1, ss. 542–545, 2019, doi: 10.1016/B978-0-12-809633-8.20349-X.
- [112] J. Koronacki i J. Mielniczuk, *Statystyka dla studentów kierunków technicznych i przyrodniczych*, tom 6, Warszawa: Wydawnictwa Naukowo-Techniczne, 2006, ss. 319–354, 467–471.
- [113] P. Bühlmann i B. Yu, „Analyzing bagging”, *Annals of Statistics*, tom 30, nr 4, ss. 927–961, 2002, doi: 10.1214/aos/1031689014.
- [114] J. Kamiński, A. Brzezicka, M. Gola i A. Wróbel, „Beta band oscillations engagement in human alertness process”, *International Journal of Psychophysiology*, tom 85, nr 1, ss. 125–128, 2012, doi: 10.1016/j.ijpsycho.2011.11.006.
- [115] K. Paluch i in., „Beware: Recruitment of Muscle Activity by the EEG-Neurofeedback Trainings of High Frequencies”, *Frontiers in Human Neuroscience*, tom 11:119, 2017, doi: 10.3389/fnhum.2017.00119.
- [116] D. E. DeGood i R. C. Chisholm, „Multiple Response Comparison of Parietal EEG and Frontalis EMG Biofeedback”, *Psychophysiology*, tom 14, nr 3, ss. 258–265, 1977, doi: 10.1111/j.1469-8986.1977.tb01171.x.
- [117] S. Maurizio, M. D. Liechti, D. Brandeis, L. Jäncke i R. Drechsler, „Differential EMG Biofeedback for Children with ADHD: A Control Method for Neurofeedback Training with a Case Illustration”, *Applied Psychophysiology Biofeedback*, tom 38, ss. 109–119, 2013, doi: 10.1007/s10484-013-9213-x.
- [118] J.-H. Kang, Y. C. Jo i S.-P. Kim, „Electroencephalographic feature evaluation for improving personal authentication performance”, *Neurocomputing*, tom 287, ss. 93–101, 2018, doi: 10.1016/j.neucom.2018.01.074.
- [119] E. Maiorana, „Deep learning for EEG-based biometric recognition”, *Neurocomputing*, tom 410, ss. 374–386, 2020, doi: 10.1016/j.neucom.2020.06.009.

Dodatek A. Uśrednione wartości miar jakości klasyfikacji dla różnych metod skalowania współczynników widmowej gęstości mocy

Dodatek stanowi uzupełnienie punktu 5.2, w którym badano wpływ skalowania współczynników widmowej gęstości mocy na miary jakości klasyfikacji. Tabele 25-26 są liczbowym przedstawieniem wyników przedstawionych na rysunkach 19-25.

Tabela 25. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe dla nieskalowanych współczynników gęstości widmowej mocy.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	76,5±11,6	71,8±21,9	81,2±6,5	77,3±11,7	18,8±6,5	28,2±21,9
2	81,1±9,0	77,0±16,6	85,1±5,2	83,3±6,6	14,9±5,2	23,0±16,6
3	82,9±7,9	79,7±13,5	86,1±5,3	85,0±6,2	13,9±5,3	20,3±13,5
4	84,4±7,6	81,4±13,6	87,4±4,7	86,4±5,3	12,6±4,7	18,6±13,6
5	86,0±7,8	83,7±14,1	88,2±4,6	87,4±5,4	11,8±4,6	16,3±14,1
6	86,8±8,1	84,1±14,3	89,4±4,3	88,5±5,4	10,6±4,3	15,9±14,3
7	88,4±6,9	86,6±11,9	90,1±4,0	89,6±4,6	9,9±4,0	13,4±11,9
8	89,4±6,4	88,6±10,4	90,2±4,0	90,0±4,5	9,8±4,0	11,4±10,4
9	89,8±6,2	89,8±10,9	89,7±4,1	89,7±4,1	10,3±4,1	10,2±10,9
10	91,2±6,0	91,3±9,3	91,1±3,8	90,9±4,3	8,9±3,8	8,7±9,3
11	91,1±6,1	91,6±9,2	90,6±4,4	90,7±4,6	9,4±4,4	8,4±9,2
12	91,7±6,0	92,0±9,8	91,3±3,3	91,2±3,8	8,7±3,3	8,0±9,8
13	91,8±5,8	91,2±9,9	92,4±2,9	92,2±3,4	7,6±2,9	8,8±9,9
14	92,0±6,5	91,8±10,6	92,1±3,3	91,9±4,2	7,9±3,3	8,2±10,6
15	92,4±5,8	92,6±8,7	92,3±3,7	92,2±4,2	7,7±3,7	7,4±8,7

Tabela 26. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji powNorm.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	69,1±10,3	55,6±20,9	82,5±8,3	74,3±12,1	17,5±8,3	44,4±20,9
2	73,6±10,2	61,3±18,3	85,9±6,4	80,4±9,5	14,1±6,4	38,7±18,3
3	76,6±9,6	66,8±16,3	86,4±7,6	83,0±9,0	13,6±7,6	33,2±16,3
4	78,0±8,7	70,8±15,9	85,3±7,7	83,1±8,4	14,7±7,7	29,2±15,9
5	80,1±8,6	72,9±14,9	87,4±6,2	85,1±7,3	12,6±6,2	27,1±14,9
6	82,8±7,9	78,0±12,5	87,6±6,0	86,2±6,9	12,4±6,0	22,0±12,5
7	84,1±8,1	79,0±13,0	89,1±5,6	87,8±6,5	10,9±5,6	21,0±13,0
8	85,8±7,8	81,5±13,7	90,2±4,3	89,1±5,4	9,8±4,3	18,5±13,7
9	86,2±7,6	82,4±12,3	90,0±5,1	89,0±5,9	10,0±5,1	17,6±12,3
10	87,0±6,8	84,4±11,2	89,6±4,6	89,0±5,0	10,4±4,6	15,6±11,2
11	88,2±7,2	86,0±12,0	90,3±3,9	89,7±4,9	9,7±3,9	14,0±12,0
12	88,7±6,6	87,0±10,8	90,3±4,9	89,9±5,1	9,7±4,9	13,0±10,8
13	88,9±6,1	86,5±9,9	91,4±4,3	91,0±4,8	8,6±4,3	13,5±9,9
14	89,5±5,9	87,8±9,1	91,2±4,1	90,8±4,5	8,8±4,1	12,2±9,1
15	89,7±5,8	88,6±8,8	90,8±4,3	90,6±4,6	9,2±4,3	11,4±8,8

Tabela 27. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji zNorm.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	62,3±10,8	46,3±21,2	78,4±10,0	66,5±14,7	21,6±10,0	53,7±21,2
2	67,5±10,1	53,6±18,2	81,5±7,4	72,8±11,4	18,5±7,4	46,4±18,2
3	70,7±9,4	60,4±17,4	81,1±8,4	75,8±10,4	18,9±8,4	39,6±17,4
4	73,3±7,4	65,6±14,2	81,1±7,6	77,8±8,0	18,9±7,6	34,4±14,2
5	75,5±8,6	67,3±15,6	83,7±6,9	80,5±7,5	16,3±6,9	32,7±15,6
6	77,6±8,3	72,4±13,3	82,9±7,1	81,0±7,8	17,1±7,1	27,6±13,3
7	80,5±7,6	75,9±12,1	85,2±5,7	83,7±6,6	14,8±5,7	24,1±12,1
8	81,1±8,7	76,2±14,8	86,0±5,6	84,3±7,0	14,0±5,6	23,8±14,8
9	82,8±7,6	79,9±12,2	85,7±6,0	84,9±6,3	14,3±6,0	20,1±12,2
10	84,7±6,8	82,8±11,0	86,6±5,0	86,0±5,3	13,4±5,0	17,2±11,0
11	85,6±7,2	83,1±12,2	88,2±4,8	87,5±5,5	11,8±4,8	16,9±12,2
12	86,0±6,7	84,2±11,0	87,8±4,5	87,4±4,8	12,2±4,5	15,8±11,0
13	86,8±5,9	84,5±9,2	89,1±4,7	88,7±4,9	10,9±4,7	15,5±9,2
14	86,5±6,1	84,5±9,2	88,6±4,7	88,2±5,0	11,4±4,7	15,5±9,2
15	87,0±6,1	85,8±9,4	88,3±4,9	88,0±5,1	11,7±4,9	14,2±9,4

Tabela 28. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji prcNorm.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	72,6±9,2	64,2±18,6	80,9±8,7	77,2±7,6	19,1±8,7	35,8±18,6
2	78,6±9,0	70,6±17,3	86,6±5,6	83,7±7,4	13,4±5,6	29,4±17,3
3	83,0±7,7	77,5±14,6	88,4±5,9	87,1±6,1	11,6±5,9	22,5±14,6
4	84,6±7,5	80,5±13,5	88,8±5,0	87,7±5,5	11,2±5,0	19,5±13,5
5	85,0±7,1	81,7±12,5	88,3±6,1	87,6±6,1	11,7±6,1	18,3±12,5
6	87,9±6,0	85,5±10,2	90,3±4,9	90,0±4,9	9,7±4,9	14,5±10,2
7	88,1±7,3	85,7±12,3	90,5±4,2	89,9±5,1	9,5±4,2	14,3±12,3
8	89,4±6,6	86,8±11,3	91,9±4,1	91,4±4,6	8,1±4,1	13,2±11,3
9	90,0±6,0	89,0±10,1	91,1±4,9	91,0±4,9	8,9±4,9	11,0±10,1
10	90,6±5,6	89,7±9,1	91,5±4,5	91,4±4,5	8,5±4,5	10,3±9,1
11	90,9±5,0	90,5±7,6	91,4±4,3	91,4±4,2	8,6±4,3	9,5±7,6
12	91,0±6,1	89,9±10,0	92,1±3,9	91,9±4,2	7,9±3,9	10,1±10,0
13	91,8±6,0	90,5±9,9	93,1±3,6	92,8±4,0	6,9±3,6	9,5±9,9
14	92,0±5,4	90,9±8,9	93,1±3,4	92,9±3,7	6,9±3,4	9,1±8,9
15	92,1±5,6	91,5±8,6	92,7±4,0	92,6±4,2	7,3±4,0	8,5±8,6

Tabela 29. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji iqrNorm.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	77,4±10,5	69,0±22,1	85,8±9,0	83,0±8,2	14,2±9,0	31,0±22,1
2	84,5±8,8	78,8±16,1	90,2±6,4	89,1±6,4	9,8±6,4	21,2±16,1
3	85,3±9,3	78,9±17,3	91,7±5,5	90,1±6,6	8,3±5,5	21,1±17,3
4	87,3±9,2	81,7±17,4	92,9±4,6	91,7±5,4	7,1±4,6	18,3±17,4
5	88,5±8,0	84,5±15,2	92,5±4,4	91,8±4,7	7,5±4,4	15,5±15,2
6	89,1±8,5	85,4±15,5	92,8±4,7	92,1±5,2	7,2±4,7	14,6±15,5
7	90,4±7,5	87,5±13,5	93,2±3,7	92,6±4,4	6,8±3,7	12,5±13,5
8	91,5±7,1	88,9±13,1	94,1±3,6	93,6±3,8	5,9±3,6	11,1±13,1
9	92,1±6,3	90,3±11,0	93,9±3,6	93,6±3,9	6,1±3,6	9,7±11,0
10	93,5±5,5	92,2±9,3	94,7±3,9	94,6±3,8	5,3±3,9	7,8±9,3
11	93,3±5,7	92,4±9,5	94,2±4,1	94,1±4,1	5,8±4,1	7,6±9,5
12	93,3±6,0	91,9±10,1	94,6±3,8	94,4±3,8	5,4±3,8	8,1±10,1
13	93,7±6,7	92,4±11,8	94,9±3,4	94,6±4,1	5,1±3,4	7,6±11,8
14	93,6±5,7	92,7±9,4	94,5±3,6	94,3±3,7	5,5±3,6	7,3±9,4
15	94,0±5,4	93,1±8,7	95,0±3,3	94,9±3,5	5,0±3,3	6,9±8,7

Tabela 30. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po zastosowaniu normalizacji rNorm.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	74,9±10,1	64,4±21,4	85,5±8,6	81,8±8,6	14,5±8,6	35,6±21,4
2	83,8±8,0	77,1±15,0	90,4±5,5	89,0±5,6	9,6±5,5	22,9±15,0
3	85,5±8,2	79,2±15,4	91,7±4,5	90,2±5,6	8,3±4,5	20,8±15,4
4	87,6±8,8	83,0±16,0	92,1±5,5	91,2±6,1	7,9±5,5	17,0±16,0
5	88,8±8,0	85,4±14,5	92,3±4,4	91,6±4,8	7,7±4,4	14,6±14,5
6	90,0±7,9	86,9±13,7	93,1±4,9	92,5±5,5	6,9±4,9	13,1±13,7
7	90,5±7,3	87,9±12,7	93,1±3,8	92,5±4,7	6,9±3,8	12,1±12,7
8	91,3±6,9	89,3±11,7	93,4±4,2	93,0±4,5	6,6±4,2	10,7±11,7
9	92,5±5,6	91,1±9,3	93,9±3,7	93,7±4,0	6,1±3,7	8,9±9,3
10	93,0±6,2	91,6±10,4	94,4±4,0	94,2±4,2	5,6±4,0	8,4±10,4
11	93,0±5,7	92,0±9,3	94,1±4,3	94,0±4,4	5,9±4,3	8,0±9,3
12	93,1±6,2	91,5±10,6	94,7±3,8	94,4±4,0	5,3±3,8	8,5±10,6
13	93,4±6,7	91,9±11,4	94,8±3,8	94,5±4,5	5,2±3,8	8,1±11,4
14	93,6±5,6	92,7±9,1	94,5±3,6	94,3±3,8	5,5±3,6	7,3±9,1
15	93,6±5,5	92,3±9,3	94,8±3,0	94,6±3,3	5,2±3,0	7,7±9,3

Tabela 31. Uśrednione wartości miar jakości klasyfikacji oraz ich odchylenia standardowe po wyrażeniu współczynników widmowej gęstości mocy w skali decybelowej (dBScale).

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	81,5±11,2	74,8±22,5	88,1±5,2	84,7±8,2	11,9±5,2	25,2±22,5
2	87,0±7,6	81,8±14,8	92,1±5,4	91,7±4,7	7,9±5,4	18,2±14,8
3	88,7±8,4	83,4±16,8	93,9±2,8	92,9±3,6	6,1±2,8	16,6±16,8
4	91,2±7,2	87,6±14,2	94,9±2,6	94,6±2,8	5,1±2,6	12,4±14,2
5	92,2±7,0	88,2±13,7	96,2±1,7	95,9±2,0	3,8±1,7	11,8±13,7
6	93,3±5,9	90,1±11,3	96,5±1,7	96,3±1,9	3,5±1,7	9,9±11,3
7	94,5±5,5	91,7±10,3	97,3±1,3	97,1±1,6	2,7±1,3	8,3±10,3
8	94,6±5,4	91,8±10,4	97,4±1,3	97,2±1,5	2,6±1,3	8,2±10,4
9	95,5±4,8	93,5±8,7	97,6±1,6	97,4±1,8	2,4±1,6	6,5±8,7
10	95,7±4,6	93,7±8,6	97,8±1,2	97,7±1,3	2,2±1,2	6,3±8,6
11	95,6±4,7	93,7±8,5	97,4±1,4	97,3±1,6	2,6±1,4	6,3±8,5
12	96,1±5,5	94,1±10,5	98,0±0,8	97,9±1,0	2,0±0,8	5,9±10,5
13	96,2±4,6	94,4±8,6	98,1±1,0	98,0±1,2	1,9±1,0	5,6±8,6
14	96,5±4,6	94,5±8,5	98,4±1,0	98,3±1,2	1,6±1,0	5,5±8,5
15	96,6±4,2	95,1±8,0	98,1±0,9	98,0±1,1	1,9±0,9	4,9±8,0

Dodatek B. Uśrednione wartości miar jakości klasyfikacji dla różnych podpasm widma sygnału EEG

Dodatek stanowi uzupełnienie punktu 5.4, w którym analizowano wpływ wybranych podpasm sygnału EEG na miary jakości klasyfikacji. Tabele 32-41 są liczbowym przedstawieniem wyników pokazanych na rysunkach 32-41.

Tabela 32. Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasma odpowiadającego rytmowi δ .

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	61,3±1,8	57,4±1,6	74,6±1,6	88,3±2,2	25,4±1,6	42,6±1,6
2	62,9±1,6	58,9±1,2	73,8±2,0	85,8±1,5	26,2±2,0	41,1±1,2
3	63,6±1,5	59,4±1,2	74,8±1,5	86,2±1,2	25,2±1,5	40,6±1,2
4	66,1±1,5	61,4±1,2	77,9±2,4	87,2±1,6	22,1±2,4	38,6±1,2
5	69,5±2,0	64,7±1,8	79,2±2,1	86,2±1,2	20,8±2,1	35,3±1,8
6	71,9±3,2	67,5±3,7	79,8±2,1	85,3±1,3	20,2±2,1	32,5±3,7
7	74,0±3,1	69,9±4,1	80,7±1,5	85,1±1,1	19,3±1,5	30,1±4,1
8	78,1±3,0	73,6±3,8	84,9±1,7	87,9±1,2	15,1±1,7	26,4±3,8
9	78,7±2,0	75,0±2,6	83,7±1,3	86,1±0,9	16,3±1,3	25,0±2,6
10	77,9±2,3	74,4±2,8	82,8±1,6	85,4±1,2	17,2±1,6	25,6±2,8
11	80,0±3,1	78,0±4,9	82,6±1,3	84,1±0,7	17,4±1,3	22,0±4,9
12	79,9±3,7	77,4±4,8	83,2±2,3	85,0±1,5	16,8±2,3	22,6±4,8
13	78,8±2,8	75,2±3,4	83,7±1,7	86,2±1,0	16,3±1,7	24,8±3,4
14	80,6±3,6	78,0±5,0	83,9±2,0	85,6±1,3	16,1±2,0	22,0±5,0
15	82,3±3,4	80,3±5,0	84,9±1,7	86,1±1,1	15,1±1,7	19,7±5,0

Tabela 33. *Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasma odpowiadającego rytmowi θ .*

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	74,3±2,5	70,6±2,9	79,8±1,7	83,7±1,6	20,2±1,7	29,4±2,9
2	76,4±2,4	72,3±2,5	82,3±2,5	85,5±2,0	17,7±2,5	27,7±2,5
3	79,1±4,1	74,9±4,1	85,3±3,0	88,2±1,4	14,7±3,0	25,1±4,1
4	79,4±3,9	75,3±4,1	85,5±2,9	88,2±1,3	14,5±2,9	24,7±4,1
5	81,4±2,1	77,7±3,0	86,6±1,3	88,5±1,7	13,4±1,3	22,3±3,0
6	86,2±1,0	83,3±1,0	89,6±1,5	90,5±1,4	10,4±1,5	16,7±1,0
7	86,3±1,7	83,2±2,1	90,0±1,4	90,9±1,3	10,0±1,4	16,8±2,1
8	87,2±1,0	85,4±1,6	89,2±0,5	89,8±0,6	10,8±0,5	14,6±1,6
9	87,5±1,2	86,0±1,3	89,1±1,3	89,6±1,3	10,9±1,3	14,0±1,3
10	86,4±1,4	84,0±1,9	89,3±1,0	90,0±1,1	10,7±1,0	16,0±1,9
11	87,7±1,0	86,3±1,0	89,2±1,4	89,6±1,5	10,8±1,4	13,7±1,0
12	87,5±0,8	86,2±1,1	88,9±1,2	89,3±1,3	11,1±1,2	13,8±1,1
13	88,8±1,1	87,4±1,2	90,3±1,4	90,6±1,5	9,7±1,4	12,6±1,2
14	88,2±1,1	86,3±1,1	90,2±1,5	90,7±1,5	9,8±1,5	13,7±1,1
15	88,5±0,8	87,0±1,0	90,2±1,1	90,6±1,1	9,8±1,1	13,0±1,0

Tabela 34. *Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasma odpowiadającego rytmowi α .*

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	81,0±2,6	77,0±3,3	87,1±1,9	89,1±2,4	12,9±1,9	23,0±3,3
2	82,9±4,3	78,7±4,8	89,2±2,0	90,9±2,0	10,8±2,0	21,3±4,8
3	85,9±4,2	82,0±4,9	91,6±1,6	92,7±1,7	8,4±1,6	18,0±4,9
4	86,9±4,4	82,7±5,0	93,1±1,9	94,2±1,2	6,9±1,9	17,3±5,0
5	87,7±2,8	83,4±3,6	93,5±1,3	94,3±1,2	6,5±1,3	16,6±3,6
6	91,5±1,5	88,8±1,7	94,8±1,6	95,1±1,5	5,2±1,6	11,2±1,7
7	91,9±1,4	89,9±1,6	94,1±1,2	94,4±1,2	5,9±1,2	10,1±1,6
8	91,7±1,1	89,3±1,7	94,5±1,2	94,8±1,1	5,5±1,2	10,7±1,7
9	92,6±1,1	90,5±1,2	94,9±1,3	95,1±1,3	5,1±1,3	9,5±1,2
10	91,3±1,9	88,4±3,0	94,9±1,2	95,3±1,2	5,1±1,2	11,6±3,0
11	92,0±1,6	89,4±2,1	95,0±1,5	95,4±1,4	5,0±1,5	10,6±2,1
12	92,9±1,3	90,4±1,6	95,8±1,4	96,1±1,3	4,2±1,4	9,6±1,6
13	91,6±1,6	89,1±2,2	94,4±1,1	94,8±1,0	5,6±1,1	10,9±2,2
14	92,6±1,5	90,2±2,2	95,3±0,7	95,6±0,7	4,7±0,7	9,8±2,2
15	92,5±1,2	90,1±1,7	95,3±0,8	95,5±0,8	4,7±0,8	9,9±1,7

Tabela 35. Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasma odpowiadającego rytmowi β .

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	88,1±4,3	87,1±7,0	89,6±1,7	90,1±1,4	10,4±1,7	12,9±7,0
2	92,7±2,9	90,7±4,3	95,1±1,6	95,4±1,4	4,9±1,6	9,3±4,3
3	90,3±2,7	85,9±3,8	96,2±0,9	96,6±0,9	3,8±0,9	14,1±3,8
4	93,1±2,5	90,8±3,9	95,8±1,0	96,1±0,9	4,2±1,0	9,2±3,9
5	94,8±1,9	93,3±3,0	96,4±0,7	96,5±0,7	3,6±0,7	6,7±3,0
6	95,0±2,1	93,3±3,3	96,9±0,9	97,1±0,8	3,1±0,9	6,7±3,3
7	95,3±1,9	93,3±3,0	97,5±0,6	97,6±0,5	2,5±0,6	6,7±3,0
8	95,4±2,0	93,7±3,2	97,2±0,7	97,4±0,6	2,8±0,7	6,3±3,2
9	96,1±1,8	95,1±2,8	97,3±0,7	97,4±0,7	2,7±0,7	4,9±2,8
10	96,2±1,5	95,0±2,4	97,5±0,6	97,5±0,6	2,5±0,6	5,0±2,4
11	96,0±1,6	94,3±2,3	97,9±1,0	98,0±1,0	2,1±1,0	5,7±2,3
12	96,5±1,7	95,2±2,8	97,8±0,6	97,9±0,6	2,2±0,6	4,8±2,8
13	97,0±1,5	95,9±2,5	98,2±0,4	98,3±0,3	1,8±0,4	4,1±2,5
14	97,0±1,6	95,9±2,4	98,2±0,8	98,2±0,7	1,8±0,8	4,1±2,4
15	97,1±1,5	95,9±2,3	98,3±0,6	98,4±0,6	1,7±0,6	4,1±2,3

Tabela 36. Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasma odpowiadającego rytmowi γ .

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	77,6±6,9	73,9±9,3	83,9±3,2	87,3±2,2	16,1±3,2	26,1±9,3
2	81,8±4,7	77,8±6,3	87,7±2,3	89,8±1,6	12,3±2,3	22,2±6,3
3	80,8±2,1	75,8±2,6	88,5±1,8	90,8±1,8	11,5±1,8	24,2±2,6
4	86,4±3,4	83,3±4,6	90,3±1,9	91,3±1,6	9,7±1,9	16,7±4,6
5	88,0±2,9	85,0±4,5	91,7±0,9	92,5±0,6	8,3±0,9	15,0±4,5
6	88,6±2,8	85,2±4,2	92,9±1,3	93,6±0,9	7,1±1,3	14,8±4,2
7	87,5±3,3	83,9±4,4	92,2±1,8	93,2±1,4	7,8±1,8	16,1±4,4
8	88,5±2,1	85,5±2,9	92,1±1,2	92,8±1,0	7,9±1,2	14,5±2,9
9	89,5±2,5	87,1±3,8	92,3±1,1	92,9±0,9	7,7±1,1	12,9±3,8
10	89,0±1,9	86,2±2,8	92,4±0,7	93,0±0,5	7,6±0,7	13,8±2,8
11	89,3±3,2	86,5±4,4	92,7±1,7	93,4±1,4	7,3±1,7	13,5±4,4
12	91,2±2,8	89,9±4,3	92,8±1,3	93,1±1,0	7,2±1,3	10,1±4,3
13	91,0±2,6	89,3±3,7	93,0±1,3	93,4±1,1	7,0±1,3	10,7±3,7
14	90,9±1,8	89,0±2,7	93,1±0,9	93,5±0,8	6,9±0,9	11,0±2,7
15	91,7±2,0	90,1±3,1	93,4±0,8	93,7±0,6	6,6±0,8	9,9±3,1

Tabela 37. *Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasz odpowiadających rytmom $\alpha+\beta$.*

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	88,8±4,1	87,2±6,4	90,8±1,7	91,4±1,2	9,2±1,7	12,8±6,4
2	94,0±2,3	92,2±3,3	96,1±1,3	96,3±1,2	3,9±1,3	7,8±3,3
3	90,9±3,0	87,3±4,3	95,6±1,0	96,1±1,0	4,4±1,0	12,7±4,3
4	93,7±1,8	91,0±3,1	97,0±1,1	97,2±1,0	3,0±1,1	9,0±3,1
5	95,7±1,7	94,7±2,7	96,9±0,9	97,0±0,8	3,1±0,9	5,3±2,7
6	95,7±1,6	93,8±2,7	97,9±0,5	98,0±0,5	2,1±0,5	6,2±2,7
7	95,8±1,8	93,8±2,9	98,1±0,5	98,2±0,5	1,9±0,5	6,2±2,9
8	96,7±1,7	95,5±2,7	98,1±0,6	98,1±0,5	1,9±0,6	4,5±2,7
9	97,0±1,6	95,9±2,6	98,1±0,7	98,2±0,6	1,9±0,7	4,1±2,6
10	97,3±1,3	96,0±2,0	98,6±0,6	98,6±0,6	1,4±0,6	4,0±2,0
11	97,2±1,5	95,7±2,3	98,8±0,7	98,9±0,7	1,2±0,7	4,3±2,3
12	97,4±1,6	96,1±2,8	98,8±0,4	98,8±0,4	1,2±0,4	3,9±2,8
13	97,1±1,7	95,6±2,9	98,8±0,4	98,8±0,4	1,2±0,4	4,4±2,9
14	97,5±1,3	96,3±2,2	98,8±0,4	98,9±0,4	1,2±0,4	3,7±2,2
15	97,4±1,5	95,9±2,5	99,0±0,5	99,1±0,5	1,0±0,5	4,1±2,5

Tabela 38. *Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasz odpowiadających rytmom $\beta+\gamma$.*

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	86,8±4,7	84,2±7,4	90,5±1,4	91,5±0,9	9,5±1,4	15,8±7,4
2	91,3±2,9	88,7±4,6	94,5±1,2	94,9±1,0	5,5±1,2	11,3±4,6
3	89,5±3,0	84,5±4,1	96,6±1,0	97,1±0,9	3,4±1,0	15,5±4,1
4	93,5±2,7	90,6±4,5	97,2±0,6	97,4±0,5	2,8±0,6	9,4±4,5
5	95,4±1,7	94,0±2,9	97,0±0,4	97,1±0,3	3,0±0,4	6,0±2,9
6	95,5±1,8	93,4±2,9	97,9±0,7	98,1±0,6	2,1±0,7	6,6±2,9
7	95,7±2,0	93,6±3,4	98,1±0,4	98,2±0,3	1,9±0,4	6,4±3,4
8	96,3±1,3	94,6±2,0	98,1±0,7	98,1±0,7	1,9±0,7	5,4±2,0
9	96,4±1,8	94,9±2,8	98,0±0,6	98,1±0,5	2,0±0,6	5,1±2,8
10	96,6±1,3	94,9±2,2	98,4±0,4	98,5±0,4	1,6±0,4	5,1±2,2
11	96,3±1,6	94,4±2,7	98,3±0,5	98,4±0,5	1,7±0,5	5,6±2,7
12	96,9±1,7	95,6±2,7	98,3±0,6	98,4±0,5	1,7±0,6	4,4±2,7
13	97,3±1,6	95,8±2,5	99,0±0,6	99,0±0,6	1,0±0,6	4,2±2,5
14	97,6±1,3	96,6±2,3	98,6±0,4	98,7±0,4	1,4±0,4	3,4±2,3
15	97,4±1,2	96,1±1,9	98,8±0,5	98,8±0,4	1,2±0,5	3,9±1,9

Tabela 39. Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasem odpowiadających rytmom $\alpha+\beta+\gamma$.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	89,4±4,6	87,8±7,6	91,7±1,3	92,3±0,9	8,3±1,3	12,2±7,6
2	92,7±2,5	90,2±4,0	95,8±0,8	96,1±0,7	4,2±0,8	9,8±4,0
3	90,3±3,3	85,6±4,4	97,0±0,9	97,4±0,8	3,0±0,9	14,4±4,4
4	94,3±2,0	91,4±3,1	97,9±0,6	98,0±0,5	2,1±0,6	8,6±3,1
5	95,8±1,9	94,2±3,2	97,7±0,5	97,8±0,5	2,3±0,5	5,8±3,2
6	96,3±1,5	94,2±2,5	98,6±0,5	98,6±0,4	1,4±0,5	5,8±2,5
7	96,2±1,8	94,2±3,0	98,4±0,6	98,5±0,5	1,6±0,6	5,8±3,0
8	96,9±1,3	95,7±2,3	98,3±0,4	98,4±0,4	1,7±0,4	4,3±2,3
9	97,0±1,5	95,5±2,5	98,7±0,5	98,8±0,5	1,3±0,5	4,5±2,5
10	97,1±1,0	95,9±1,8	98,5±0,3	98,6±0,3	1,5±0,3	4,1±1,8
11	96,9±1,4	95,2±2,4	98,7±0,3	98,8±0,3	1,3±0,3	4,8±2,4
12	97,5±1,6	96,2±2,7	98,8±0,3	98,9±0,3	1,2±0,3	3,8±2,7
13	97,2±1,5	95,8±2,6	98,8±0,3	98,9±0,3	1,2±0,3	4,2±2,6
14	97,4±1,5	96,0±2,6	99,1±0,3	99,1±0,3	0,9±0,3	4,0±2,6
15	97,3±1,2	96,0±2,3	98,7±0,2	98,7±0,2	1,3±0,2	4,0±2,3

Tabela 40. Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasem odpowiadających rytmom $\delta+\alpha+\beta+\gamma$.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	88,0±4,7	84,9±7,6	92,6±0,9	93,4±0,6	7,4±0,9	15,1±7,6
2	91,9±3,0	88,4±4,5	96,4±1,3	96,8±1,1	3,6±1,3	11,6±4,5
3	90,9±2,9	86,7±4,0	96,6±0,8	97,0±0,8	3,4±0,8	13,3±4,0
4	95,3±2,5	93,2±4,1	97,7±0,6	97,9±0,6	2,3±0,6	6,8±4,1
5	95,4±2,1	93,0±3,5	98,1±0,4	98,2±0,3	1,9±0,4	7,0±3,5
6	96,0±1,3	93,7±2,2	98,5±0,2	98,6±0,2	1,5±0,2	6,3±2,2
7	96,4±1,6	94,3±2,7	98,7±0,4	98,7±0,3	1,3±0,4	5,7±2,7
8	96,8±1,5	95,4±2,7	98,4±0,3	98,4±0,2	1,6±0,3	4,6±2,7
9	97,1±1,3	95,7±2,2	98,5±0,4	98,6±0,4	1,5±0,4	4,3±2,2
10	97,4±1,0	96,0±1,7	98,8±0,3	98,8±0,3	1,2±0,3	4,0±1,7
11	97,3±1,5	95,7±2,6	99,0±0,4	99,1±0,3	1,0±0,4	4,3±2,6
12	97,4±1,6	95,9±2,9	99,1±0,2	99,2±0,2	0,9±0,2	4,1±2,9
13	97,5±1,3	95,9±2,4	99,2±0,2	99,2±0,2	0,8±0,2	4,1±2,4
14	97,4±1,5	96,0±2,7	99,0±0,3	99,0±0,3	1,0±0,3	4,0±2,7
15	97,8±1,1	96,7±2,1	99,0±0,1	99,0±0,1	1,0±0,1	3,3±2,1

Tabela 41. Uśrednione wartości miar jakości klasyfikacji w zależności od liczby sesji treningowych EEG osoby weryfikowanej oraz ich odchylenia standardowe dla podpasm odpowiadających rytmom $\theta+\alpha+\beta+\gamma$.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	89,9±4,7	87,5±7,2	93,3±1,5	93,9±1,1	6,7±1,5	12,5±7,2
2	92,4±2,5	89,7±3,6	95,7±1,5	96,0±1,4	4,3±1,5	10,3±3,6
3	90,4±3,7	85,7±4,8	97,3±0,8	97,7±0,8	2,7±0,8	14,3±4,8
4	94,9±1,9	92,6±3,2	97,5±0,7	97,7±0,6	2,5±0,7	7,4±3,2
5	96,0±1,5	94,1±2,6	98,1±0,4	98,2±0,3	1,9±0,4	5,9±2,6
6	96,2±1,3	94,5±2,4	98,2±0,2	98,3±0,2	1,8±0,2	5,5±2,4
7	96,6±1,4	94,8±2,4	98,7±0,3	98,7±0,3	1,3±0,3	5,2±2,4
8	97,0±1,3	95,9±2,4	98,3±0,3	98,3±0,2	1,7±0,3	4,1±2,4
9	97,3±1,4	96,1±2,3	98,6±0,5	98,6±0,5	1,4±0,5	3,9±2,3
10	97,1±0,9	95,7±1,7	98,6±0,3	98,6±0,3	1,4±0,3	4,3±1,7
11	97,6±1,2	96,3±2,1	98,9±0,4	98,9±0,4	1,1±0,4	3,7±2,1
12	97,5±1,5	96,2±2,6	99,0±0,3	99,0±0,2	1,0±0,3	3,8±2,6
13	97,6±1,5	96,2±2,5	99,1±0,4	99,2±0,4	0,9±0,4	3,8±2,5
14	97,7±1,4	96,4±2,5	99,1±0,3	99,1±0,3	0,9±0,3	3,6±2,5
15	97,5±1,2	96,2±2,3	98,9±0,2	98,9±0,2	1,1±0,2	3,8±2,3

Dodatek C. Uśrednione wartości miar jakości klasyfikacji dla różnych zestawów elektrod i podpasów sygnału EEG

Dodatek stanowi uzupełnienie punktu 5.5.1, w którym analizowano wpływ liczby sesji pomiarowych sygnału EEG osoby weryfikowanej użytych do treningu klasyfikatora na miary jakości klasyfikacji. Rysunki 60-63 i tabele 42-45 są odpowiednikami rysunków 48-51 i tabel 15-18 dla 15 sesji pomiarowych sygnału EEG osoby weryfikowanej użytych do treningu klasyfikatora i 5 sesji testowych.

Tabela 42. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu 19 elektrod.

Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	89,7±4,3	86,9±6,6	93,6±1,3	94,3±0,9	6,4±1,3	13,1±6,6
2	92,4±2,9	89,9±4,6	95,5±1,1	95,8±1,0	4,5±1,1	10,1±4,6
3	91,5±3,1	87,4±4,3	97,0±0,9	97,3±0,8	3,0±0,9	12,6±4,3
4	94,9±1,9	92,6±3,0	97,6±0,9	97,7±0,8	2,4±0,9	7,4±3,0
5	95,4±1,8	93,0±2,9	98,2±0,4	98,3±0,3	1,8±0,4	7,0±2,9
6	95,7±1,3	93,3±2,2	98,3±0,4	98,4±0,3	1,7±0,4	6,7±2,2
7	96,7±1,6	94,7±2,7	98,9±0,3	99,0±0,3	1,1±0,3	5,3±2,7
8	96,7±1,5	94,9±2,7	98,7±0,3	98,8±0,3	1,3±0,3	5,1±2,7
9	97,4±1,3	96,3±2,2	98,6±0,3	98,7±0,3	1,4±0,3	3,7±2,2
10	97,2±0,9	96,0±1,7	98,5±0,3	98,5±0,3	1,5±0,3	4,0±1,7
11	97,7±1,2	96,6±2,1	99,0±0,3	99,0±0,3	1,0±0,3	3,4±2,1
12	97,6±1,5	96,2±2,6	99,2±0,3	99,3±0,3	0,8±0,3	3,8±2,6
13	97,6±1,3	96,1±2,3	99,2±0,3	99,2±0,2	0,8±0,3	3,9±2,3
14	97,8±1,1	96,4±2,0	99,2±0,2	99,2±0,2	0,8±0,2	3,6±2,0
15	97,8±1,0	96,6±1,9	99,0±0,2	99,1±0,2	1,0±0,2	3,4±1,9

Tabela 43. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu 19 elektrod.



Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	88,8±4,1	87,2±6,4	90,8±1,7	91,4±1,2	9,2±1,7	12,8±6,4
2	94,0±2,3	92,2±3,3	96,1±1,3	96,3±1,2	3,9±1,3	7,8±3,3
3	90,9±3,0	87,3±4,3	95,6±1,0	96,1±1,0	4,4±1,0	12,7±4,3
4	93,7±1,8	91,0±3,1	97,0±1,1	97,2±1,0	3,0±1,1	9,0±3,1
5	95,7±1,7	94,7±2,7	96,9±0,9	97,0±0,8	3,1±0,9	5,3±2,7
6	95,7±1,6	93,8±2,7	97,9±0,5	98,0±0,5	2,1±0,5	6,2±2,7
7	95,8±1,8	93,8±2,9	98,1±0,5	98,2±0,5	1,9±0,5	6,2±2,9
8	96,7±1,7	95,5±2,7	98,1±0,6	98,1±0,5	1,9±0,6	4,5±2,7
9	97,0±1,6	95,9±2,6	98,1±0,7	98,2±0,6	1,9±0,7	4,1±2,6
10	97,3±1,3	96,0±2,0	98,6±0,6	98,6±0,6	1,4±0,6	4,0±2,0
11	97,2±1,5	95,7±2,3	98,8±0,7	98,9±0,7	1,2±0,7	4,3±2,3
12	97,4±1,6	96,1±2,8	98,8±0,4	98,8±0,4	1,2±0,4	3,9±2,8
13	97,1±1,7	95,6±2,9	98,8±0,4	98,8±0,4	1,2±0,4	4,4±2,9
14	97,5±1,3	96,3±2,2	98,8±0,4	98,9±0,4	1,2±0,4	3,7±2,2
15	97,4±1,5	95,9±2,5	99,0±0,5	99,1±0,5	1,0±0,5	4,1±2,5

Tabela 44. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.



Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	84,4±3,0	81,1±4,3	88,9±1,8	90,2±1,5	11,1±1,8	18,9±4,3
2	88,8±2,5	85,3±3,2	93,1±1,8	93,8±1,5	6,9±1,8	14,7±3,2
3	91,6±2,3	88,5±3,3	95,4±1,5	95,8±1,4	4,6±1,5	11,5±3,3
4	92,4±2,1	89,8±2,8	95,5±1,6	95,8±1,4	4,5±1,6	10,2±2,8
5	92,7±2,1	90,5±2,9	95,2±1,4	95,4±1,3	4,8±1,4	9,5±2,9
6	93,8±1,5	91,7±2,3	96,2±1,5	96,3±1,4	3,8±1,5	8,3±2,3
7	93,6±1,2	90,9±1,5	96,8±1,2	97,0±1,2	3,2±1,2	9,1±1,5
8	94,1±1,3	92,6±1,7	95,7±0,9	95,8±0,8	4,3±0,9	7,4±1,7
9	95,3±0,9	94,4±1,0	96,3±1,0	96,4±1,0	3,7±1,0	5,6±1,0
10	95,6±1,2	94,5±1,5	96,9±1,1	96,9±1,0	3,1±1,1	5,5±1,5
11	96,4±1,5	95,8±2,3	97,0±0,8	97,1±0,8	3,0±0,8	4,2±2,3
12	96,1±1,2	94,7±1,7	97,6±0,9	97,7±0,9	2,4±0,9	5,3±1,7
13	95,6±1,2	94,3±1,8	97,1±0,6	97,2±0,6	2,9±0,6	5,7±1,8
14	96,6±0,7	95,7±0,9	97,4±0,6	97,5±0,6	2,6±0,6	4,3±0,9
15	96,0±1,1	95,2±1,6	96,8±0,8	96,9±0,7	3,2±0,8	4,8±1,6

Tabela 45. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.



Liczba sesji	Miara jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	85,6±3,4	85,0±4,8	86,4±2,1	86,8±1,6	13,6±2,1	15,0±4,8
2	91,5±2,7	91,1±3,7	91,9±1,9	92,0±1,8	8,1±1,9	8,9±3,7
3	91,0±2,1	88,3±2,9	94,2±1,5	94,6±1,3	5,8±1,5	11,7±2,9
4	93,2±1,9	91,4±2,4	95,3±1,7	95,5±1,6	4,7±1,7	8,6±2,4
5	92,9±1,6	91,0±2,0	95,0±1,4	95,3±1,3	5,0±1,4	9,0±2,0
6	94,0±1,6	92,6±2,3	95,5±1,3	95,7±1,3	4,5±1,3	7,4±2,3
7	93,5±1,1	91,3±1,5	95,9±1,3	96,1±1,2	4,1±1,3	8,7±1,5
8	94,3±1,4	93,1±1,7	95,5±1,4	95,7±1,3	4,5±1,4	6,9±1,7
9	95,2±1,8	94,1±2,2	96,4±1,5	96,5±1,4	3,6±1,5	5,9±2,2
10	95,2±1,5	94,1±1,7	96,4±1,3	96,5±1,2	3,6±1,3	5,9±1,7
11	95,2±2,0	94,3±2,7	96,3±1,2	96,4±1,2	3,7±1,2	5,7±2,7
12	95,4±1,4	94,0±2,0	96,8±0,9	97,0±0,9	3,2±0,9	6,0±2,0
13	95,3±1,1	94,2±1,3	96,6±1,1	96,7±1,1	3,4±1,1	5,8±1,3
14	95,8±1,1	94,9±1,2	96,7±1,2	96,8±1,2	3,3±1,2	5,1±1,2
15	95,3±1,3	94,4±1,7	96,3±0,9	96,4±0,9	3,7±0,9	5,6±1,7





Rysunek 60. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu 19 elektrod.



Rysunek 61. *Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla podpasem odpowiadających rytmom $\alpha+\beta$ i zestawu 19 elektrod.*



Rysunek 62. *Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.*



Rysunek 63. *Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla podpasem odpowiadających rytmom $\alpha+\beta$ i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.*

Dodatek D. Uśrednione wartości miar jakości klasyfikacji dla sparametryzowanych cech podpasm widma sygnału EEG

Dodatek stanowi uzupełnienie punktu 5.8, w którym zamieszczono wyniki weryfikacji tożsamości osób dla sparametryzowanych cech podpasm widma sygnału EEG. Tabele 46-49 są liczbowym przedstawieniem wyników pokazanych na rysunkach 52-55, gdzie do weryfikacji używano 5 sesji testowych i liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki zamieszczone w tabelach 50-53 odpowiadają rysunkom 56-59 i zostały uzyskane dla 11 sesji testowych i liczby sesji treningowych zmieniającej się w zakresie od 1 do 9.

Tabela 46. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu 19 elektrod.

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	83,1±5,1	77,3±6,7	93,2±1,4	94,9±0,8	6,8±1,4	22,7±6,7
2	89,2±4,5	85,4±6,8	94,5±1,2	95,3±0,9	5,5±1,2	14,6±6,8
3	90,2±2,5	85,6±3,5	96,4±0,8	96,9±0,6	3,6±0,8	14,4±3,5
4	92,5±3,0	89,0±4,3	96,8±1,2	97,2±1,0	3,2±1,2	11,0±4,3
5	93,4±2,5	91,0±3,7	96,4±1,0	96,6±0,9	3,6±1,0	9,0±3,7
6	94,7±1,8	92,6±2,8	97,0±0,6	97,2±0,5	3,0±0,6	7,4±2,8
7	94,9±2,1	92,4±3,3	97,8±0,7	97,9±0,6	2,2±0,7	7,6±3,3
8	95,1±2,1	93,0±3,4	97,5±0,6	97,6±0,5	2,5±0,6	7,0±3,4
9	95,0±2,0	92,8±3,0	97,6±0,7	97,8±0,6	2,4±0,7	7,2±3,0
10	95,7±1,5	93,8±2,6	97,7±0,5	97,8±0,4	2,3±0,5	6,2±2,6
11	95,9±1,9	94,1±3,0	98,0±0,6	98,1±0,5	2,0±0,6	5,9±3,0
12	96,1±1,7	94,4±2,6	98,1±0,6	98,2±0,5	1,9±0,6	5,6±2,6
13	96,1±1,7	94,0±2,7	98,4±0,5	98,5±0,5	1,6±0,5	6,0±2,7
14	96,3±1,5	94,7±2,6	98,2±0,5	98,3±0,4	1,8±0,5	5,3±2,6
15	96,6±1,5	94,9±2,3	98,4±0,6	98,5±0,5	1,6±0,6	5,1±2,3

Tabela 47. *Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu 19 elektrod.*

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	82,0±4,4	77,6±6,2	88,7±1,7	90,8±0,9	11,3±1,7	22,4±6,2
2	87,3±4,4	83,8±5,8	91,8±2,4	92,9±1,9	8,2±2,4	16,2±5,8
3	89,8±3,1	86,1±4,1	94,7±1,7	95,3±1,4	5,3±1,7	13,9±4,1
4	91,8±2,9	89,1±3,8	94,9±1,7	95,3±1,5	5,1±1,7	10,9±3,8
5	92,3±2,6	89,7±3,3	95,2±1,7	95,5±1,6	4,8±1,7	10,3±3,3
6	93,6±2,4	91,2±3,3	96,4±1,3	96,7±1,1	3,6±1,3	8,8±3,3
7	94,0±2,5	91,9±3,6	96,4±1,2	96,6±1,1	3,6±1,2	8,1±3,6
8	93,7±2,9	91,6±4,5	96,3±1,2	96,5±1,1	3,7±1,2	8,4±4,5
9	94,4±2,3	92,3±3,3	96,9±1,1	97,1±1,0	3,1±1,1	7,7±3,3
10	94,9±2,3	93,1±3,4	97,0±1,0	97,1±0,9	3,0±1,0	6,9±3,4
11	95,4±2,2	93,8±3,0	97,1±1,2	97,3±1,1	2,9±1,2	6,2±3,0
12	95,2±1,9	93,4±3,1	97,2±0,6	97,4±0,5	2,8±0,6	6,6±3,1
13	95,4±2,0	93,5±3,0	97,5±0,8	97,6±0,8	2,5±0,8	6,5±3,0
14	95,3±2,0	93,8±3,0	97,1±0,8	97,2±0,7	2,9±0,8	6,2±3,0
15	95,6±2,0	93,8±2,9	97,6±1,0	97,7±1,0	2,4±1,0	6,2±2,9

Tabela 48. *Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.*

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	74,6±2,0	69,4±2,2	83,8±1,2	88,3±0,8	16,2±1,2	30,6±2,2
2	83,0±2,5	78,1±3,1	90,4±1,6	92,1±1,6	9,6±1,6	21,9±3,1
3	86,3±2,2	81,9±2,5	92,2±1,4	93,3±1,0	7,8±1,4	18,1±2,5
4	87,5±2,0	83,9±2,5	92,1±1,4	93,0±1,2	7,9±1,4	16,1±2,5
5	88,4±1,5	84,7±2,0	93,2±1,2	93,9±1,2	6,8±1,2	15,3±2,0
6	89,4±1,4	85,4±1,8	94,5±1,2	95,1±1,1	5,5±1,2	14,6±1,8
7	89,5±1,7	85,9±2,1	93,9±1,3	94,5±1,2	6,1±1,3	14,1±2,1
8	91,3±1,7	88,4±2,4	94,7±0,9	95,1±0,8	5,3±0,9	11,6±2,4
9	91,6±1,7	89,6±2,1	93,8±1,3	94,2±1,2	6,2±1,3	10,4±2,1
10	92,3±1,7	89,8±2,0	95,1±1,5	95,4±1,4	4,9±1,5	10,2±2,0
11	92,2±1,8	89,5±2,4	95,3±1,5	95,6±1,4	4,7±1,5	10,5±2,4
12	92,3±1,3	90,6±1,6	94,3±1,1	94,5±1,0	5,7±1,1	9,4±1,6
13	92,8±1,6	90,8±2,0	95,0±1,2	95,3±1,1	5,0±1,2	9,2±2,0
14	93,2±1,7	91,2±2,1	95,3±1,4	95,6±1,3	4,7±1,4	8,8±2,1
15	93,0±1,5	91,3±1,6	94,8±1,4	95,0±1,3	5,2±1,4	8,7±1,6

Tabela 49. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 5 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 15. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	72,0±3,6	68,2±3,0	78,0±4,6	82,6±3,6	22,0±4,6	31,8±3,0
2	79,8±3,5	75,9±3,7	85,2±2,9	87,6±1,7	14,8±2,9	24,1±3,7
3	83,2±2,4	79,7±3,1	87,9±1,9	89,3±2,0	12,1±1,9	20,3±3,1
4	84,5±1,7	81,2±2,0	88,6±1,6	89,8±1,4	11,4±1,6	18,8±2,0
5	86,9±2,4	84,5±2,6	89,7±2,1	90,5±1,8	10,3±2,1	15,5±2,6
6	87,8±2,5	84,7±3,0	91,5±2,3	92,3±2,1	8,5±2,3	15,3±3,0
7	88,2±2,2	86,0±2,7	90,6±1,7	91,2±1,4	9,4±1,7	14,0±2,7
8	88,4±2,3	85,8±3,0	91,4±1,6	92,0±1,3	8,6±1,6	14,2±3,0
9	88,3±1,9	86,4±2,1	90,4±1,8	90,9±1,7	9,6±1,8	13,6±2,1
10	89,5±2,1	87,8±2,6	91,4±1,7	91,8±1,6	8,6±1,7	12,2±2,6
11	90,0±2,3	88,5±3,0	91,6±1,7	92,0±1,5	8,4±1,7	11,5±3,0
12	90,7±2,2	89,4±2,7	92,3±1,7	92,6±1,5	7,7±1,7	10,6±2,7
13	90,9±2,2	89,2±2,6	92,8±2,0	93,1±1,9	7,2±2,0	10,8±2,6
14	91,1±2,4	90,1±2,9	92,2±1,8	92,5±1,7	7,8±1,8	9,9±2,9
15	91,3±2,2	90,6±2,4	92,0±2,0	92,1±2,0	8,0±2,0	9,4±2,4

Tabela 50. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu 19 elektrod.

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	83,7±5,1	78,4±7,2	92,7±1,0	94,4±0,5	7,3±1,0	21,6±7,2
2	89,6±3,6	85,6±5,1	95,0±1,3	95,7±1,0	5,0±1,3	14,4±5,1
3	91,0±2,4	86,7±3,2	96,6±1,2	97,0±1,0	3,4±1,2	13,3±3,2
4	93,1±2,6	90,3±3,5	96,4±1,3	96,7±1,2	3,6±1,3	9,7±3,5
5	93,9±1,8	91,3±2,4	97,0±0,9	97,2±0,8	3,0±0,9	8,7±2,4
6	94,9±1,6	93,0±2,2	97,1±1,0	97,2±0,9	2,9±1,0	7,0±2,2
7	94,8±2,0	92,4±2,9	97,5±0,8	97,6±0,7	2,5±0,8	7,6±2,9
8	95,1±2,0	92,8±3,0	97,6±0,7	97,8±0,6	2,4±0,7	7,2±3,0
9	95,7±1,5	93,8±2,1	97,9±0,7	98,0±0,7	2,1±0,7	6,2±2,1

Tabela 51. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu 19 elektrod.

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	82,5±4,6	78,3±6,3	88,8±2,3	90,7±1,4	11,2±2,3	21,7±6,3
2	87,3±3,5	83,8±4,7	91,8±1,7	92,8±1,3	8,2±1,7	16,2±4,7
3	89,8±2,8	86,3±3,6	94,2±1,7	94,8±1,4	5,8±1,7	13,7±3,6
4	91,6±2,3	89,0±3,0	94,6±1,5	95,0±1,3	5,4±1,5	11,0±3,0
5	92,7±2,4	90,5±3,1	95,2±1,7	95,5±1,6	4,8±1,7	9,5±3,1
6	93,1±2,5	91,0±3,3	95,5±1,6	95,8±1,4	4,5±1,6	9,0±3,3
7	93,2±1,9	91,1±2,5	95,5±1,2	95,7±1,1	4,5±1,2	8,9±2,5
8	93,8±2,4	91,8±3,3	96,1±1,4	96,3±1,3	3,9±1,4	8,2±3,3
9	94,0±1,6	91,6±2,1	96,8±1,1	97,0±1,0	3,2±1,1	8,4±2,1

Tabela 52. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla całego rozpatrywanego pasma sygnału EEG i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	74,8±1,8	69,0±1,9	85,7±1,0	90,1±0,7	14,3±1,0	31,0±1,9
2	82,4±2,7	78,3±3,1	88,1±1,5	89,9±0,9	11,9±1,5	21,7±3,1
3	85,1±2,1	80,5±2,5	91,6±1,4	92,9±1,2	8,4±1,4	19,5±2,5
4	88,0±1,5	84,4±1,9	92,5±1,0	93,3±0,9	7,5±1,0	15,6±1,9
5	89,6±1,2	86,3±1,6	93,7±1,2	94,3±1,1	6,3±1,2	13,7±1,6
6	90,6±1,4	87,4±2,0	94,5±1,5	94,9±1,4	5,5±1,5	12,6±2,0
7	90,7±1,2	88,0±1,4	93,9±1,1	94,3±1,0	6,1±1,1	12,0±1,4
8	91,4±1,4	89,2±2,1	94,0±0,5	94,4±0,4	6,0±0,5	10,8±2,1
9	92,0±1,0	90,0±1,4	94,2±0,6	94,5±0,6	5,8±0,6	10,0±1,4

Tabela 53. Uśrednione wartości miar jakości klasyfikacji i ich odchylenia standardowe dla 11 sesji testowych w zależności od liczby sesji treningowych zmieniającej się w zakresie od 1 do 9. Wyniki dla podpasm odpowiadających rytmom $\alpha+\beta$ i zestawu ośmiu elektrod C3C4P3P4O1O2T5T6.

Liczba sesji	Miary jakości klasyfikacji [%]					
	ACC	SEN	SPEC	PREC	FAR	FRR
1	74,0±2,5	70,0±2,4	80,1±2,7	84,2±1,8	19,9±2,7	30,0±2,4
2	79,0±3,0	75,0±3,5	84,7±2,2	87,3±1,3	15,3±2,2	25,0±3,5
3	81,9±2,1	77,8±2,4	87,3±1,6	89,2±1,1	12,7±1,6	22,2±2,4
4	85,4±1,2	82,5±1,7	88,8±1,1	89,7±1,2	11,2±1,1	17,5±1,7
5	87,5±1,9	84,9±2,2	90,6±1,5	91,3±1,3	9,4±1,5	15,1±2,2
6	87,6±1,5	85,3±2,1	90,4±0,9	91,0±0,8	9,6±0,9	14,7±2,1
7	88,6±1,6	86,4±1,8	91,2±1,4	91,7±1,3	8,8±1,4	13,6±1,8
8	88,4±1,7	86,4±2,2	90,8±1,2	91,3±1,1	9,2±1,2	13,6±2,2
9	89,3±1,6	87,4±1,8	91,4±1,4	91,9±1,3	8,6±1,4	12,6±1,8