

## RECENZJA ROZPRAWY DOKTORSKIEJ

mgr inż. Moniki Prucnal

pt.

„Metody analizy sygnału EEG ukierunkowane na wykrywanie bezdechu sennego”

### 1. Zagadnienia formalne

Niniejsza recenzja została opracowana na podstawie zlecenia (pismo nr RDN-AEE/109/2021 z dnia 13.07.2021 roku) wystawionego przez Przewodniczącego Rady Dyscypliny Naukowej Automatyka, Elektronika i Elektrotechnika, Politechniki Wrocławskiej, prof. dr hab. inż. Andrzeja Dziedzica. Ze zlecenia wynika, że przewód doktorski wszczęty został w dyscyplinie *Elektronika*, co aktualnie wg klasyfikacji określonej w rozporządzeniu MNiSW z dnia 20 września 2018 roku w sprawie dziedzin i dyscyplin naukowych oraz dyscyplin artystycznych (Dz. U. 2018, poz. 1818) odpowiada dyscyplinie *Automatyka, Elektronika i Elektrotechnika*. Na przynależność do tej dyscypliny wskazuje również zawartość przedstawionej do oceny rozprawy.

### 2. Wstęp i ocena tematyki rozprawy

Rozprawa dotyczy przetwarzania i analizy sygnału EEG ukierunkowanego na wykrywanie i klasyfikowanie zaburzeń snu związanych z tzw. bezdechem sennym. Praca bardzo ściśle koncentruje się na przetwarzaniu jedynie jednokanałowego sygnału EGG pozyskanego w trakcie rejestracji wielu różnych sygnałów, zwanej polisomnografią. W trakcie takiej rejestracji pozyskuje się również sygnały związane z EKG, EMG, EOG, saturacją krwi tlenem, przepływem powietrza w drogach oddechowych, ruchami klatki piersiowej, dźwiękami oddechowymi itp. Badanie takie jest złożoną procedurą trwającą co najmniej kilka godzin (najczęściej całą noc), zwykle w warunkach wyspecjalizowanych laboratoriów i jest niezwykle kosztowne, ale mało wydajne w badaniach przesiewowych. Badania takie są niezwykle istotne, jak bowiem ocenia się, przypadłość zaburzeń snu może dotyczyć nawet 10 % społeczeństwa. Konsekwencją występowania bezdechu sennego (który w skrajnych przypadkach może występować nawet kilkadziesiąt razy w ciągu godziny) może być uczucie ciągłego zmęczenia, złe samopoczucie, choroby związane z układem krążenia, itp. Niesie to więc za sobą istotne społecznie problemy zdrowotne. Stąd dążenie do opracowania szybkiej, stosunkowo łatwej i taniej metody wykrywania i klasyfikacji tego typu schorzeń należy uznać za niezwykle istotne. Najlepiej gdyby takie badanie, traktowane jako przesiewowe, mogło odbywać się w warunkach domowych, a analiza sygnału i klasyfikacji ewentualnego schorzenia realizowana była w sposób automatyczny, bez udziału na tym etapie specjalistów.

Doktorantka zdecydowała się na wybór z całej grupy sygnałów polisomnograficznych sygnału EGG, który wcześniej wykorzystywany był głównie do detekcji faz snu. Pozostałe sygnały polisomnograficzne, jak również opisy specjalistów wykorzystane zostały do zweryfikowania poprawności i skuteczności opracowanej metody. Wybór sygnału EEG wynika z faktu, że istnieją aktualnie komercyjne urządzenia pozwalające na łatwą rejestrację tego sygnału w warunkach domowych, za pomocą przenośnych urządzeń (podobnie jak EKG za

WPLYNĘŁO

13.09.2021

RDU-AGE/138/2021

pomocą aparatu Holtera). Daje to szansę na spełnienie wymagania związanego z prowadzeniem efektywnych i szeroko zakrojonych badań przesiewowych. Z badań literaturowych wynika również, że istnieje tysiące prac dotyczących wykorzystania polisomnografii do detekcji bezdechu sennego. W tej grupie jednak tylko kilkadziesiąt prac dotyczyło wykrywania bezdechu jedynie z wykorzystaniem sygnału EEG i to w ograniczonym zakresie (bezdech, zwykle obturacyjny lub oddech normalny). Raportowana dokładność klasyfikacji takich stanów nie przekraczała 90%. Właśnie ta stosunkowo niska dokładność klasyfikacji i to tylko binarnej oraz niewielka liczba prac w tym zakresie stały się dla doktorantki motywacją do podjęcia badań związanych z analizą jednokanałowego sygnału EEG i klasyfikacji pozwalającej na rozróżnienie większej liczby stanów chorobowych (bezdech obturacyjny, bezdech centralny i mieszany). Dodatkową motywacją jest fakt, że poprawnie opracowana i skuteczna metodyka wykrywania bezdechu z sygnału EEG, który jest bardzo zasobny w informacje o stanie organizmu ludzkiego, może w przyszłości posłużyć do wykrywania innych stanów chorobowych (np. epilepsja czy różnego rodzaju nerwice). Przyjęto, że metodyka badań polegać będzie na szeregowym przetwarzaniu sygnału EEG, od przetwarzania wstępnego, poprzez ekstrakcję i selekcję cech do klasyfikacji i oceny jakości przyjętego modelu

**Autorka postawiła tezę, że „odpowiedni dobór metod przetwarzania jednokanałowego sygnału EEG na poszczególnych etapach: przetwarzania wstępnego, ekstrakcji i selekcji cech oraz uczenia maszynowego pozwoli na uzyskanie dokładności automatycznego rozróżniania między bezdechem sennym a normalnym oddychaniem oraz rozróżniania typu bezdechu większej niż uzyskano w dotychczasowych badaniach”.**

Teza ta została uzupełniona przez jasno sformułowany cel pracy tj. zaproponowanie procedury przetwarzania jednokanałowego sygnału EEG z zapisu całonocnego, która zmaksymalizuje dokładność zarówno automatycznego rozróżniania okresu bezdechu sennego od okresu normalnego oddychania, jak i różnicowanie typów bezdechu.

Uważam, że postawiona teza i określony cel są bardzo ambitne, w kontekście wybrania z badań polisomnograficznych tylko jednego sygnału. Badania mające udowodnić postawioną tezę wpisują się w aktualne badania dotyczące diagnozowania bezdechu sennego i są ich doskonałym uzupełnieniem. Zaproponowana metodyka badań jest poprawna, a uzyskane wyniki mogą być z powodzeniem wykorzystane do automatyzacji, a tym samym intensyfikacji i dostępności badań przesiewowych. Badania prowadzone w tym obszarze i uzyskane wyniki mogą być z powodzeniem podstawą do ubiegania się o stopień doktora nauk technicznych w dyscyplinie Elektronika (aktualnie Automatyka, Elektronika i Elektrotechnika).

### 3. Struktura rozprawy

Rozprawa napisana jest w języku polskim, liczy 234 strony, a jej treść została podzielona na 9 rozdziałów (z wyłączeniem bibliografii oraz obszernego spisu oznaczeń i stosowanych skrótów). Bibliografia zawiera alfabetyczny wykaz liczący 346 pozycji. Wykaz ten zawiera 4 pozycje, których Doktorantka jest współautorką. Literatura jest właściwie dobrana, poprawnie cytowana w pracy i stanowi doskonały przegląd tematu dysertacji z ostatnich kilkunastu lat.

W rozdziałach od pierwszego do czwartego Autorka przedstawia zagadnienia teoretyczne dotyczące problemu bezdechu sennego, jego rodzaje, potencjalne skutki, zagadnienia dotyczące sygnału EEG, metody jego rejestracji i możliwości wykorzystania w diagnostyce medycznej oraz przedstawia dostępne bazy danych takich sygnałów. W kolejnych rozdziałach oprócz wnikliwej analizy literaturowej, przedstawia także wyniki własnych badań i testów, porównując je z wynikami raportowanymi w literaturze.

W rozdziale pierwszym (Wstęp) Autorka przedstawiła podstawowe zagadnienia dotyczące problemu bezdechu sennego i jego konsekwencji, prowadzące do określenia motywacji, które skłoniły Ją do podjęcia tej tematyki. Opisała rodzaje możliwych typów bezdechu, częstość ich

występowania w populacji i skutki jakie niesie za sobą to schorzenie. Przedstawiła znane aktualnie metody diagnostyczne dotyczące bezdechu i stosowaną aparaturę. Pokazała również jak wyglądają aktualne badania bezdechu z wykorzystaniem EGG i uzasadniła dlaczego warto zająć się tą tematyką (bardzo mało doniesień o stosowaniu tylko EEG do klasyfikacji bezdechu i niskie dokładności przy klasyfikacji automatycznej tego schorzenia). Zaproponowała również metodykę prowadzenia badań w tym zakresie oraz sformułowała (przytoczone już wcześniej) cel i tezę pracy.

W rozdziale drugim Doktorantka przedstawia aktualny stan wiedzy na temat bezdechu sennego i stosowanych aktualnie metod jego wykrywania. Precyzyjnie opisuje syndrom bezdechu sennego i jego epidemiologię. Omawia znane aktualnie rodzaje bezdechu (obturacyjny, centralny, mieszany) i szczegółowo omawia każdy z nich, szczegółowo zaznaczając jakiej populacji dotyczy (płeć, wiek, otyłość, inne schorzenia towarzyszące lub sprzyjające bezdechowi, itp.) i jakie konsekwencje niesie dla pacjenta oraz jakie jest możliwe podłoże postawienia takiego schorzenia. Definiuje również współczynniki AI oraz AHI, na podstawie których podejmuje się decyzję o stawianej diagnozie i dalszym postępowaniu z pacjentem. Przedstawia znane aktualnie metody diagnostyczne (głównie polisomnografia) i związane z tym trudności techniczne, czasowe, finansowe, konieczność dostępu do ekspertów, a tym samym ograniczenia w możliwości przeprowadzenia szeroko zakrojonych badań przesiewowych. Biorąc pod uwagę powyższe, wskazuje na konieczność prowadzenia badań ukierunkowanych na uproszenie procedury badawczej (ograniczenie liczby rejestrowanych sygnałów, prosta, tania i przenośna aparatura pomiarowa) i automatyzację procesu diagnostycznego.

W rozdziale 3 Autorka przedstawia istotę sygnału EEG i aktualny stan wiedzy na temat pozyskiwania, analizy, niesionych przez niego informacji i wykorzystania tego sygnału w diagnozowaniu różnego rodzaju schorzeń. Omawia biofizyczne podstawy elektroencefalografii, powstawanie sygnału EEG, sposoby jego rejestracji, rozkład elektrod do rejestracji EEG, a także możliwe interpretacje tego sygnału. Opisuje występujące w sygnale fale mózgowo i zakresy częstotliwości w jakich się one lokują, a także niesione przez nie informacje i ich specyfikę dla różnych etapów aktywności i snu człowieka. Obszernie i klarownie wprowadza w zagadnienia zjawisk zachodzących w organizmie człowieka i ich powiązanie z sygnałem EEG (poszczególnymi jego frakcjami). Szczególnie odnosi się do zjawiska bezdechu sennego i sposobu ujawniania się różnych odmian tego zjawiska w poszczególnych falach EEG. Analizę sygnału EEG Autorka przedstawia jako przykład problemu odwrotnego. Dość szczegółowo analizuje mechanizmy wpływu bezdechu sennego na postać sygnału EEG. Na podstawie badań literaturowych wskazuje, że większość publikowanych prac koncentruje się na wpływie bezdechu obturacyjnego na EEG, a niewiele jest prac wiążących zmiany w sygnale EEG z bezdechem centralnym. Zagadnienia te wskazuje jako wymagające dalszej szczegółowej analizy. Doktorantka wskazuje również na podstawie badań literaturowych na dysproporcje w długości poszczególnych faz snu u osób zdrowych i osób z bezdechem, a także na zmiany średniej mocy sygnału EEG i zmiany częstotliwości w sygnale EEG po epizodzie bezdechu. Możliwa jest też analiza zmian energii poszczególnych fal sygnału EEG, którą można powiązać z wystąpieniem u pacjenta bezdechu. Wszystkie te techniki wskazuje jako te, które potencjalnie mogą być wykorzystane w dalszych badaniach do parametryzacji sygnału. W większości dostępnych prac wykrywanie bezdechu z wykorzystaniem sygnału EEG powiązane jest z jednoczesnym wykorzystaniem innych zarejestrowanych sygnałów biomedycznych. Niewiele natomiast jest dostępnych wyników badań bazujących jedynie na sygnale EEG. Badania takie pochodzą głównie z ostatnich lat i prowadzone były równocześnie z pracami Doktorantki. Autorka przedstawia techniki stosowane przez innych autorów do analizy sygnału EEG. W ramach przetwarzania wstępnego korzysta się często z usuwania trendu, normalizacji sygnału, i jego wstępnej filtracji (zwykle

filtracja pasmowoprzepustowa). Na tym etapie sygnał dzielony jest często na krótsze fragmenty poddawane analizie tzw. epoki. Na etapie ekstrakcji cech często wykorzystywane są metody statystyczne, czasowe i częstotliwościowe. Dzięki temu możliwe jest zbudowanie wektora cech o wymiarze znacznie mniejszym niż liczba próbek analizowanego sygnału, co ułatwia potem dalszą analizę. Ważne jest na tym etapie aby wybierać takie cechy, wyznaczanie których nie powoduje istotnej utraty informacji zawartej w sygnale wejściowym. Kolejny etap analizy to selekcja cech, tak aby zredukować wymiar wektora cech, a zachować te cechy, które są najbardziej zróżnicowane i niosą najwięcej informacji. Zwykle na tym etapie stosowane są metody takie jak analiza wariacji, PCA, ICA, metody regresji, minimalizacja redundancji itp. Klasyfikacja ma zaś na celu rozróżnienie epok, w których pojawił się epizod bezdechu od tych, w których oddychanie odbywało się normalnie. Zwykle na tym etapie wykorzystywane są metody tzw. inteligencji obliczeniowej. Na koniec następuje ocena jakości procesu klasyfikacji poprzez porównanie uzyskanych wyników z wynikami referencyjnymi ustalonymi zwykle przez eksperta w oparciu o wiele dostępnych informacji pozyskanych w procesie polisomnografii. Do oceny jakości klasyfikatora stosowane są zwykle takie wskaźniki jak: dokładność, czułość i swoistość. Szkoda, że Autorka nie omówiła dokładnie definicji tych wskaźników. W rozdziale tym, Doktorantka bardzo precyzyjnie odnosi się do prowadzonych w tym samym czasie prac innych autorów. **Były to jednak wyłącznie prace dotyczące klasyfikacji binarnej (bez rozróżniania typu bezdechu).** W niektórych pracach raportowano uzyskanie dokładności sięgającej prawie 100%. Nie były to jednak sygnały pozyskane z elektrod, z których korzystała doktorantka w swoich badaniach. W tym czasie Doktorantka sukcesywnie publikowała wyniki swoich badań dotyczące klasyfikacji trójetykiowej w czterech wskazanych w bibliografii pracach. O aktualności i istotności prowadzonych badań świadczą odniesienia do tych prac w publikacjach autorów z innych ośrodków.

W rozdziale 4 Autorka opisuje bazy danych sygnałów, z których korzystała. Z rozdziału tego wynika pełna świadomość Autorki co do sposobu rejestracji sygnałów i jakości zgromadzonych danych, a także jakości opisu tych danych przez ekspertów. Ważne jest też, że bazy te są powszechnie wykorzystywane przez innych autorów, co dało możliwość porównywania uzyskiwanych wyników z wynikami z innych ośrodków. Doktorantka przedstawia cztery najbardziej istotne bazy, w których oprócz innych sygnałów rejestrowanych zwykle przy badaniu bezdechu sennego, zapisano sygnały EEG z różnych kanałów. Autorka w pracy doktorskiej wykorzystwała bazę opracowaną w University College w Dublinie. Baza ta zawiera bardzo dużo wyników badań osób, u których stwierdzono występowanie bezdechu sennego różnych typów. Zgromadzone sygnały są szczegółowo opisane i skalsyfikowane przez ekspertów w oparciu o sygnały EEG przy równoczesnym wykorzystaniu innych typów sygnałów, co zwiększa wiarygodność poprawności klasyfikacji, do której potem można było się odnieść jako do referencji.

W rozdziale piątym Autorka dokonała przeglądu możliwych do zastosowania w analizie sygnału EEG metod przetwarzania wstępnego. Procedury wstępnego przetwarzania mają za zadanie usunięcie z analizowanego sygnału zidentyfikowanych zakłóceń i nieprawidłowości wynikających choćby ze sposobu rejestracji, ustawień związanych z zapisem sygnału, usunięciem tych składowych sygnałów, które nie niosą istotnych informacji, z punktu widzenia postawionego w dalszej analizie celu (w tym przypadku klasyfikacji). Zakłócenia występujące w sygnale EEG, Doktorantka dzieli na dwie grupy, tj. zakłócenia zewnętrzne i wynikające z fizjologii (i wylicza je wyczerpująco na początku tego rozdziału). W dalszej części rozdziału przedstawia możliwe do zastosowania metody wstępnego przetwarzania rozważając ich znane zalety i wady, szczególnie w odniesieniu do sygnału EEG. Metody te Autorka podzieliła na grupy, w zależności od roli jaką mogą one odegrać we wstępnych przetwarzaniu. Wyróżniła więc:

1. metody wczesnego przetwarzania niezwiązane z artefaktami fizjologicznymi. Zwykle są one stosowane w odniesieniu do całego sygnału, niezależnie od pojawiających się w nim artefaktów. Można do tych metod zaliczyć: usuwanie fragmentów o nadmiernej amplitudzie (nasylenia) mogących pochodzić od wpływów zewnętrznych, technicznych (ruchy elektrod i przewodów), bądź fizjologią, normalizacja i standaryzacja sygnałów (często wynikająca z faktu, że sygnały były rejestrowane w różnych okresach czasu), usuwanie trendów poprzez filtrację górnoprzepustową lub metodami parametrycznymi, uśrednianie potencjału odniesienia (potencjału elektrody referencyjnej), usuwanie charakterystycznych zakłóceń, np. pochodzących od sieci elektroenergetycznej.
2. metody przetwarzania artefaktów. Artefakty takie jak wpływ aktywności serca, tętno (okresowe i regularne), ruchy pacjenta, aktywność mięśniowa, ruchy gałek ocznych, mruganie, itp. (nieregularne), obserwować można zarówno w dziedzinie czasu jak i częstotliwości. Autorka metody związane z przetwarzaniem sygnału w takich przypadkach dzieli na techniki wykrywania, usuwania lub redukcji artefaktów. W tej grupie metod wyróżniono metody przydatne w przetwarzaniu artefaktów w sygnale wielokanałowym, jednokanałowym i dla obu przypadków. Wśród proponowanych metod są: ślepa separacja źródeł (np. ICA, CCA, MCA), nieujemna faktoryzacja macierzy, usuwanie fragmentów sygnału, metody regresji, STFT, transformacje falkowe, filtracja adaptacyjna i inne metody.

Kolejnym etapem wstępnego przetwarzania jest podział sygnału na epoki i klasy. Odbywa się to na bazie opisu sygnału EEG (i czasami innych sygnałów wspomagających) przez ekspertów. Eksperci opisują precyzyjnie sygnał pod kątem występowania różnego typu zaburzeń związanych z analizowanym schorzeniem. W przypadku sygnału EEG podział dokonywany jest na 30-sekundowe epoki zawierające jedno z trzech możliwych zdarzeń: normalne oddychanie, bezdech obturacyjny i bezdech centralny. Czasami pod uwagę brane są również spłyccenia oddychania, co może wpływać na liczbę klas analizowanych zaburzeń. Zwykle pojedyncza epoka zawiera jedno z wymienionych zdarzeń, tak więc każda z epok może być jednoznacznie przypisana do danej klasy. Taka baza opisana przez eksperta stanowi bazę referencyjną do dalszej analizy.

Doktorantka w rozdziale piątym każdą z opisanych, możliwych do zastosowania metod dokładnie analizuje. Warto podkreślić fakt doskonałej znajomości wielu różnych metod przetwarzania wstępnego sygnału EEG wraz z ich wadami, zaletami, ograniczeniami w stosowaniu i świadomości skutków ich zastosowania, co w efekcie pozwoliło na poprawny wybór końcowej grupy metod wykorzystywanych w dalszej części pracy. Wiele z przedstawionych metod zostało przebadanych z wykorzystaniem sygnałów EEG i w pracy przedstawiono skutki ich działania i określono parametry lub zakresy parametrów tych metod (minimalne długości ciągów próbek, progi odcięcia itp.). Efekty działania tych metod w wielu przypadkach przedstawiono w formie wykresów i przebiegów sygnałów przed i po analizie.

Finalnym kryterium wyboru grupy metod wstępnego przetwarzania było zastosowanie klasyfikatora NN do sygnału oryginalnego i sygnałów poddanych przetwarzaniu przez wybrane metody. Porównywano uzyskiwane wyniki klasyfikacji w odniesieniu do sygnału bez wstępnego przetwarzania. Stwierdzono, że niektóre metody usuwają z sygnału artefakty i zakłócenia ale nie wpływają wprost na jakość klasyfikacji wprost. Jednak w połączeniu z inną metodą wstępnego przetwarzania uzyskuje się poprawę jakości klasyfikacji (np. usunięcie wysyczeń amplitudy nie poprawiało wyniku klasyfikacji, ale wraz z filtracją dolnoprzepustową dawało już pozytywne efekty). W efekcie tych badań do dalszej analizy wybrano następujące metody: usuwanie wysyczeń, filtracja dolnoprzepustowa i standaryzacja sygnału.

W rozdziale szóstym Doktorantka przedstawiła analizę możliwych do zastosowania metod ekstrakcji cech z sygnału EEG. Celem tego etapu przetwarzania jest wydobycie z sygnału jego

charakterystycznych cech, bez utraty istotnych informacji zawartych w sygnale, przy jednoczesnej redukcji wymiaru wektora cech w porównaniu z oryginalnym sygnałem. Takie podejście ułatwia dalsze przetwarzanie i interpretację sygnału. Autorka w tym rozdziale koncentruje się nad wyborem takich metod ekstrakcji cech, które dają możliwość uzyskania wektora cech komplementarnych i całościowo opisujących analizowany sygnał. Proponuje metody możliwe do zastosowania w różnych dziedzinach, tj. w dziedzinie: czasu, czasu-częstotliwości, czasu-skali i częstotliwości. Bazując na fakcie, że sygnał EEG opisywany jest przez jego składowe związane z falami mózgowymi, proponuje zastosowanie metod ekstrakcji do każdej z fal z osobna. Jako pierwszy etap przetwarzania w procesie ekstrakcji cech proponuje dekompozycję sygnału EEG. Do tego celu możliwe jest zastosowanie metod realizowanych w dziedzinie czasu, jak np. filtracja pasmowoprzepustowa, dekompozycja empiryczna czy dekompozycja wariacyjna. Jako metody dekompozycji w dziedzinie czasu-częstotliwość i czas-skala rozważa: transformację Hilberta-Huanga, krótkoczasową transformację Fouriera i transformację falkową. W dziedzinie częstotliwości proponuje takie metody jak: transformacja Fouriera i wyznaczanie widmowej gęstości mocy sygnału. Dzięki takim transformacjom sygnału Doktorantka uzyskuje składowe analizowanych sygnałów, które w dalszej kolejności mogą być poddane skalaryzacji. Wśród możliwych do wyznaczenia cech skalarnych z zdekomponowanego sygnału EEG Autorka analizuje następujące grupy cech: energetyczne (energia sygnału, średnia moc sygnału, parametry Hjortha), cechy spektralne, cechy związane z kształtem sygnału, cechy statystyczne oraz cechy związane z dynamiką nieliniową sygnału (entropia, wymiar fraktalny czy analiza fluktuacji sygnału). Bardzo szczegółowo analizuje dostępną literaturę i proponowane tam metody ekstrakcji oraz efekty ich stosowania. Analizuje również zestawy metod dekompozycji sygnału i wyznaczania wartości skalarnych ze względu na najlepsze efekty detekcji bezdechu. Pod uwagę brano zarówno jednoetapowe metody dekompozycji, jak i dwuetapowe (złożone z przedstawionych wcześniej metod). Po przeprowadzeniu badań literaturowych Doktorantka zdecydowała się na zastosowanie do analizy sygnału EEG czterech metod dekompozycji jednoetapowej (filtracja pasmowoprzepustowa, transformacja falkowa, dekompozycja empiryczna i dekompozycja wariacyjna) i trzech metod dekompozycji dwuetapowej (Hilberta-Huanga, falkowa+Hilberta, wariacyjna+Hilberta). Wybrała również 9 cech skalarnych, które w Jej opinii były najbardziej obiecujące w dalszej analizie. Wśród wybranych cech były cechy statystyczne (skrośność, kurtoza i mediana), cztery parametry Hjortha oraz entropia i cecha związana z kształtem (wartość maksymalna). W dalszej części pracy Doktorantka przedstawia efekty stosowania wybranych i zaimplementowanych metod dekompozycji. Wyniki przedstawione są dla wybranego sygnału z bazy danych. W przypadku filtracji przedstawia również uzyskane charakterystyki częstotliwościowe zaprojektowanych filtrów. Ostatecznie wybór siedmiu metod dekompozycji i 9 cech skalarnych dla każdej metody dekompozycji dało możliwość wyznaczenia wektorów cech dla każdej z tych metod. Ze względu na fakt, że każda z zastosowanych metod dekompozycji dawała na wyjściu różną liczbę składowych, uzyskano wektory cech o różnych rozmiarach, tj. od 45 do 351. Łącznie możliwe jest wyznaczenie 873 cech.

Rozdział siódmy dotyczy metod selekcji cech skalarnych wyekstrahowanych z sygnału EEG, a przedstawionych w rozdziale poprzednim. Selekcja cech jest etapem przetwarzania sygnału EEG, na którym Doktorantka podejmuje próby uzyskania optymalnego zbioru cech przydatnych w procesie klasyfikacji. Cel jaki wskazuje to znalezienie zbioru cech jak najbardziej informacyjnych, komplementarnych i jak najmniej redundantnych. Jako metody umożliwiające selekcję cech wskazuje na podstawie badań literaturowych trzy ich grupy: metody filtrów, metody opakowane i metody wbudowane. Po wnikliwej analizie przydatności tych metod w podjętym przez Nią zagadnieniu, odrzuca metody wbudowane i opakowane jako czasochłonne, wymagające współpracy z docelowym algorytmem klasyfikacji, co może



doprowadzić do wyboru cech optymalnych dla wybranego algorytmu klasyfikacji, ale nieoptymalnych dla innych algorytmów. Jako najbardziej adekwatne wskazuje metody filtrów i na ich analizie koncentruje się w tym rozdziale. Filtry dzieli ze względu na rodzaj stosowanej miary informacji, statystycznej, odległości, zależności, itp. Pod uwagę w tej grupie wzięła takie rodzaje filtrów jak: algorytm ReliefF, analiza wariancji, metoda Fishera, s t-Studenta, analizy korelacyjne, dyskryminacyjne, algorytm MRMR, metoda składowych głównych oraz metody selekcji krokowej. Autorka przedstawiła zasady działania tych metod, możliwości zastosowania w zależności np. od liczby wyróżnianych klas, oraz omówiła ich potencjalne wady i zalety, dość szeroko odnosząc się do dostępnej literatury. Na podstawie doniesień literaturowych, stwierdziła, że często w analizie sygnału EEG nie stosuje się etapu selekcji cech, a pracuje się na pełnym ich zbiorze. Jednak odnosząc się do liczby metod dekompozycji zaproponowanych w tej pracy i liczby wskaźników skalarnych wybranych do dalszej analizy (co będzie skutkowało bardzo dużą liczbą wyznaczanych cech), Autorka podjęła decyzję o zastosowaniu metod selekcji i poszukiwaniu zbioru cech optymalnych (lub suboptymalnych). Autorka przyjęła, że tak wybrane cechy dla poszczególnych metod dekompozycji sygnału zostaną finalnie połączone w jeden zbiór, który będzie jeszcze raz poddany procesowi selekcji. Wynikowy zbiór cech zostanie wykorzystany do badań automatycznych klasyfikatorów i do doboru ich optymalnych parametrów. Doktorantka zdecydowała o wyborze trzech filtrów: algorytmu MRMR, algorytmu ReliefF w połączeniu z regresją liniową oraz analizy wariancji z regresją liniową. Wybrane metody zostały poddane wnikliwym badaniom, w tym doborowi ich parametrów, a uzyskane wyniki przedstawiono w pracy. Badania prowadzono w oparciu o dane pochodzące z ekstrakcji cech metodą HHT, co dawało najliczniejszy zbiór tj. 351 cech na wejściu metod selekcji. Każda z proponowanych metod selekcji dawała zbiór danych, które poddane klasyfikacji wybranym wcześniej algorytmem dawały wyniki klasyfikacji bardzo bliskie wynikowi uzyskanego w procesie klasyfikacji przeprowadzonej w oparciu o pełny zbiór cech. Dzięki zastosowanym metodom selekcji udało się ograniczyć zbiór cech wyjściowych nawet do 217 cech. Autorka przedstawiła efekty zastosowania proponowanych metod selekcji do wszystkich metod ekstrakcji cech omówionych w rozdziale 6, przy założeniu, że efekt klasyfikacji wybraną wcześniej metodą nie może ulec znacznemu pogorszeniu (rozkład istotności poszczególnych cech przedstawiono w pracy w formie graficznej). Z tabeli 7.2 (dla metody ReliefF) wynika, że jakość klasyfikacji po selekcji cech ulegała nieznacznej poprawie, a ograniczenie liczby cech w niektórych przypadkach było znaczące. Po połączeniu, tak wybranych cech wyselekcjonowanych dla podgrup związanych z metodą ekstrakcji, w jeden zbiór, poddano go ponownej selekcji. W efekcie uzyskano zbiór wynikowy o liczebności 387 cech. W zbiorze wynikowym dominowały cechy wyznaczone metodą HHT (ponad 66%) i metodą DWT+HT (prawie 15%). Zbiór cech wyjściowych ograniczono poprzez selekcję o ok. 25%.

Rozdział ósmy jest zasadniczym rozdziałem tej dysertacji, w którym omówiono możliwe do zastosowania metody automatycznej klasyfikacji stanów bezdechu sennego, przedstawiono ich wady i zalety oraz wybrano na podstawie badań literaturowych te, które będą podlegały dalszej analizie. Uzasadnieniem poszukiwania takich efektywnych klasyfikatorów jest fakt, że aktualnie standardem jest klasyfikacja takich stanów przez ekspertów, na podstawie wzrokowej oceny zarejestrowanych sygnałów, co jest procesem niezwykle czasochłonnym. Alternatywą są automatyczne klasyfikatory, które dają szansę na znaczące skrócenie czasu diagnozowania, pod warunkiem wystarczająco wysokiej dokładności takiej klasyfikacji. Doktorantka wyróżniła kilka zasadniczych grup metod klasyfikacji, tj. sztuczne sieci neuronowe, klasyfikatory statystyczne, klasyfikatory rozmyte, klasyfikatory mieszane oraz klasyfikatory wykorzystujące tzw. uczenie głębokie. Autorka w tej pracy na podstawie badań literaturowych opracowała podstawowe kompendium wiedzy o metodach ekstrakcji, selekcji, ale również klasyfikacji w oparciu o sygnały EEG (ze szczegółowym odniesieniem do literatury przedmiotu), co dla

czytelnika jest niewątpliwą, istotną wartością dodaną. W grupie klasyfikatorów statystycznych omówiła takie jak: k-najbliższych sąsiadów, analizę dyskryminacyjną, klasyfikator bayesowski, modele Markova oraz maszynę wektorów nośnych. W grupie sztucznych sieci neuronowych, szczególnie skupiła się na sieciach klasycznych, Kohonena i z głębokim uczeniem (choć w dalszej części pracy zrezygnowała z wykorzystania tych ostatnich). Pokróćce przedstawiła też klasyfikatory rozmyte. Sporo uwagi poświęciła zasadom i metodom oceny jakości klasyfikatorów, proponując odpowiednie miary takiej oceny zarówno dla klasyfikatorów binarnych, jak i wieloetykietowych. Na koniec tej analizy wskazała miary (uśredniona dokładność klasyfikacji, precyzja i czułość), które zamierzała wykorzystać do oceny wybranych klasyfikatorów. W grupie wybranych klasyfikatorów znalazły się: metoda k-najbliższych sąsiadów, sztuczne, klasyczne sieci neuronowe i maszyna wektorów nośnych. W przypadku metody k-najbliższych sąsiadów pod uwagę wzięto 10 różnych miar odległości (zdefiniowanych w pracy) oraz liczbę sąsiadów w przedziale 3-150. Poszukiwano zestawu optymalnych parametrów tej metody z punktu widzenia dokładności klasyfikacji. Za optymalny uznano klasyfikator z 47 najbliższymi sąsiadami i miarą euklidesową standaryzowaną. Pozwolił on na uzyskanie dokładności klasyfikacji równej 82,29%. Warto również zauważyć, że w przypadku tego klasyfikatora nie było pomyłek między oddechem normalnym a bezdechem, fałszywa klasyfikacje występowały jedynie między klasami bezdechu obturacyjnego i centralnego. Znacznie dokładniej diagnozowany był bezdech obturacyjny. Większość przypadków CSA zaliczane było do klasy OSA. W przypadku metody SVM, która jest klasyfikatorem binarnym, zastosowano połączenie seryjne tego klasyfikatora do rozwiązania problemu wieloetykietowego. Jego strukturę optymalizowano dla trzech funkcji jądra: liniowej, radialnej i wielomianowej dla stopnia wielomianu równego 2 i 3. W tym przypadku klasyfikację prowadzono po ustandaryzowaniu wszystkich epok sygnału EEG branych pod uwagę. Jeśli chodzi o skalę jądra, to najlepsze efekty uzyskiwano dla wartości 10 i 100. Parametr C badano w zakresie od  $10^{-5}$  do  $10^7$ . Najwyższą dokładność równą 83,26% uzyskano dla radialnej funkcji bazowej (dla optymalnie dobranych parametrów), a tylko nieco mniejszą dokładność dla funkcji wielomianowej. Efekty doboru optymalnych parametrów klasyfikatora SVM przedstawiono szczegółowo na rysunkach. Podobnie jak w przypadku poprzedniego klasyfikatora praktycznie bezbłędnie wskazywana była klasa związana z oddechem normalnym. Błędne klasyfikacje występowały tylko między klasami OSA i CSA (i były stosunkowo liczne). Ostatnią z badanych metod klasyfikacji były sztuczne sieci neuronowe. W tym przypadku różnorodność struktur sieci, ich parametrów i metod uczenia jest niezwykle duża. Bazując na badaniach literaturowych związanych z analizą sygnału EEG w zastosowaniu do diagnostyki bezdechu, Autorka skoncentrowała się na analizie klasycznej, jednokierunkowej sieci neuronowej. Poszukując optymalnej struktury sieci do tego zadania, dobierała kolejno jej architekturę (liczby warstw i neuronów), algorytm uczący (spośród GD, SCG i LM), funkcje aktywacji sieci, liczbę epok uczenia oraz metody obliczania błędów sieci. Poszukiwanie najlepszego algorytmu uczącego przeprowadzono wykorzystując sieć o dwóch warstwach ukrytych (17+7) oraz trzech różnych funkcjach aktywacji warstwy wyjściowej. Analizowano czas uczenia sieci i średnią dokładność klasyfikacji przy jej użyciu. Zbiór uczący był ok. 4 razy liczniejszy niż zbiory walidacyjny i testujący. Niezależnie od funkcji aktywacji, analizowane metody uczenia dawały podobne wyniki tj. najdłuższy czas uczenia i najwyższą dokładność uzyskano dla algorytmu LM (ok. 700s i 75%). Najkrótszy czas uczenia uzyskano dla SCG niewiele tracąc na dokładności. W efekcie optymalnej struktury sieci poszukiwano stosując algorytm uczenia SCG. Optymalnej struktury poszukiwano wśród sieci jednowarstwowych i dwuwarstwowych. W przypadku sieci jednowarstwowej wybrano strukturę z 10 neuronami w warstwie ukrytej i radialnej funkcji aktywacji, uczoną metodą SCG. Uzyskano przy jej użyciu dokładność klasyfikacji równą 81,5%. Sieć taka poprawnie klasyfikowała wszystkie przypadki oddechu normalnego, wykrywała również wszystkie



przypadki bezdechu, nie klasyfikując jednak poprawnie każdego z typów bezdechu. Podobne wyniki uzyskano dla tej struktury sieci uczonej metoda GD, a nieco gorsze dla metody LM (w tym przypadku wzrosła liczba nieprawidłowo zaklasyfikowanych przypadków, w tym również oddechu normalnego). Jednak takich wyników można się było spodziewać, bo strukturę dobierano stosując jednak metodę SCG. Wyniki tych analiz przedstawiono w postaci graficznej.

W przypadku sieci dwuwarstwowej, stosując taką samą metodykę, jako optymalną wybrano sieć z warstwami ukrytymi 14+14, dla której uzyskano dokładność klasyfikacji 81,36%, przy uczeniu metodą SCG. Sieć tak dobrana dała możliwość poprawnej w 100% klasyfikacji oddechu normalnego i przypadków bezdechu. Jednak rodzaje bezdechu były mylone w stopniu podobnym do sieci jednowarstwowej. Tak wybraną strukturę sieci przetestowano również z pozostałymi metodami uczenia, uzyskując większą (82,25%) dokładność klasyfikacji dla metody LM i w odróżnieniu od sieci jednowarstwowej, nie było pomyłek w klasyfikowaniu oddechu normalnego i bezdechu. Poziom niepoprawnej klasyfikacji OSM i CSM był podobny dla wszystkich metod uczenia i podobny jak w sieci jednowarstwowej.

Badaniom poddano również sieć wielowarstwową z 3, 4 i 5 warstwami ukrytymi, każda o liczbie 14 neuronów (nie sygnalizowano w pracy etapu optymalizacji tych sieci). Sieci uczone metodą LM. Uzyskane wyniki były nieco gorsze niż w przypadku sieci dwuwarstwowej. Zdarzały się również błędne klasyfikacje między klasą oddechu normalnego i klasami związanymi z bezdechem.

Podsumowując, najlepsze efekty z punktu widzenia dokładności klasyfikacji uzyskano dla klasyfikatora SVM (83,26%) i tylko nieco gorsze dla pozostałych (82,29% i 82,25%) dla optymalnie dobranych struktur i parametrów tych klasyfikatorów. Badania wskazują, że praktycznie we wszystkich przypadkach prawidłowo klasyfikowano proces oddychania normalnego i bezdechu. Jednak rozróżnienie rodzaju bezdechu wymaga dalszych badań. W przypadku badań prezentowanych w literaturze, kiedy osiągnięta dokładność była na poziomie powyżej 84%, klasyfikacja dotyczyła wyłącznie przypadku binarnego. Jedyna publikacja raportująca wyższe dokładności w trzech klasach, odnosiła się do innych baz danych i nieco innej metodyki badań. Świadczy to o tym, że zaprezentowane w tej pracy badania są na najwyższym światowym poziomie. Autorka wskazuje również na dalsze możliwości zwiększania dokładności klasyfikacji, np. poprzez dodanie drugiego kanału EEG. Daje to na przyszłość spore możliwości badawcze i publikacyjne dla Doktorantki, szczególnie po bardzo dobrym opanowaniu i znajomości metod stosowanych na wszystkich etapach przetwarzania sygnałów EEG, na co wskazuje niniejsza dysertacja.

W rozdziale dziesiątym zebrano najważniejsze wnioski podsumowujące wyniki badań zaprezentowane w rozdziałach poprzedzających. W rozdziale tym doktorantka przedstawiała również kierunki dalszych prac dotyczących bezdechu sennego i jego automatycznego wykrywania. Autorka wskazuje na: zbudowanie liczniejszej bazy danych sygnałów EEG, prace nad poszukiwaniem cech różnicujących typy bezdechu (np. klasyfikacja hierarchiczna), poszerzenie zbioru cech skalarnych, dodanie drugiego, symetrycznego, kanału EEG, wykrywanie dodatkowych zdarzeń związanych ze snem, a widocznych w sygnale EEG. Wskazuje to na duży potencjał tematyki przedstawionej w tej dysertacji.

#### **4. Uwagi do dyskusji i uwagi szczegółowe**

Do opiniowanej pracy doktorskiej mgr inż. Moniki Prucnal recenzent zgłasza następujące kwestie do wyjaśnienia lub dyskusji:

1. Szkoda, że Autorka korzystała głównie z ilustracji zaczerpniętych z materiałów źródłowych (często średniej jakości) zamiast z własnych badań, a przynajmniej w przypadku metod, które potem stosowała do analizy sygnału EEG,
2. Jaka jest jednostka wartości podanych na osi X na rys. 3.5?
3. Str. 53, 8 linia przed 3.2.3 – powołanie na rys. 3.7 (dipole prądowe umieszczone w jednorodnym ...) – brak w pracy takiego rysunku,
4. Str. 60, 3 linia od góry – czy chodzi o wzrost wartości sygnału, czy częstotliwości, czy innego parametru?
5. Str. 73, 11 linia od góry – częstotliwość próbkowania sygnału równa 128Hz, a częstotliwość fal mózgowych do nawet 100Hz (a na str. 89, pierwsza linia od góry mówi się o paśmie nawet do 120 Hz). Czy taka częstotliwość próbkowania jest wystarczająca?
6. Str. 78, czy pojęcie „sygnały o zbyt dużej amplitudzie” jest właściwe? Czy rzeczywiście chodzi o amplitudę? Amplituda jest parametrem sygnałów (często okresowych) o określonych kształtach. W tym przypadku raczej powinno się użyć pojęcia wartości maksymalnej, wartości przekraczającej określony próg, ....
7. Rys. 5.6 – miejsce sklejenia przed i po przepróbkowaniu - na czym polega zysk z przepróbkowania, z rysunku nie wynika to jednoznacznie – wartość skoku w miejscu sklejenia praktycznie się nie zmieniła,
8. Str. 100, 4 wiersz od góry – czy rzeczywiście chodzi o filtrację pasmowoprzepustową, czy może pasmowozaporową?
9. Rys. 5.7, w podpisie mowa o charakterystyce częstotliwościowej i fazowej. Obie są częstotliwościowe – amplitudowa i fazowa. Podobnie na stronie 136 – 6 linia od dołu. Podobnie w podpisie rys. 6.10,
10. Na rys. 5.9 tak przedstawionym jak w pracy praktycznie nie widać żadnych efektów filtracji (być może jest to kwestia kolorystyki), podobnie rys. 5.13,
11. Rys. 5.12, jaka jest jednostka na osi X (Hz?), i dlaczego różne skalowanie tej osi na obu charakterystykach, czy były wyznaczane w trochę innych pasmach?
12. Dlaczego przyjęto czas trwania epoki równy 30 s? Z rys. 5.17 wynika, że z powodzeniem mogło to być np. 45 s – pozwoliłoby to na pełniejsze uwzględnienie pojawiających się zdarzeń.
13. Na rys. 6.10, osie Y opisano jako „Moc [dB]” – jednostką mocy jest Wat. Jeśli stosowano jednostki logarytmiczne to raczej odnoszą się do *poziomu mocy* (i czy w takim przypadku nie powinny być w [dBm])?
14. Po serii rysunków, jak np. na str. 138-139, brakuje trochę komentarza na bieżąco. Pojawia się on potem w podsumowaniu, ale w trakcie oglądania rysunków, trochę tego brakuje.
15. Str. 156, pod rys. 7.1 – czy rzeczywiście chodzi o próg o wartości 0,015, czy 0,15? Mowa jest o znacznym spadku wartości, a przy progu 0,015 nie już praktycznie żadnych istotnych cech, co w takim razie odcinamy?? Ile cech zostało odciętych?
16. Str. 160, w linii 5 przed tabelą 7.1 jest odniesienie do komentarza „f” – w tabeli, ani pod tabelą nie ma takiego odniesienia.
17. Str. 173, rozdział 8.1.2.2 jest „sieci Kohena”, powinno być „sieci Kohonena”, i potem w tekście rozdziału,
18. Rys. 8.1, może warto było w tym miejscu pokazać własne wyniki, opis w legendzie nie koreluje z treścią pracy, na rysunku zaznaczono tylko 8 sąsiadów, mimo, że mowa jest o 10. Co jest na osiach tego rysunku?
19. Mam wrażenie, że sieć wielowarstwowa została potraktowana po macoszemu, dlaczego wybrano po 14 neuronów w warstwach? Brakuje etapu optymalizacji struktury tej sieci i może dlatego jej skuteczność jest gorsza niż sieci dwuwarstwowej?

Autorka nie ustrzegła się również pewnych nieścisłości i niedociągnięć edycyjnych i stylistycznych:

Ogólne:

- Jest jakieś zamieszanie z oznaczeniami w wykazie oznaczeń (str. 15), tzn. precyzja i czułość klasyfikacji wieloetykietowej są oznaczone tak samo, a we wzorach na str. 179, stosowane są zróżnicowane oznaczenia,
- Oznaczenia dotyczące dokładności klasyfikacji wieloetykietowej *Micro* i *Macro* są różne w zestawie oznaczeń i we wzorach (str. 179),
- Autorka bardzo często zamiast słowa „liczba” używa pojęcia „ilość”,
- Czasami zamiast odwołania do np. numeru rysunku jest odwołanie typu „na rys. poniżej, powyżej” – nie zawsze jest jednoznaczne, np. str. 137, 144, 145, czy podpis pod rys. 6.18.
- W ostatnim wierszu tabeli 6.2 użyto pojęcia „maksymalna amplituda”, czy nie lepiej byłoby „maksymalna wartość”?

Szczegółowe (niektóre):

1. Str. 17, błędy edycyjne w pozycjach: 6 (AI) – dwa nawiasy, 14 (CPAP) – zamknięcie powinno być prostym nawiasem, (SA) – brak nawiasu,
2. Str. 33 – czwarty wiersz przed 2.4.2 jest „... obserwuje się ranne bóle ..”, raczej „... obserwuje się poranne bóle..”,
3. Str. 39/40, podpis pod rysunkiem na innej stronie niż rysunek,
4. Str. 40, 7 linia od końca – jest „mózgowe”, ma być „mózgowej”,
5. Str. 41, druga linia po 3.1.1.2, jest „aktywność” zamiast „aktywności”, a 8 linia – „rejestrowany” – „rejestrowane”
6. Str. 42, 2 linia od końca – jest „metody”, powinno być „elektrody”,
7. Str. 45, 15 linia od dołu – powinno być „z sennością”
8. Str. 47, 3 linia od dołu, „cyk snu” – „cykl snu”,
9. Str. 53, 2 linia po 3.2.2, „parametrowi” – „parametrów”,
10. Rys. 3.10 – słaba jakość,
11. Str. 62, 9 linia od góry – „średnich” – „średnim”,
12. Str. 66, 2 linia od góry – „poprawie” – „poprawnie”,
13. Str. 84, w podrozdz. 5.1.2.1, podpunkt A niepotrzebny, bo jedyny w tym podrozdziale,
14. Str. 90, pierwsza linia w podpunkcie G, jesy „polegają za połączeniu...”, powinno być „polegają na połączeniu ..”,
15. W podpisie rys. 5.4 po słowie „oraz” brakuje słowa „po”
16. Str. 113, 8 linia od góry – jest „podeście”, powinno być „podejście”,
17. Str. 117, 8 linia od góry – jest „jaj”, powinno być „jej”,
18. Str. 117, 12 linia od góry, powołanie na tabelę 1, powinno być powołanie na tabelę 2,
19. Str. 122, linia 5 przed wzorem 6.2 – jest „funkcję eksponentjalną”, chodzi zapewne o „funkcję eksponencjalną”,
20. Str. 126, 10 linia od góry, jest „następne”, powinno być „następnie”,
21. Str. 154, 8 linia w rozdz. 7.1.3 – jest „głębokim”, powinno być „głębokie”,
22. Str. 174, 8 linia od dołu, jest „prze wszystkim”, powinno być „przede wszystkim”,

## 5. Podsumowanie i wniosek końcowy

Praca napisana jest klarownie, dobrym językiem, przy stosunkowo niewielkiej liczbie uchybień edytorskich.

Uważam, że zarówno postawiona teza, jak i cel pracy zostały poprawnie sformułowane, a przyjęta metodyka badań oraz zastosowane metody były właściwie dobrane i zrealizowane. Na podstawie przedstawionych w pracy wyników badań stwierdzam, że postawiona na wstępie teza i sformułowany cel pracy zostały osiągnięte. Za najważniejsze i oryginalne osiągnięcia Doktorantki uważam:

1. Propozycję metody wstępnego przetwarzania sygnału związaną z eliminacją wysyczeń i nadmiernych wartości sygnału, powiązane z filtracją DP,
2. Podjęcie próby klasyfikacji zdarzeń bezdechowych w oparciu o jednokanałowy sygnał EEG, dla większej liczby klas niż dwie, jak to jest najczęściej raportowane w dostępnych publikacjach,
3. Umiejętny i trafny dobór metod wykorzystywanych łącznie na etapie ekstrakcji cech,
4. Propozycja globalnego zestawienia cech skalarnych w jednym zbiorze i jego analiza pod kątem komplementarności i redundancji, i eliminacja cech nadmiarowych (minimalizacja zbioru cech wejściowych dla metod klasyfikacji),
5. Propozycja łączenia metod selekcji cech, nie raportowana dotąd w innych pracach związanych z analiza sygnału EEG,
6. Uzyskanie bardzo dobrych wyników automatycznej klasyfikacji wieloetykietowej, a po sprowadzeniu problemu klasyfikacji do wersji binarnej – dokładność jest prawie stuprocentowa.

Docenić również należy ogromny nakład pracy związany z bardzo szerokimi badaniami literaturowymi, a w ich efekcie wnikliwym przedstawieniem ogromnej liczby możliwych do zastosowania metod na poszczególnych etapach przetwarzania sygnału EEG, z których potem Autorka wybrała najbardziej obiecujące do badań nad bezdechem sennym.

Analizując te metody autorka wskazywała na ich zalety, wady i najistotniejsze parametry. Ta część pracy może być niezwykle przydatna dla osób rozpoczynających pracę związaną z przetwarzaniem sygnałów EEG (lub innych sygnałów, w szczególności biomedycznych).

Warto również zauważyć, że przedstawiona w pracy metodyka badań i zaproponowane i przeanalizowane metody mogą być z powodzeniem wykorzystane do analizy i wykrywania innego rodzaju schorzeń.

**Biorąc pod uwagę wszystkie wcześniej sformułowane uwagi krytyczne, jak również oryginalne osiągnięcia Doktorantki oraz jakość uzyskanych wyników, z całym przekonaniem stwierdzam, że przedstawiona rozprawa doktorska mgr inż. Moniki Prucnal pt. „Metody analizy sygnału EEG ukierunkowane na wykrywanie bezdechu sennego” spełnia wymagania stawiane pracom doktorskim w odniesieniu do postawionego problemu i umiejętności jego samodzielnego rozwiązania przez obowiązujące aktualnie przepisy. W związku z tym wnioskuję o dopuszczenie pani mgr inż. Moniki Prucnal do publicznej obrony rozprawy doktorskiej.**

