

Autoreferat

Badania nad personalizacją i poprawą efektywności terapii neurofeedback z wykorzystaniem sztucznych sieci neuronowych

Jacek Rogala
Wydział Fizyki
Uniwersytet Warszawski

Warszawa, maj 2023

Spis Treści

1.	Imię i Nazwisko	3
2.	Posiadane dyplomy, stopnie naukowe– z podaniem podmiotu nadającego stopień, roku ich uzyskania oraz tytułu rozprawy doktorskiej.....	3
3.	Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych lub artystycznych..	3
4.	Osiągnięcie Naukowe.....	3
4.1.	Tytuł osiągnięcia naukowego	3
4.2.	Spis prac stanowiących podstawę procedury habilitacyjnej	3
4.3.	Omówienie osiągnięcia naukowego.....	4
4.3.1.	Historia badań nad Neurofeedback-EEG (N-EEG).	6
4.3.2.	Stan wiedzy przed rozpoczęciem własnych badań	6
4.3.3.	Ocena wpływu stosowanych powszechnie protokołów na zmiany sygnału EEG i poprawę celowanych funkcji poznawczych.	7
4.3.4.	Badania skuteczności treningu Neurofeedback-EEG w oparciu o wnioski z przeglądu literatury.....	8
4.3.5.	Badania nad zależnością cech sygnału EEG i funkcji poznawczych w warunkach laboratoryjnych i ekologicznych	8
4.3.6.	Badania skuteczności spersonalizowanych parametrów treningu N-EEG.....	10
4.3.7.	Badania nad możliwością wykorzystania sztucznych sieci neuronowych do nadzorowania treningu Neurofeedback-EEG (N-EEG)	14
4.3.8.	Podsumowanie	18
4.3.9.	Literatura	19
5.	Aktywność Naukowa.....	19
5.1.	Neurofeedback-EEG.....	22
5.2.	Analiza EEG z wykorzystaniem metod uczenia maszynowego.....	23
5.3.	Badania nad percepcją sztuki.....	24
6.	Osiągnięcia organizacyjne oraz popularyzujące naukę	25
6.1.	Centrum Badania Ryzyka Systemowego	25
6.2.	Innowacyjność	25
6.3.	Współpraca krajowa i zagraniczna	26

1. Imię i Nazwisko

Jacek Rogala

2. Posiadane dyplomy, stopnie naukowe – z podaniem podmiotu nadającego stopień, roku ich uzyskania oraz tytułu rozprawy doktorskiej.

- Magister, Praca magisterska: Odżywianie się stynki (*osmerus eperlanus*) w siedmiu jeziorach mazurskich, Zakład Hydrobiologii, Wydział Biologii, Uniwersytet Warszawski, 1991
- Doktor, Rozprawa doktorska: Rola ciała okołolankowego (PGN) w modulowaniu odpowiedzi komórek przekaźnikowych ciała kolankowego bocznego (LGN) u kota, Pracownia Neuroinformatyki, Zakład Neurofizjologii, Instytut Biologii Doświadczalnej PAN, 2014

3. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych lub artystycznych

- Specjalista w Zakładzie Fizyki Biomedycznej, Wydział Fizyki, Uniwersytet Warszawski (2022-do dzisiaj)
- Staż podoktorski: Naukowe Centrum Obrazowania Biomedycznego, Światowe Centrum Słuchu, Instytut Fizjologii i Patologii Słuchu (2018–2022)
- Staż podoktorski: Katedra Informatyki Stosowanej, Wydział Fizyki, Astronomii i Informatyki, Uniwersytet Mikołaja Kopernika w Toruniu (2017–2018)
- Staż podoktorski: Pracownia Neurobiologii Układu Wzrokowego, Zakład Neurofizjologii, Instytut Biologii Doświadczalnej PAN (2014–2016)

4. Osiągnięcie Naukowe

4.1. Tytuł osiągnięcia naukowego

Tytuł osiągnięcia naukowego, stanowiącego podstawę postępowania habilitacyjnego, brzmi:

Badania nad personalizacją i poprawą efektywności terapii neurofeedback z wykorzystaniem sztucznych sieci neuronowych

Osiągnięcie dotyczy badania mechanizmu oddziaływania neurofeedback-EEG, jako metody terapii zaburzeń funkcji poznawczych w oparciu o spersonalizowany protokół wykorzystujący wyjaśnialne sztuczne sieci neuronowe.

4.2. Spis prac stanowiących podstawę procedury habilitacyjnej

Spis pięciu publikacji, stanowiących spójny cykl, będący podstawą postępowania habilitacyjnego, zawarty jest w tabeli poniżej. Mój indywidualny wkład jest wymieniony w poniższym spisie publikacji oraz w Załączniku nr 3 (Wykaz osiągnięć).

Autorzy (rok)	Tytuł	Czasopismo
[1] Jacek Rogala, Katarzyna Jurewicz, Katarzyna Paluch, Ewa Kublik, Ryszard Cetnarski, Andrzej Wróbel (2016)	The do's and don'ts of neurofeedback training: a review of the controlled studies using healthy adults	Frontiers in Human Neuroscience, doi.org/10.3389/fnhum.2016.00301. (IF=3.473) MNiSW 100

		Liczba cytowań (WoS): 57
Indywidualny wkład: Koncepcja artykułu, analiza danych, główne wnioski		
[2] Katarzyna Paluch, Katarzyna Jurewicz, Jacek Rogala , Rafał Krauz, Marta Szczypińska, Mirosław Mikicin, Andrzej Wróbel, Ewa Kublik (2017)	Beware: Recruitment of Muscle Activity by the EEG-Neurofeedback Trainings of High Frequencies	Frontiers in Human Neuroscience. Volume 11 – 2017. doi.org/10.3389/fnhum.2017.00119 (IF=3.473) MNiSW 100 Liczba cytowań (WoS): 15
Indywidualny wkład: Interpretacja wyników, weryfikacja tekstu artykułu		
[3] Jacek Rogala , Ewa Kublik, Rafał Krauz, Andrzej Wróbel (2020)	Resting-state EEG activity predicts frontoparietal network reconfiguration and improved attentional performance	Scientific Reports, 10 (2020), pp. 1-15, 10.1038/s41598-020-61866-7 (IF=4.996) MNiSW 140 Liczba cytowań (WoS): 26
Indywidualny wkład: Koncepcja artykułu, analiza danych, główne wnioski		
[4] Jacek Rogala , Joanna Dreszer, Urszula Malinowska, Marek Waligóra, Agnieszka Pluta, Ingrida Antonova, Andrzej Wróbel (2021)	Stronger connectivity and higher extraversion protect against stress-related deterioration of cognitive functions	Scientific Reports, 11, 17452. (IF=4.996) MNiSW 140 Liczba cytowań (WoS): 2
Indywidualny wkład: Koncepcja artykułu, analiza danych, główne wnioski		
Jarosław Żygierewicz, Romuald A Janik, Igor T Podolak, Alan Drozd, Urszula Malinowska, Martyna Poziomska, Jakub [5] Wojciechowski, Paweł Ogniewski, Paweł Niedbalski, Iwona Terczynska, Jacek Rogala (2022)	Decoding working memory-related information from repeated psychophysiological EEG experiments using convolutional and contrastive neural networks	Journal of Neural Engineering 19 046053 DOI 10.1088/1741-2552/ac8b38 (IF=5.043) MNiSW 140 Liczba cytowań (WoS): 0
Indywidualny wkład: Koncepcja artykułu, analiza danych, główne wnioski		

Treść publikacji znajduje się w Załączniku nr 5, a oświadczenia autorów wspólnych publikacji (oprócz [1], [2], [3] i [4], w których znajduje się paragraf Author contribution) zostały zawarte w Załączniku nr 6.

4.3. Omówienie osiągnięcia naukowego

Celem badań opisanych w serii publikacji [1-5] była weryfikacja i poprawa skuteczności metody Neurofeedback-EEG (N-EEG), jako techniki wspierającej rozwój/terapię funkcji poznawczych.

N-EEG to biologiczne sprzężenie zwrotne polegające na dostarczeniu pacjentowi informacji zwrotnej (feedback) o aktywności jego mózgu. Informacje tą stanowi sygnał EEG zbierany na bieżąco za pomocą elektrod umieszczonych na głowie pacjenta. Następnie, po przetworzeniu przez specjalnie zaprojektowany program, sygnał ten jest prezentowany pacjentowi w formie wykresów, gier lub dźwięku. Podczas sesji terapeutycznych (zwykle minimum 20) pacjent jest zachęcany do wpływania na aktywność swojego mózgu, poprzez stosowanie różnych strategii i technik, takich jak medytacja, wizualizacja czy kontrola oddechu. Jeśli osoba osiąga pożądane zmiany w aktywności swojego mózgu, otrzymuje pozytywną informację zwrotną, w formie na

przykład, wzrostu wysokości dźwięku lub zmiany obrazu na ekranie. W swoim założeniu trening N-EEG powinien doprowadzić do wygaszenia niepożądanych oraz wzmocnieniem pożądanых fal EEG. Biologiczną podstawą treningu jest wykorzystywanie "plastyczności mózgu", polegającej na zdolności mózgowych sieci neuronalnych do utrwalania zmian aktywowanych połączeń.

Powszechnie stosowane metody treningu N-EEG nie zapewniają, niestety, odpowiedniego poziomu skuteczności [1]. Oznacza to, że w większości przypadków stosowana terapia nie przyczynia się do istotnej poprawy zdrowia u osób w niej uczestniczących, narażając je na niepotrzebne koszty, lub nawet na pogorszenie stanu zdrowia, jeśli jednocześnie zaniechano stosowania innych metod terapeutycznych. Z drugiej strony badania kliniczne wskazują, że przy usprawnianiu funkcji poznawczych osób w starszym wieku oraz osób dotkniętych schorzeniami ośrodkowego układu nerwowego dodatkowa terapia behawioralna wzmocnia wyniki leczenia farmakologicznego.

Niskiej skuteczności terapii N-EEG upatruje się głównie w źle dobranych metodach treningowych [1]. Obecnie stosowane protokoły treningowe (umiejscowienie elektrod i wybór zakresu częstotliwości EEG używanej do treningu) opierają się na analizie zapisu EEG w stanie spoczynku lub porównaniu zapisu EEG pacjenta z zapisem z bazy normatywnej. Wybierany protokół treningowy ma na celu wzmocnienie lub osłabianie sygnału EEG w wybranych zakresach częstotliwości (pasmach), według powszechnie stosowanych tabel (np. Kropotov, 2009). Ponieważ zależność między amplitudą wybranego pasma EEG, a przypisaną mu funkcją poznawczą (oraz zaburzeniami jej funkcjonowania) nie ma jednoznacznych podstaw naukowych, to dobór terapii jest często arbitralny i w rezultacie skuteczność stosowanych terapii N-EEG jest niska.

Badania opisane w przedstawianym cyklu publikacji pozwoliły na sformułowanie nowatorskiej (jednej z pierwszych na świecie), krytycznej oceny dotychczasowych praktyk terapeutycznych i badawczych, co dało podstawę do dalszych prac zmierzających w kierunku opracowania metody pozwalającej na przygotowanie spersonalizowanego protokołu treningowego. Nowa metoda, wykorzystująca sztuczne sieci neuronowe pozwala na przygotowanie protokołu opartego na indywidualnej analizie sygnału EEG zarejestrowanego podczas wykonywania zadań wymagających zaangażowania celowanych funkcji poznawczych. Analiza porównawcza zapisów sygnału EEG zebranych w trakcie wykonywania zadania związanego z daną funkcją pozwala na określenie parametrów docelowych treningu, czyli cech sygnału EEG towarzyszących tylko próbom wykonanym poprawnie. Wzmocnienie tych cech w trakcie treningu, również opartego na zadaniach wykorzystujących daną funkcję powinno, w zamierzeniu, prowadzić do poprawy skuteczności mierzonej polepszeniem zdolności poznawczych pacjenta.

Podstawowym wyzwaniem badawczym było analityczne powiązanie wyników behawioralnych, zebranych w czasie wykonywania zadania poznawczego z dynamiką indywidualnych map EEG. Dotychczasowe próby takich analiz napotykały na trudności związane z zakłóceniami pochodzącymi od równoległe rejestrowanej aktywności mięśniowej [2], zakłóceń zewnętrznych oraz wysokiej zmienności sygnału EEG między kolejnymi powtórzeniami prób treningowych. Dodatkowym problemem analitycznym, w dotychczasowej praktyce, była wielowymiarowość sygnału EEG (rozmieszczenie elektrod, amplituda, częstotliwość, czas, korelacje pomiędzy sygnałami z poszczególnych elektrod) oraz brak jednoznacznych zależności pomiędzy sygnałem EEG a rejestrowanymi zmianami zachowania lub funkcji poznawczych. Dla lepszego opisanie tych zależności oraz detekcji stanów aktywności sygnału EEG towarzyszących poprawnie wykonanym

próbom zastosowaliśmy, jako jedni z pierwszych na świecie, wyjaśnialne sztuczne sieci neuronowe (ang. XAI – explainable Artificial Intelligence). Posługując się tą metodyką dokonaliśmy identyfikacji cech sygnału EEG leżących u podstaw klasyfikacji, a następnie przeprowadziliśmy fizjologiczną interpretację otrzymanych wyników. **W toku badań wykryliśmy, że istotność cech sygnału EEG w procesie klasyfikacji zależy od stosowanych metod treningu sieci neuronowych. Ma to zasadnicze znaczenie nie tylko w przypadku treningów N-EEG, które powinny być oparte na cechach o znanym fizjologicznie mechanizmie, ale również w diagnostyce medycznej, np. w detekcji i klasyfikacji zaburzeń ruchowych i kognitywnych.** Wypracowane metody i rozwiązania mogą stanowić podstawy do personalizacji, obiektywizacji i automatyzacji treningów i terapii opartych na metodzie N-EEG poprawiając jej skuteczność, a także wnieść ważny wkład w wykorzystaniu sztucznych sieci neuronowych w praktyce klinicznej.

4.3.1. Historia badań nad Neurofeedback-EEG (N-EEG).

Jednym z pionierów N-EEG był Joe Kamiya, który w 1962 roku odkrył, że przy pomocy prostego urządzenia wydającego dźwięk w momencie wykrycia wzrostu aktywności w paśmie alfa (8-12 Hz), osoby badane można nauczyć świadomego kontrolowania wysokości amplitudy tego pasma. Mniej więcej w tym samym czasie Barry Sterman wraz ze swoim zespołem, którego istotnym członkiem była Wanda Wyrwicka – alumna Instytutu Biologii Doświadczalnej im. M. Nenckiego, odkrył, że koty można nauczyć zwiększania amplitudy rytmu zmysłowo-ruchowego (ang. sensorimotor, SMR; 12-15Hz) rejestrowanego nad korą ruchową (Sterman i wsp. 1969). Nagradzanie wzrostu aktywności rytmu SMR, któremu towarzyszył spadek aktywności ruchowej, okazało się bardziej skutecznym sposobem treningu niż nagradzanie reakcji bezruchu ciała. Okazało się również, że koty wytrenowane w zwiększaniu aktywności SMR były bardziej odporne na drgawki wywoływane środkami farmakologicznymi. Odkrycie to przyczyniło się do opracowania pierwszego protokołu neurofeedback (tj. określenia trenowanej częstotliwości i rozmieszczenia elektrod) dla zaburzeń napadowych u ludzi (Sterman and Friar 1972). Nieco później Joel Lubar, opublikowała pierwszy artykuł opisujący zastosowanie neurofeedback w terapii nadpobudliwości (Lubar i Shouse 1976). Od tego czasu liczba publikacji poświęconych N-EEG systematycznie rosła. W ciągu pierwszych dwóch dekad (1972-1990) opublikowano 162 opracowania dotyczące N-EEG (dane na podstawie wyszukiwania w Google Scholar, dla słowa kluczowego "neurofeedback"). W kolejnych dekadach liczba prac dotyczących tej tematyki dalej gwałtownie rosła, osiągając w latach dziewięćdziesiątych 1260, w latach 2001-2010 około 6100, a w latach 2011-2015 ponad 9000 publikacji, poświęconych różnym aspektom N-EEG!

4.3.2. Stan wiedzy przed rozpoczęciem własnych badań

W czasie, gdy rozpoczynałem swoje badania (2015) wiarygodne dane eksperymentalne były zaskakująco nieliczne, a stosowane powszechnie metodologia i wyniki - niespójne. Jedną z pierwszych prac przeglądowych na ten temat, opublikowana przez Vernona (Vernon i wsp. 2004), dotyczyła zastosowania N-EEG w leczeniu zespołu nadpobudliwości psychoruchowej z deficytem uwagi (ADHD). Autorzy omówili czynniki eksperymentalne, takie jak czas trwania treningu, lokalizacja elektrod, modalność sygnału i omówili ich możliwy wpływ na wyniki leczenia. W pracy tej zasugerowano, że osiągnięcie efektów terapeutycznych wymaga, co najmniej 20 sesji N-EEG oraz, protokołów opartych na pasmach beta/SMR. Omawiane przez autorów badania budziły jednak istotne obawy dotyczące zasadności zastosowania tej metody, głównie ze względu na brak

grup kontrolnych lub brak dowodów na specyficzność treningu związaną ze zmianami EEG (Vollebregt i wsp. 2014; Zuberer i wsp. 2015).

Pierwszy ilościowy przegląd N-EEG (Arns i wsp. 2009) koncentrował się na kontrolowanych badaniach dotyczących ADHD. Przegląd ten wskazywał na pozytywne efekty terapeutyczne treningu. Jednak w przeciwieństwie do Vernona (Vernon i wsp. 2004), zespół Arnsa stwierdził, że nieuwaga i nadpobudliwość były bardziej wrażliwe na niespecyficzne czynniki leczenia (np. interakcje terapeuta-pacjent), niż na biologiczne sprzężenie zwrotne. Okazało się również (Logemann i wsp. 2010), że czynniki niespecyficzne mogą być odpowiedzialne za efekty treningu obserwowane u osób zdrowych. W kolejnym przeglądzie (May i wsp. 2013) przeprowadzonym na pacjentach z urazowym uszkodzeniem mózgu potwierdzono możliwość uzyskania pozytywnych efektów terapeutycznych paradygmatu N-EEG, jednak w tych badaniach brakowało odpowiednich grup kontrolnych. Ta sama słabość metodologiczna charakteryzowała badania ukierunkowane na ADHD analizowane w następnej pracy przeglądowej (Arns i wsp. 2014). Co ważne, w przypadku wszystkich badań wykorzystujących aktywne grupy kontrolne (porównanie z rutynowym leczeniem o znanych efektach terapeutycznych) wyniki treningu N-EEG okazały się negatywne. W badaniach podstawowych przeprowadzanych z uczestnictwem osób zdrowych grupy kontrolne powinny pozwolić na eliminację wpływu czynników niespecyficznych takich jak interakcje trener-pacjent czy zaangażowanie uwagi, towarzyszących każdemu treningowi N-EEG. Najczęściej stosowanym i najskuteczniejszym sposobem kontroli czynników niespecyficznych jest zastosowanie pseudo-treningu, tzn. procedury obejmującej wszystkie elementy pełnoprawnego treningu N-EEG z wyjątkiem sprzężenia zwrotnego, które zwykle zastępowane jest losowym generowaniem wartości modyfikujących informacje zwrotną prezentowaną pacjentowi. Niestety, ten rodzaj kontroli w większości badań wykonywanych na osobach zdrowych nie był stosowany.

Podsumowując, większość uprzednich badań eksperymentalnych i analiz przeglądowych nie pozwalała na ocenę wpływu poszczególnych protokołów eksperymentalnych N-EEG na zależność między sygnałami EEG i sprawnością funkcji poznawczych, dla których ta metoda była stosowana.

4.3.3. Ocena wpływu stosowanych powszechnie protokołów na zmiany sygnału EEG i poprawę celowanych funkcji poznawczych.

Według naszej wiedzy przegląd literatury opracowany na potrzeby planowanych badań [1] był jednym z pierwszych, krytycznych opracowań wyników N-EEG. Głównym celem tego przeglądu była ocena skuteczności stosowanych metod treningowych pod względem zdolności do modyfikacji elektrycznej aktywności mózgu oraz poprawy funkcji poznawczych. Dodatkowo staraliśmy się określić wpływ czynników niespecyficznych, które są często ignorowane w badaniach N-EEG. Podstawowym wnioskiem z dokonanego przeglądu okazał się dosyć powszechny brak grupy kontrolnej, co wykluczyło większość prac z grupy kilkuset sprawdzonych publikacji, z których do analizy zakwalifikowano jedynie 28. Analiza badań spełniających kryteria kontrolne wykazała nieskuteczność stosowanych metod treningowych, ze względu na niską specyficzność treningu opartego na rejestracji wielu pasm EEG pochodzących z małej liczby elektrod. Dodatkowo zaobserwowano, że zmiany aktywności pasma alfa, będącego podstawą większości protokołów N-EEG, wstępują we wszystkich stosowanych protokołach i nie mają związku ze skutecznością zastosowanego treningu. Nasza analiza przeglądowa zaowocowała opracowaniem listy zaleceń, które pozytywnie korelowały z oczekiwanymi zmianami mocy

trenowanego pasma (pasm) N-EEG. Wśród tych zaleceń były (i) trening jak najmniejszej liczby plastycznych pasm EEG analizowanych z użyciem (ii) jak największej liczby elektrod rejestrujących. Pomimo wprowadzonych zmian protokołów doświadczalnych nie znaleźliśmy jednak dowodów na pozytywny związek między zmianami mocy trenowanego pasma (pasm) a specyficznymi efektami behawioralnymi, z wyjątkiem treningu pamięci roboczej z wykorzystaniem pasma theta. Wnioski płynące z naszego opracowania zostały później potwierdzone w badaniu eksperymentalnym przeprowadzonym przez grupę Andreas'a Sonderegger'a z Politechniki w Lozannie (Naas i wsp. 2019).

4.3.4. Badania skuteczności treningu Neurofeedback-EEG w oparciu o wnioski z przeglądu literatury

Na podstawie wniosków z przeglądu literatury zaplanowano przeprowadzenie własnych badań. Pomimo wdrożenia wcześniej opracowanych zaleceń tj. nakierowaniu treningu na konkretną funkcję poznawczą (uwagę), oparciu treningu na pomiarze aktywności w paśmie beta, którego związek z aktywnością uwagową jest dobrze udokumentowany (Wróbel 2014), rozmieszczenia elektrod rejestrujących nad obszarami czołowo-ciemieniowej pętli uwagowej, oraz neutralizacji efektu trenera/terapeuty poprzez ich rotację i zastosowaniu pseudo-treningu w grupie kontrolnej, nie uzyskano pożądanych efektów behawioralnych i neuronalnych [2]. Co więcej, większe zadowolenie z treningu zgłaszali uczestnicy z grupy kontrolnej niż grupy poddanej uczeniu N-EEG. Mimo, że uczestnicy zostali poinformowani o podstawowych mechanizmach działania metody N-EEG oraz proszono ich o nieporuszanie się w trakcie doświadczenia (trenerzy interweniowali, gdy tylko zauważyli nadmierny ruch lub inny rodzaj niepożądanego zachowania), prawie połowa osób trenowanych wykorzystywała aktywność mięśniową pod elektrodami rejestrującymi (w większości przypadków - nieświadomie) w celu osiągnięcia lepszych wyników w grze terapeutycznej. Spowodowało to zagłuszenie sygnałów mózgowych sygnałami pochodzącymi z aktywności mięśniowej [2] o znacznie wyższej amplitudzie, co prowadziło do artefaktowych wyników behawioralnych w trakcie treningów. Zgromadzone obserwacje wykazały, że wzbudzenie reakcji mięśniowych nie może być skutecznie kontrolowane i eliminowane przez trenerów i wskazały na potrzebę efektywnej, automatycznej kontroli on-line aktywności mięśniowej podczas treningów N-EEG. Dotyczyło to w szczególności protokołów mających na celu zwiększanie amplitudy pasm wyższych częstotliwości (beta), których zakres częściowo pokrywa się z zakresem elektrycznej aktywności mięśni. Właściwa kontrola aktywności mięśniowej jest wymogiem nie tylko dla uzyskania wysokiej jakości sygnału EEG, ale przede wszystkim przeprowadzenia prawdziwego treningu N-EEG opartego na mózgowych źródłach aktywności zwrotnej.

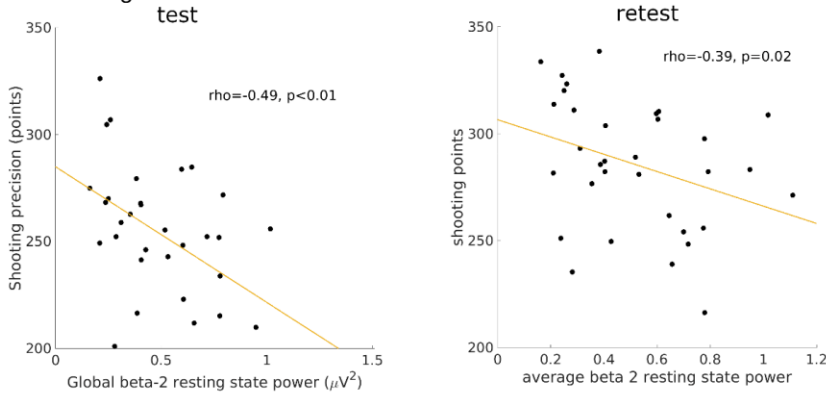
4.3.5. Badania nad zależnością cech sygnału EEG i funkcji poznawczych w warunkach laboratoryjnych i ekologicznych

Wyniki przeglądu literatury oraz własnych badań skłoniły nas do rozpoczęcia poszukiwań zależności pomiędzy cechami sygnału EEG i sprawnością funkcji poznawczych, które mogłyby być wykorzystane w treningu N-EEG i które: (i) wiązałyby silnie aktywność EEG z funkcjami poznawczymi, (ii) związek ten dotyczyłby nie tylko laboratoryjnych wyników testów psychofizjologicznych, ale byłby również kwantyfikowalny w warunkach ekologicznych tj. związanych z codzienną aktywnością (zawodową lub np. sportową). To ostatnie założenie wynikało z faktu, że podstawowym celem terapii N-EEG jest poprawa codziennego

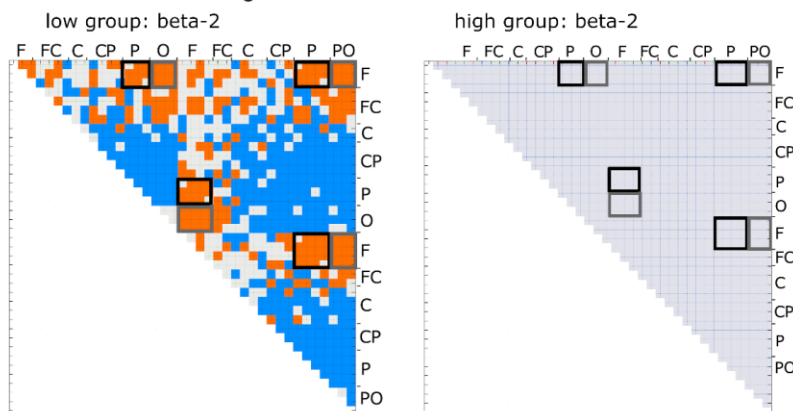
funkcjonowania osób z deficytami poznawczymi lub doskonalenie w dziedzinie wymagającej wykorzystania danej funkcji poznawczej. Własne badania pilotażowe wykazały, że dobrym parametrem dla poszukiwania takich związków mogą być korelacje fazowe sygnału EEG określające siłę wzajemnej zależności sygnałów EEG rejestrowanych na poszczególnych elektrodach. Spośród wielu dostępnych miar wybraliśmy phase locking value (PLV, Lachaux i wsp. 1999). PLV nie zależy od mocy spektralnej zarejestrowanych sygnałów, co więcej, jest odporna na zakłócenia sygnału, wynikające z artefaktów ruchowych i mięśniowych (Cohen 2015). Wreszcie, jest czulszą miarą siły korelacji fazowej niż wskaźnik opóźnienia fazowego, która nie uwzględnia korelacji fazowych o zerowym opóźnieniu.

Do badania zależności pomiędzy PLV i wynikami testów funkcji poznawczych oraz wynikami behawioralnymi związanymi z codzienną aktywnością osób badanych wybrano test wyszukiwania wzrokowego badający procesy uwagi oraz wyniki treningu strzelectwa sportowego (również wymagające zaangażowania uwagi) u początkujących adeptów tej dyscypliny [3]. Badanie obejmowało powtórzone pomiar zarówno testów psychofizjologicznych jak i wyników strzelania sportowego (liczby uzyskanych punktów) przeprowadzonych przed rozpoczęciem i po zakończeniu treningu strzeleckiego (test-retest). Uzyskane wyniki wykazały, że osoby o większej wartości PLV dla połączeń czołowo-ciemieniowych w paśmie beta (większej korelacji sygnałów świadczącej o silniejszej synchronizacji struktur mózgowych) w stanie spoczynku oraz manifestującej się wysoką globalną średnią (uśrednioną po wszystkich elektrodach) amplitudą tego pasma, osiągnęły istotnie gorsze wyniki w strzelectwie sportowym (Ryc. 1A) oraz charakteryzowały się słabszą rekonfiguracją połączeń neuronalnych (Ryc. 1B).

A. Shooting task



B. Neural network reconfigurations

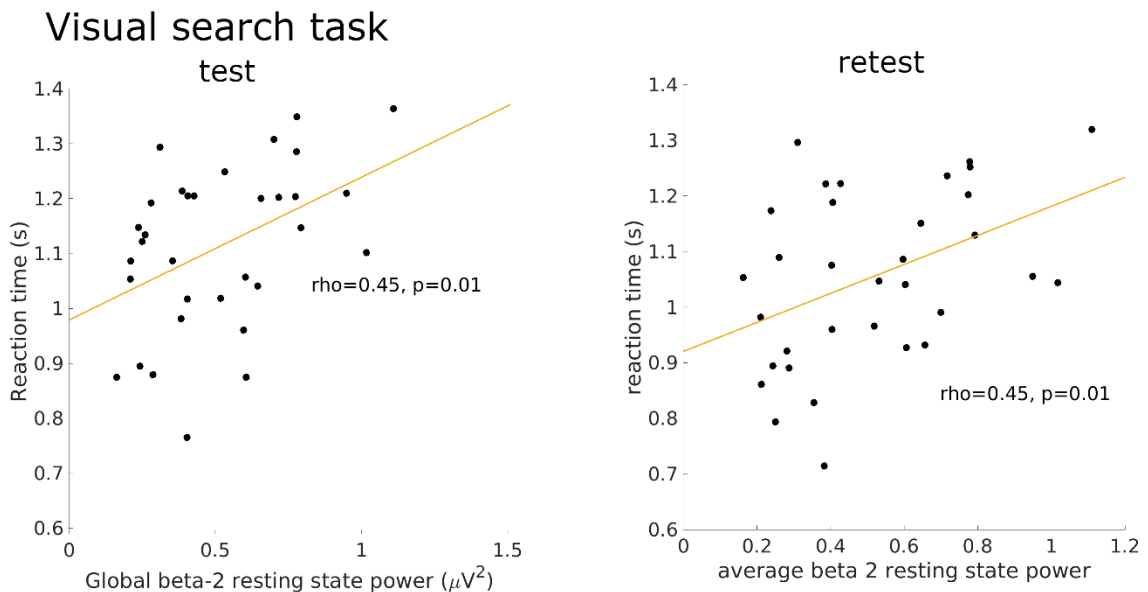


Rycina 1. A. Korelacje między średnią globalną mocą beta-2 (22-29 Hz) w stanie spoczynku charakteryzującą siłę połączeń czołowo-ciemieniowych sygnału EEG w tym paśmie, a wynikami w strzelectwie sportowym (na 400 możliwych punktów), $n = 33$.

B. Istotne różnice siły korelacji sygnałów EEG ($p < 0,05$, skorygowane FDR) w paśmie beta-2 między sesjami retest i test dla grupy o niskiej sile połączeń (charakteryzującą się niskimi wartościami średniej globalnej amplitudy beta2 - lewy panel) i brak istotnych różnic dla grupy o wysokiej sile połączeń (charakteryzującą się wysokimi wartościami średniej globalnej amplitudy - prawy panel). Kolorem czerwonym i niebieskim zaznaczono istotne dodatnie i ujemne różnice, odpowiednio, między retestem a testem; czarne kontury oznaczają połączenia czołowo-ciemieniowe; szare kontury oznaczają połączenia czołowo-potyliczne (Rogała et al. 2020).

Nasze wyniki potwierdziły przewidywania wcześniejszych prac teoretycznych, które wykazały, że silne połączenia między odległymi strukturami mózgu są bardzo stabilne (Ermentrout and Kopell, 1990; Kopell i wsp. 2000; Chandrasekaran i wsp. 2010), mniej podatne na zakłócenia i mniej wymagające energetycznie (Ermentrout i Kopell 1990; Chandrasekaran i wsp. 2010).

Równocześnie, okazało się, że silniejsze korelacje fazowe występują w sieciach neuronalnych o mniejszej złożoności, czemu towarzyszą: mniejsza elastyczność przetwarzania informacji (Goldberger i wsp. 2002; Zappasodi i wsp. 2014) i gorsze wyniki behawioralne (Tzagarakis, 2019). Słabsze połączenia neuronalne ułatwiają z kolei rekonfigurację sieci w odpowiedzi na zadania poznawcze (Ryc. 2).



Rycina 2. Korelacje między średnią globalną mocą beta-2 (22-29 Hz) w stanie spoczynku charakteryzującą siłę połączeń czołowo-ciemieniowych sygnału EEG w tym paśmie a czasami reakcji w zadaniu wyszukiwania wzrokowego, $n = 33$ (Rogała et al. 2020).


4.3.6. Badania skuteczności spersonalizowanego treningu N-EEG

Opierając się na wynikach opisanego wyżej badania [3] zaprojektowano spersonalizowany protokół doświadczalny, polegający na indywidualnym doborze par elektrod oraz pasm EEG. Procedura przygotowania protokołu składała się z trzech sesji diagnostycznych (Sesja-1, Sesja-2 i Sesja-3) przeprowadzanych w 2-3 dniowych odstępach, które miały na celu określenie charakterystyki połączeń fazowych sygnału EEG podczas zadań wymagających zaangażowania

pamięci roboczej. Podczas sesji uczestnicy grali w grę komputerową opartą na zadaniu odroczonego dopasowania do wzorca (ang. DMTS, delayed match to sample) za pomocą klawiatury w czasie, której rejestrowano 19 kanałowy sygnał EEG. Każda z sesji składała się z losowo wymieszanych prób wymagających uwagi i pamięci, oraz prób kontrolnych, które pomimo identycznego przebiegu nie wymagały użycia pamięci dla poprawnego wykonania. Dane zebrane z trzech sesji zostały następnie wykorzystane do dekodowania aktywności EEG towarzyszącej poprawnym próbom wymagającym użycia uwagi i pamięci roboczej. Dobrane indywidualnie parametry miały być wykorzystane podczas treningu EEG z zastosowaniem identycznej gry, której sterowanie oparte było na detekcji stanu aktywności EEG o parametrach korelacji fazowych, zbliżonych to tych uzyskanych w trakcie sesji diagnostycznych podczas poprawnie wykonanych prób. Kontrolę skuteczności treningu stanowiła bateria testów psychofizjologicznych obejmująca: klasyczny test pamięci roboczej n-wstecz oraz test rozumowania przechodniego, który wymaga jednoczesnego przetwarzania, utrzymywania i manipulowania informacjami, czyli efektywnych zdolności uwagi i pamięci roboczej. Testy te były przeprowadzane przed rozpoczęciem (pre-test) i po zakończeniu serii treningów N-EEG (post-test). Równocześnie, aby sprawdzić rolę dotychczas nieuwzględnianych czynników związanych z osobowością pacjentów, osoby badane wypełniły kwestionariusz wymiarów osobowości (tj. ekstrawersji i neurotyczności) (Eysenck & Eysenck, 1991).

Zaplanowany eksperyment N-EEG wykorzystujący protokół oparty na korelacjach fazowych sygnału EEG został przerwany przez epidemię COVID-19. Część badań wstępnych (pre-test), stanowiących kontrolę skuteczności planowanego treningu N-EEG, udało się zebrać jeszcze przed lockdownem (w dalszej analizie grupa ta otrzymała nazwę Pre-Pandemic). Pomimo wprowadzenia lockdownu część uczestników zgłosiła chęć kontynuowania udziału w badaniu (grupa Pandemic). Obie grupy zostały poproszone o ponowne wykonanie psychofizjologicznych testów kontrolnych (post-test). Tak więc, pomimo braku możliwości kontynuowania eksperymentu w planowanej formie i skali udało się zebrać unikatowy zestaw danych, który umożliwił zbadanie odpowiedzi neuronalnej i behawioralnej na silny i długotrwały stres wywołany przez zagrożenie zarażeniem COVID-19 u osób o różnej sile korelacji fazowych sygnału EEG i różnych cechach osobowości, oraz porównanie tych wyników do danych zebranych od osób, które badania odbyły przed pandemią [4]. Kwestionariusz lęku przed COVID-19 wypełniony przez wszystkich uczestników w okresie lockdownu nie wykazał różnic pomiędzy grupami, tak więc, decyzja o kontynuacji udziału w badaniu w okresie lockdownu musiała wynikać z innych, niż lęk, przyczyn.

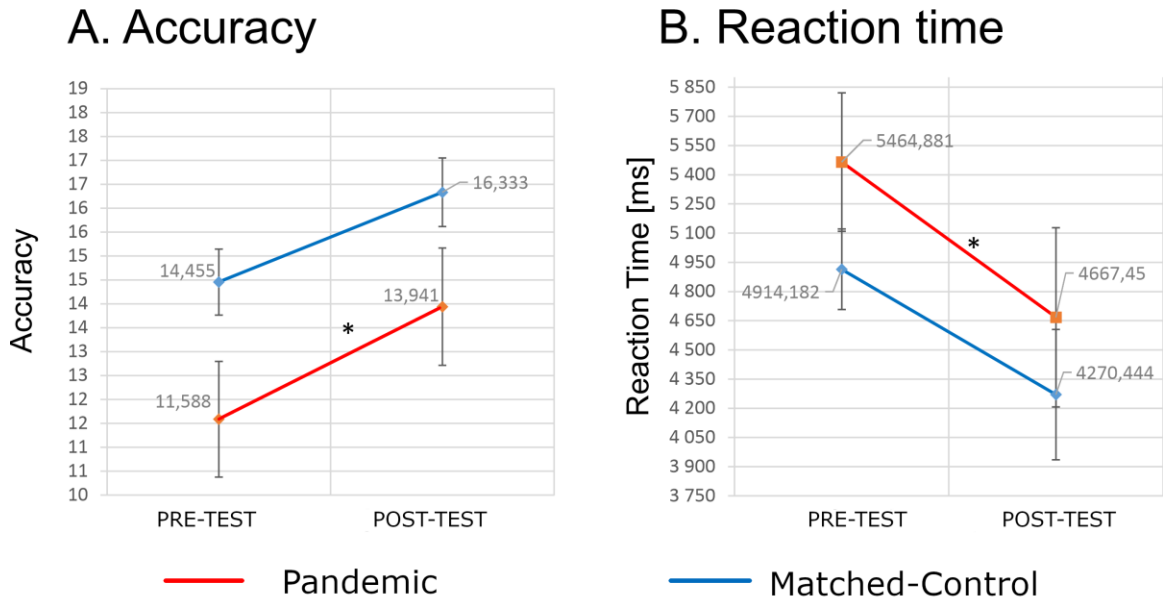
Analiza zebranych danych wykazała jednocześnie, że osoby, które kontynuowały udział w badaniu w czasie pandemii charakteryzowało wyższe natężenie ekstrawersji (Ryc. 3) oraz silniejsze średnie globalne korelacje fazowe sygnału EEG (Ryc. 4) w porównaniu do grupy, która ukończyła badania przed pandemią.



Ryc. 3. A. Porównanie poziomu ekstrawersji na skali stenowej pomiędzy grupami Pandemic i Pre-Pandemic Control w Sesji-1. Gwiazdka oznacza istotną różnicę między grupami ($p < 0,05$ test Manna-Whitneya).

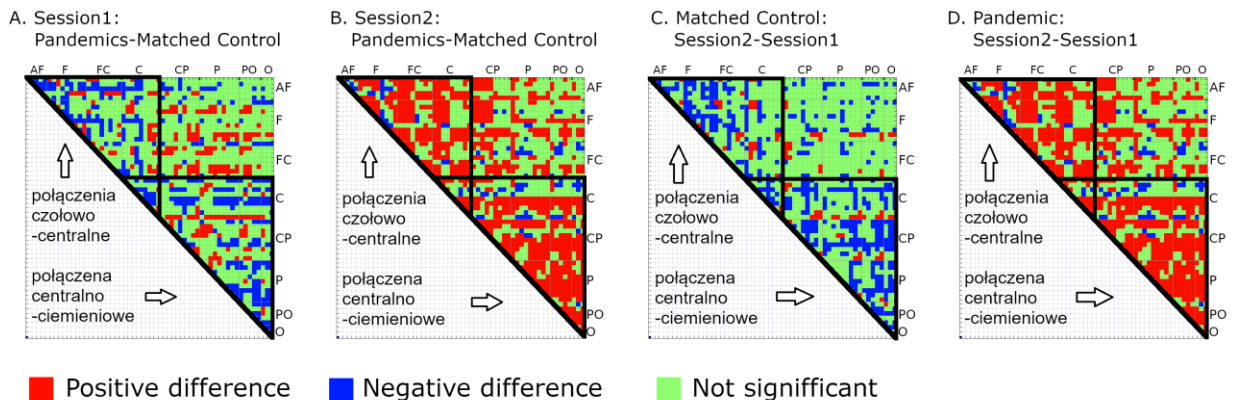
B. Średnie grupowe global connectivity index (GCI, średnia globalna liczona po wszystkich elektrodach) w czterech pasmach EEG podczas Sesji-1 (przed pandemią COVID-19). Różnice między grupami we wszystkich pasmach były istotne ($p < 0,01$, ANOVA, a następnie test post-hoc Tukeya). GCI obliczono, jako uśrednioną wartość PLV (miara siły połączeń opierała się na fazie sygnału EEG) w czterech kanonicznych pasmach EEG: theta (4-7 Hz), alfa (8-12 Hz), beta-1 (14-20 Hz) i beta-2 (21-30 Hz). Pandemic – grupa badana w czasie lockdown, Pre-Pandemic Control – grupa, która ukończyła badania przed wybuchem pandemii (Rogała et al. 2021).

W dotychczasowych badaniach tylko nieliczni autorzy zwrócili uwagę na potencjalną zależność między stanem aktywności funkcjonalnej sieci neuronalnej (mierzoną parametrami sygnału EEG) i stresem u osób zdrowych (Nair i wsp. 2020; Alonso i wsp. 2015). W szczególności Alonso ze współpracownikami (2015) wykazali, że stres wywołany przez zadanie poznawcze prowadził do zwiększenia siły korelacji w paśmie beta. Obserwacja ta potwierdziła się również w naszym eksperymencie, ale dodatkowo nasze wyniki pokazały, że zwiększenie siły korelacji sygnału EEG w stresie obejmuje wszystkie badane pasma. Różnice te wynikły prawdopodobnie z powodu silniejszego i trwałego stresu związanego z zagrożeniem pandemią. Badani z wyższą ekstrawersją, a więc zmniejszonym odczuwaniem skutków stresu, częściej kontynuowali zaplanowane działania (tj. udział w badaniu). Wynik ten można tłumaczyć niższą zdolnością rekonfiguracji sieci neuronalnych związaną z wyższą siłą korelacji fazowych, a co za tym idzie, zmniejszoną możliwością modyfikacji reakcji behawioralnych opisaną w naszej wcześniejszej pracy [3]. Co ciekawe, osoby nieróżniące się średnią globalną siłą połączeń, które ukończyły badania przed pandemią, uzyskały gorsze wyniki w powtórzonych testach (post-test), niż osoby wystawione na długotrwały stres (Ryc. 4).



Ryc. 4. Dokładność i czas reakcji w zadaniach na rozumowanie przechodnie wykonanych w pre-testu i post-testu. Średnie dokładności w wariancie trudnym (A) oraz średnie czasy reakcji w wariancie łatwym (B). Gwiazdki nad liniami łączącymi wyniki Sesji-1 i Sesji-2 oznaczają różnice istotne ($p < 0,05$) w teście post-hoc Chi2, a następnie nieparametrycznej ANOVA Friedmana. Matched-Control grupa osób, która ukończyła badania przed pandemią odpowiadająca grupie badanej pod względem poziomu ekstrawersji i GCI (ang. global connectivity index) w danym paśmie (Rogala et al. 2021).

Te pozornie sprzeczne obserwacje stają się zrozumiałe w świetle wyniku wskazującego, że u osób o silnych korelacjach sygnałów EEG, w nieobecności silnej stymulacji, zmiana konfiguracji sieci neuronalnych jest trudniejsza, co może skutkować brakiem lub tylko niewielką modyfikacją zachowania w odpowiedzi na czynniki środowiskowe. W przypadku osób kontynuujących udział w badaniach w czasie pandemii, długotrwała ekspozycja na silną stymulację mogła spowodować modyfikację połączeń funkcjonalnych i w konsekwencji modyfikację odpowiedzi behawioralnej na wykonywane zadanie, prowadząc do poprawy wyników (Ryc. 5) [4].



Ryc. 5. Porównanie różnic PLV dla wszystkich par electrode pomiędzy grupami Pandemic i Matched Control oraz pomiędzy sesjami dla tych grup, w przykładowym paśmie beta-2. (A) różnice PLV dla grup Pandemic i Matched Control w pre-test przed wybuchem pandemii; (B) to samo dla post-test, dla grupy Matched Control przed wybuchem pandemii, a dla grupy Pandemic podczas lockdown; (C) różnice PLV pomiędzy post-test i pre-test dla grupy Matched

Control wykonanych przed wybuchem pandemii; (D) różnice między post-test (zebranymi podczas lockdown) i pre-test (przed wybuchem pandemii) dla grupy Pandemic. Czarne kontury wyznaczają różnice PLV dla połączeń czołowo-centralnych i centralno-ciemieniowych. Różnice istotne przy $p < 0,01$, po korekcie Bonferroniego. Matched-Control grupa osób, która ukończyła badania przed pandemią odpowiadająca grupie badanej pod względem poziomu ekstrawersji i GCI (ang. global connectivity index) w danym paśmie. Pandemic – grupa badana w czasie lockdown, Pre-Pandemic Control – grupa, która ukończyła badania przed wybuchem pandemii. Matched-Control grupa osób, która ukończyła badania przed pandemią odpowiadająca grupie badanej pod względem poziomu ekstrawersji i GCI (ang. global connectivity index) w danym paśmie (Rogala et al. 2021).

Paradoksalnie, opisany powyżej mechanizm może być korzystny dla zasobów poznawczych - w sytuacjach stresowych silne połączenia funkcjonalne i niższa zdolność modyfikacji zachowania sprzyja ochronie zasobów poznawczych przed spadkiem efektywności oraz kontynuacji rozpoczętych zadań.

Wyniki obu opisanych badań ([3] i [4]) wskazują na konieczność personalizacji terapii N-EEG, gdyż zarówno wzmacnianie jak i osłabianie siły połączeń neuronalnych, a także prawdopodobnie innych cech sygnału EEG, może przynieść korzystny efekt terapeutyczny, w zależności od indywidualnej predyspozycji pacjentów oraz sytuacji zewnętrznej, w której działają. Należy dodać, że ostatni z trzech opisanych wyżej eksperymentów (poszukiwanie indywidualnych parametrów treningu N-EEG, [4]) charakteryzował się złożonym, a przez to czasochłonnym, procesem przygotowania indywidualnego protokołu. Konieczność indywidualnego doboru par elektrod i pasm EEG oraz wielokrotne porównania uśrednionej wartości PLV pomiędzy próbami wymagającymi zaangażowania celowanej funkcji poznawczej i próbami kontrolnymi wymagały znajomości specjalistycznej wiedzy i narzędzi programistycznych oraz dużego nakładu pracy, co ogranicza przydatność opracowanej metody w praktyce klinicznej. Ponadto zastosowane w obu badaniach korelacje fazowe sygnału EEG miały charakter binarny i nie uwzględniały wzajemnego oddziaływania sygnałów pochodzących z wielu kanałów jednocześnie. Protokół nie uwzględniał też innych cech sygnału EEG, jak chociażby mocy lub zależności funkcjonalnych pomiędzy poszczególnymi pasmami. Wszystkie te czynniki powodują, że nawet dobrany dużym wysiłkiem indywidualny protokół może okazać się niewystarczający, aby zapewnić zarówno spodziewaną zmianę aktywności mózgu jak i poprawę w wynikach behawioralnych.

Aby zminimalizować opisane wyżej ryzyka i jednocześnie usprawnić proces opracowywania indywidualnych protokołów, w kolejnym badaniu zdecydowano się na zastosowanie sztucznych sieci neuronowych [5].

4.3.7. Badania nad wykorzystaniem sztucznych sieci neuronowych do nadzorowania treningu Neurofeedback-EEG (N-EEG)

Głębokie sieci neuronowe (ang. deep neural networks; DNN) są z powodzeniem wykorzystywane w wielu dziedzinach badań do ekstrakcji oraz klasyfikacji cech podstawie danych wejściowych (end-to-end). Skuteczność tego podejścia w odniesieniu do klinicznych rejestracji EEG wykazał poprzednio m.in. Schirrneister i wsp. (2017). Jednak praktyczne zastosowanie DNN do klasyfikacji EEG jest utrudnione ze względu na dwa główne problemy: (i) małe zbiory danych niosące ryzyko przeuczenia; (ii) brak identyfikacji i wyjaśnienia znaczenia cech istotnych w procesie klasyfikacji (black-box). Ograniczenia te powodują ryzyko wykorzystania do klasyfikacji artefaktów (Comstock i wsp. 1992, Nathan i Contreras-Vidal 2016). O ile w przypadku interfejsów mózg-komputer

wykorzystanie artefaktów może być wręcz pożądane, to w przypadku metody neurofeedback, czy zastosowań diagnostycznych, może to prowadzić do fałszywych diagnoz i niepożądanych efektów ubocznych.

Wyzwania związane z małą liczebnością zbiorów treningowych i wyjaśnieniem znaczenia cech istotnych dla wyników klasyfikacji są znane od dawna. Techniki ograniczające negatywny wpływ tych zjawisk zostały opracowane i zastosowane w różnych dziedzinach, w tym w badaniach EEG. W przypadku problemu małych zbiorów danych, powszechnie stosowaną techniką jest uczenie transferowe. Zostało ono zastosowane już w 1998 roku (Thrun i Pratt 1998), a dziś jest powszechnie wykorzystywane w klasyfikacji EEG (patrz przegląd Wan i wsp. 2021). Nowsze rozwiązania obejmują m.in. takie techniki jak nienadzorowane uczenie kontrastowe (Contrastive learning; Hyvarinen i Morioka 2016). Rozwiązanie to przyniosło już obiecujące rezultaty w badaniach EEG (Mohsenvand i wsp. 2020, Banville i wsp. 2021). Natomiast do technik stosowanych w celu przezwycięzenia problemu interpretowalności należą: analiza wrażliwości oraz metoda gradientu prawdopodobieństw. Analiza wrażliwości jest najbardziej popularną metodą, opierającą się na lokalnej ocenie gradientu wyjściowego względem cech wejściowych. Wyniki analizy wrażliwości prezentowane są w postaci map ciepła obrazujących cechy wejściowe o największym wpływie na wynik.

Coraz powszechniejsze stosowanie metod uczenia maszynowego nacechowane jest dążeniem do osiągnięcia jak największej dokładności z pominięciem interpretowalności i wyjaśnienia wyników. Ryzyko klasyfikacji na podstawie artefaktów wymaga badań, które wyjaśniłyby wpływ rodzajów klasyfikatora i metod treningu sztucznych sieci neuronowych na dobór cech wykorzystywanych przez klasyfikatory. Niestety, tego typu badań nie znaleźliśmy w literaturze, a dotychczasowe skupiają się głównie na klasyfikacji aktywności EEG za pomocą jednego rodzaju treningu i klasyfikatora (Bird i wsp. 2018, Chakladar i wsp. 2020, Han i wsp. 2020).

W celu wyjaśnienia wpływu typu treningu i klasyfikatora na istotność cech wejściowych wykorzystano dane zebrane podczas poprzednich badań w trakcie trzech sesji diagnostycznych [4]. Na potrzeby przeprowadzonych analiz opracowano cztery modele sztucznych sieci neuronowych, wykorzystujące dwie różne metody treningowe [5]. Zastosowanie różnych modeli i metod treningu do tego samego zbioru danych pozwoliło nam porównać wpływ różnej architektury, strategii treningowych i reprezentacji danych wejściowych na wyniki klasyfikacji i znaczenie poszczególnych cech EEG w procesie klasyfikacji.

Opracowane lub zaadaptowane na potrzeby eksperymentu modele sztucznych sieci neuronowych obejmowały: (i) Shallow ConvNet— model referencyjny opracowany pierwotnie przez Schirrneister i wsp. (2017); (ii oraz iii) Modele Parallel ConvNet i Hybrydowy — modele wykorzystujące wejściową reprezentację sygnału w formie kanał-częstotliwość-czas oraz wspólną konwolucyjną część architektury. Dodatkowo, model hybrydowy został dotrenowany w celu klasyfikacji poszczególnych uczestników; (iv) Model kontrastowy z bramkowanym perceptronem wielowarstwowym (gMLP-MoCo), miał na celu ocenę uczenia transferowego z wykorzystaniem treningu kontrastowego.

Modele Shallow ConvNet, Parallel ConvNet oraz wstępnie wytrenowana część modelu hybrydowego były trenowane przy użyciu optymalizatora AdamW. Trening przeprowadzono ze standardową binarną funkcją straty krzyżowej. Model gMLP-MoCo był trenowany w dwóch

etapach: etap pierwszy nienadzorowany trening wstępny na danych klinicznych z wykorzystaniem momentum contrastive learning (MoCo), oraz etap drugi - trening wstępnie wytrenowanej sieci na danych z bieżącego eksperymentu.

Celem zastosowania treningu kontrastowego, poza oceną wpływu tego typu treningu na istotność cech, było wyodrębnienie tych cech sygnału EEG, które mogłyby przynieść nowy wgląd w korelaty aktywności neuronalnej dotyczące retencji informacji w pamięci roboczej. Metody uczenia kontrastowego (Wu i wsp. 2018, Chen i wsp. 2020, He i wsp. 2020, Tian i wsp. 2020) opierają się ekstrakcji niezmienników poprzez wprowadzanie przekształceń zbioru treningowego. W celu identyfikacji cech i określenia ich znaczenia dla wyników klasyfikacji zastosowaliśmy analizę perturbacyjną z wykorzystaniem automatycznej oceny gradientu prawdopodobieństwa. Aby odnieść tak opracowane wyniki do najczęściej stosowanych klasycznych analiz EEG skupiliśmy się na mocy sygnału EEG w kanonicznych pasmach częstotliwości na poszczególnych elektrodach i jako punkt odniesienia do analiz perturbacyjnych przyjęliśmy klasyczne analizy spektralne w poszczególnych pasmach. Moc w każdym z pasm częstotliwości została oszacowana poprzez zsumowanie periodogramów w zakresach odpowiadających pasmom częstotliwości falek Morleta, użytych w naszych modelach, dla których wykonaliśmy serię testów permutacyjnych, tasując etykiety dla każdej kombinacji elektroda-częstotliwość.

Wyniki klasyfikacji z użyciem zastosowanych klasyfikatorów i metod treningowych wykazały największą skuteczność dla najbardziej złożonych modeli, w tym modelu opartego na uczeniu kontrastowym, wykorzystującym surowe dane (Tabela 1).

Tabela 1. Wyniki klasyfikacji dla poszczególnych modeli (Żygierewicz i wsp. 2022).

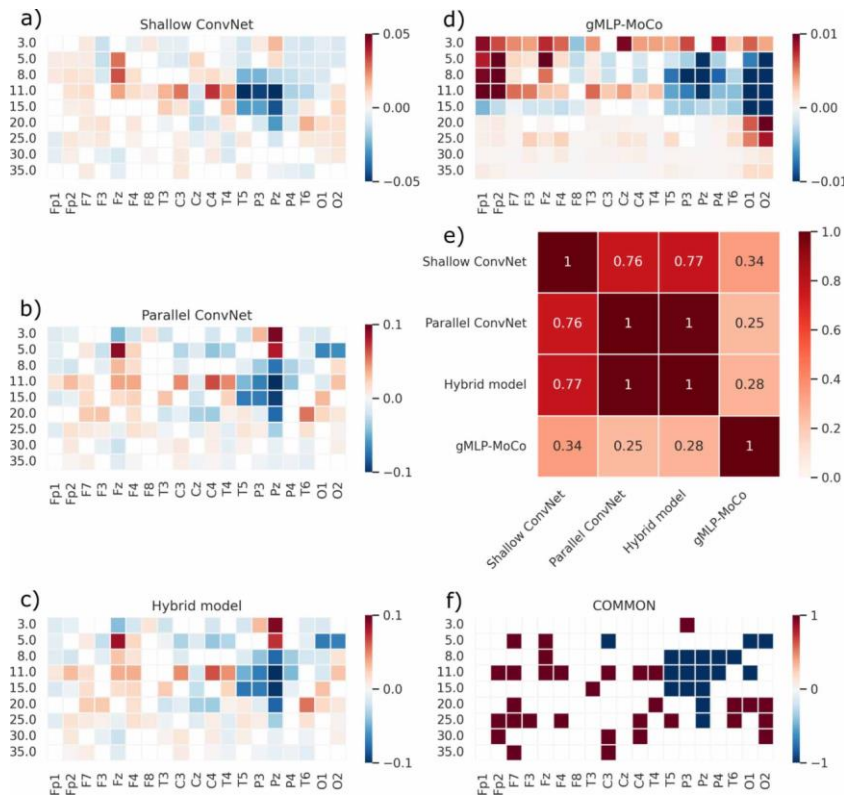
Model	ACC	MCC	# Trainable parameters
Shallow ConvNet	61.50 ± 2.33	0.216 ± 0.030	3.5×10^4
Parallel ConvNet	62.06 ± 1.39	0.223 ± 0.025	2.1×10^4
Hybrid model	64.38 ± 0.60	0.264 ± 0.011	2.1×10^4
gMLP-MoCo	65.29 ± 0.76	0.288 ± 0.018	6.1×10^6

Chociaż związek między widmem mocy w kanonicznych pasmach EEG a funkcjami poznawczymi nie jest w pełni wyjaśniony, był on postulowany od początku istnienia elektroencefalografii, a korelaty EEG pamięci roboczej należą do najlepiej poznanych. Ogólnie uważa się, że cechy widmowe, wykorzystywane przez modele do klasyfikacji i ich porównanie z klasyczną analizą przestrzenno-częstotliwościową i aktualną wiedzą, mogą wskazać czy wyniki klasyfikacji odzwierciedlają znane zjawiska fizjologiczne. Korelacje takie mogą mieć ogromne znaczenie w medycynie i biologii. Klasyczne metody analizy EEG polegają na statystycznym porównaniu wyników predefiniowanych miar rejestrowanych, w wybranych regionach zainteresowania dla różnych warunków eksperymentalnych. Natomiast sztuczne sieci neuronowe wykorzystują informacje o wszystkich dostępnych cechach i lokalizacjach jednocześnie, co może dać dodatkowy

wgląd w udział innych (w tym nieznanymi dotychczas) mechanizmów fizjologicznych i funkcjonalnych, związanych z cechami istotnymi dla wyników klasyfikacji.

Wszystkie modele, wykazujące duże wzajemne podobieństwo cech istotnych dla wyników klasyfikacji, charakteryzowały się płytką architekturą, stosunkowo małą liczbą trenowanych parametrów oraz uczeniem nadzorowanym. Najbardziej charakterystyczne cechy, wspólne dla tych modeli, obejmowały: dodatnie wartości indeksu ważności cech w paśmie theta (5-8 Hz) na elektrodach czołowych oraz ujemne wartości indeksu ważności cech na elektrodach ciemieniowych skupionych wokół częstotliwości 11 Hz (alfa) i 15 Hz (beta) (Ryc. 6A-C). Cechy te są dobrze udokumentowane w licznych badaniach psychologicznych i neurobiologicznych dotyczących analizy EEG i badaniach pamięci roboczej. Wykazano, że przechowywanie informacji w pamięci wiąże się ze wzrostem mocy pasma theta rejestrowanej na elektrodach czołowych (Wilson i wsp. 1999, Bastiaansen i wsp. 2002, Klimesch i wsp. 2008, Michels i wsp. 2010, Sauseng i wsp. 2010). Chociaż fizjologiczna interpretacja pozostałych cech (np. aktywność pasm alfa i beta na elektrodach ciemieniowych) jest trudniejsza, to cechy te są również wykrywane w licznych eksperymentach elektrofizjologicznych (patrz przegląd, Pavlov i Kotchoubey 2022). Podsumowując – istotność dla wyniku klasyfikacji takich cech jak aktywność w paśmie theta na elektrodach czołowych pokazuje, że wyniki klasyfikacji badanych modeli są oparte na cechach interpretowalnych przy użyciu klasycznych metod elektrofizjologicznych.

Gradienty prawdopodobieństwa, obliczone dla modelu gMLP-MoCo z uczeniem kontrastowym, poza cechami opisanymi powyżej, pokazały również wzorce innych istotnych cech, których znaczenie dla wyników klasyfikacji było wyższe niż cech charakterystycznych dla modeli o płytkiej architekturze, opisanych wcześniej (Ryc. 6D). Szczególnie interesujący jest wysoki indeks ważności cech dla pasm delta i theta na elektrodach Fp1 i Fp2 oraz, w mniejszym stopniu, dla pasma gamma w regionach czołowych i potylicznych. Wyniki te świadczą o wykorzystaniu do klasyfikacji cech kojarzonych z artefaktami związanymi z ruchem gałek ocznych i aktywnością mięśniową, i to pomimo oczyszczenia danych eksperymentalnych z artefaktów (m.in. usunięcie elektrycznych zapisów mrugnięć oczu i aktywności mięśni). Aktywność delta i theta na elektrodach Fp1 i Fp2 jest charakterystyczna dla artefaktów mrugania oczami, natomiast wysoka amplituda aktywności gamma w okolicach czołowych i potylicznych może wynikać z aktywności okolicznych mięśni. Jednocześnie dodatkowe badania wykluczyły możliwość, że przyczyną ważności tych cech było zastosowanie danych klinicznych do uczenia wstępnego. **Otrzymane wyniki mają szczególne znaczenie dla zastosowań DNN w treningu i diagnostyce N-EEG, natomiast wysoka wrażliwość na cechy związane z artefaktami praktycznie wyklucza ten model z zastosowania w medycynie, choć może on mieć nadal praktyczne zastosowanie w aplikacjach BCI.**



Ryc. 6. Wyniki analizy perturbacyjnej. (A-D) mapy ciepła indeksu ważności cech dla czterech badanych modeli. Pary kanał-częstotliwość zamaskowane na biało nie były istotne. (E) Korelacja Spearmana pomiędzy mapami ciepła; zaznaczono wszystkie istotne korelacje ($p < 0.001$). (F) Elementy map ciepła wspólne dla wszystkich modeli - czerwone dodatnie, niebieskie ujemne (Żygierewicz i wsp. 2022).

Podsumowując znaczenie wyodrębnionych cech sygnału EEG dla celów klasyfikacji należy zauważyć że, w przypadku modeli o płytkiej architekturze, odpowiadają one fizjologicznym właściwościom sygnałów EEG, obserwowanym podczas eksperymentów biologicznych i klinicznych. Istotność dla wyników klasyfikacji cech sygnału EEG o udokumentowanym znaczeniu fizjologicznym wskazuje na zasadność stosowania sztucznych sieci neuronowych o płytkiej architekturze i uczeniu nadzorowanym do przygotowania protokołu treningowego i nadzorowania przebiegu treningów N-EEG. Należy jednak zaznaczyć, że różne metody treningowe prowadzą do klasyfikacji opartych na różnych zbiorach cech, które niekoniecznie są bezpośrednio związane z realizowanym zadaniem. Oznacza to, że kryteria doboru klasyfikatorów i metod uczenia sztucznych sieci neuronowych, w przypadku zastosowań diagnostycznych i terapeutycznych, powinny obejmować metody identyfikacji i wyjaśniania istotności cech, co pozwoli ograniczyć możliwość klasyfikacji w oparciu o artefakty.

4.3.8. Podsumowanie

Spójny program badawczy, stanowiący podstawę niniejszej pracy, umożliwił weryfikację skuteczności i zasadności stosowanych do tej pory metod modulowania aktywności elektrycznej mózgu i poprawy funkcji poznawczych z użyciem N-EEG [1]. Weryfikacji tej dokonaliśmy w oparciu o badania własne, które wykazały ograniczenia dotychczasowych metod, wynikające z braku zależności pomiędzy cechami sygnału EEG wykorzystywanymi do tej pory w N-EEG, a celowanymi funkcjami poznawczymi [2]. Nasze wyniki znalazły również potwierdzenie w badaniach eksperymentalnych innych ośrodków naukowych (Naas i wsp. 2019). Zarówno przegląd literatury [1] jak i wyniki własnych badań stały się punktem wyjścia do poszukiwania metod, które, po

pierwsze, wiązałyby aktywność EEG z wynikami testów funkcji poznawczych stosowanych powszechnie w laboratoriach badawczych, jak i aktywnością wzbudzaną w codziennej praktyce [2], i po drugie, cechowałyby się większą odpornością na artefakty doświadczałne. W toku podjętych badań wykryto zależność między siłą korelacji fazowej sygnału EEG oraz wynikami behawioralnymi testów funkcji poznawczych i wyników osiągniętych poza laboratorium [3]. Dalsze badania nie tylko potwierdziły zależność między siłą korelacji fazowych oraz wynikami testów funkcji poznawczych, ale również ujawniły ich związek z odpowiedzią na silny i długotrwały stres, a także z cechami osobowości takimi jak ekstrawersja [4]. Zebrane w toku tych badań wyniki wykazały konieczność personalizacji treningu opartej na pomiarach diagnostycznych z wykorzystaniem testów celowanych funkcji poznawczych poprzedzających właściwy trening oraz doprowadziły do badań nad możliwością wykorzystania metod uczenia maszynowego w treningach N-EEG. **Badania te, jako jedne z pierwszych, wykazały wpływ metod stosowanych w uczeniu sztucznych sieci neuronowych na cechy stanowiące podstawę klasyfikacji, co ma zasadnicze znaczenie dla wykorzystania poszczególnych modeli w medycynie i biologii. Badanie nad zastosowaniem metod sztucznych sieci neuronowych wykazały również zasadność stosowania wyjaśnialnych modeli sztucznych sieci neuronowych do przygotowania i nadzorowania przebiegu treningów N-EEG.**

4.3.9. Literatura

- Alonso, J. F., Romero, S., Ballester, M. R., Antonijoan, R. M. & Mañanas, M. A. (2015). Stress assessment based on EEG univariate features and functional connectivity measures. *Physiol. Meas.* 36, 1351–1365.
- Arns, M., Heinrich, H., and Strehl, U. (2014). Evaluation of neurofeedback in ADHD: the long and winding road. *Biol. Psychol.* 95, 108–115. doi: 10.1016/j.biopsycho.2013.11.013
- Arns, M., Ridder de, S., Strehl, U., Breteler, M., and Coenen, A. (2009). Efficacy of neurofeedback treatment in ADHD: the effects on inattention, impulsivity and hyperactivity: a meta-analysis. *Clin. EEG Neurosci.* 40, 180–189. doi: 10.1177/155005940904000311
- Banville, H., Chehab, O., Hyvärinen, A., Engemann, D-A. and Gramfort, A. (2021). Uncovering the structure of clinical EEG signals with self-supervised learning *J. Neural Eng.* 18 046020
- Bastiaansen, M. C., Posthuma, D., Groot, P. F. and De Geus, E. J. (2002). Event-related alpha and theta responses in a visuo-spatial working memory task *Clin. Neurophysiol.* 113 1882–93
- Bird, J. J., Manso, L. J., Ribeiro, E. P., Ekárt, A. and Faria, D. R. (2018). A study on mental state classification using EEG-based brain-machine interface *Int. Conf. on Intelligent Systems (IS) (IEEE)*, 795–800
- Chakladar, D. D., Dey, S., Roy, P. P. and Dogra, D. P. (2020). EEG-based mental workload estimation using deep BLSTM-LSTM network and evolutionary algorithm *Biomed. Signal Process. Control* 60 101989
- Chandrasekaran, L., Achuthan, S. & Canavier, C. C. (2010). Stability of two cluster solutions in pulse coupled networks. *Journal of Computational Neuroscience* 30, 427–445.
- Chen, T., Kornblith, S., Norouzi, M. and Hinton, G. (2020). A simple framework for contrastive learning of visual representations *Int. Conf. on Machine Learning (PMLR)*, 1597–607

- Cohen, M. X. Effects of time lag and frequency matching on phase-based connectivity. *Journal of neuroscience methods* 250, 137–146. (2015).
- Comstock, J. R. et al. (1992). The multi-attribute task battery for human operator workload and strategic behavior research NASA Technical Memorandum NASA-TM-104174
- Ermentrout, G. B. & Kopell, N. (1990). Oscillator Death in Systems of Coupled Neural Oscillators. *SIAM Journal on Applied Mathematics* 50, 125–146.
- Goldberger, A. L. et al. (2002). Fractal dynamics in physiology: alterations with disease and aging. *Proc Natl Acad Sci USA* 99, 2466–2472.
- Han, S-Y., Kwak, N-S., Oh, T. and Lee, S-W. (2020). Classification of pilots' mental states using a multimodal deep learning network *Biocybern. Biomed. Eng.* 40 324–36
- He, T., Kong, R., Holmes, A. J., Nguyen, M., Sabuncu, M. R., Eickhoff, S. B., Bzdok, D., Feng, J. and Yeo, B. T. (2020). Deep neural networks and kernel regression achieve comparable accuracies for functional connectivity prediction of behavior and demographics *NeuroImage* 206 116276
- Hyvarinen, A. and Morioka, H. (2016). Unsupervised feature extraction by time-contrastive learning and nonlinear ICA *Advances in Neural Information Processing Systems* 29, 3765–73.
- Kamiya, J. (1968). Conscious control of brain waves. *Psychology Today*. 57-60.
- Klimesch, W., Freunberger, R., Sauseng, P. and Gruber, W. (2008). A short review of slow phase synchronization and memory: evidence for control processes in different memory systems? *Brain Res.* 1235 31–44
- Kopell, N., Ermentrout, B., Whittington, M. A. & Traub, R. (2000). Gamma rhythms and beta rhythms have different synchronization properties. *Proceedings of the National Academy of Sciences of the United States of America* 97, 1867–72.
- Kropotov, J. D. (2009). *Quantitative EEG, Event-Related Potentials and Neurotherapy*, Elsevier, AP
- Logemann, H. N. A., Lansbergen, M. M., Van Os, T. W. D. P., Böcker, K. B. E., and Kenemans, J. L. (2010). The effectiveness of EEG-feedback on attention, impulsivity and EEG: a sham feedback controlled study. *Neurosci. Lett.* 479, 49–53. doi: 10.1016/j.neulet.2010.05.026
- Lubar, J. F. and Shouse, M. N. (1976). EEG and behavioral changes in a hyperkinetic child concurrent with training of the sensorimotor rhythm (SMR): A preliminary report. *Biofeedback and Self-Regulation* 1, 293-306.
- Lachaux, J.-P., Rodriguez, E., Martinerie, J. & Varela, F. J. Measuring phase synchrony in brain signals. *Human Brain Mapping* 8, 194–208 (1999).
- May, G., Benson, R., Balon, R., and Boutros, N. (2013). Neurofeedback and traumatic brain injury: a literature review. *Ann. Clin. Psychiatry* 25, 289–296. doi: 10.5298/1081-5937-43.1.05
- Michels, L., Bucher, K., Lüchinger, R., Klaver, P., Martin, E., Jeanmonod, D. and Brandeis, D. (2010). Simultaneous EEG-fMRI during a working memory task: modulations in low and high frequency bands *PLoS One* 5 e10298
- Mohsenvand, M. N., Izadi, M. R. and Maes, P. (2020) Contrastive representation learning for electroencephalogram classification *Machine Learning for Health (PMLR)*, 238–53

- Naas, A., Rodrigues, J., Knirsch, J. P., and Sonderegger, A. (2019). Neurofeedback training with a low-priced EEG device leads to faster alpha enhancement but shows no effect on cognitive performance: a single-blind, sham-feedback study. *PLoS ONE* 14:e0211668. doi: 10.1371/journal.pone.0211668
- Nair, N. et al. (2020). Effects of stress on functional connectivity during problem solving. *Neuroimage* 208, 116407.
- Nathan, K. and Contreras-Vidal, J. L. (2016). Negligible motion artifacts in scalp electroencephalography (EEG) during treadmill walking *Front. Hum. Neurosci.* 9 708
- Pavlov, Y. G., & Kotchoubey, B. (2022). Oscillatory brain activity and maintenance of verbal and visual working memory: A systematic review. *Psychophysiology*, 59(5), e13735.
- Sauseng, P., Griesmayr, B., Freunberger, R. and Klimesch, W. (2010). Control mechanisms in working memory: a possible function of EEG theta oscillations *Neurosci. Biobehav. Rev.* 34 1015–22
- Schirrneister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W. and Ball, T. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization *Hum. Brain Mapp.* 38 5391–420
- Serman, M. B., Wyrwicka W., and Howe, R. (1969). Behavioral and neurophysiological studies of the sensorimotor rhythm in the cat," *Electroencephalogr Clin Neurophysiol*, vol. 27, pp. 678-9.
- Serman, M. B. and Friar L. (1972). Suppression of seizures in an epileptic following sensorimotor EEG feedback training. *Electroencephalography and Clinical Neurophysiology*, vol. 33, pp. 89-95.
- Thrun, S. and Pratt, L. (1998). *Learning to learn: introduction and overview* Learning to Learn (Amsterdam: Kluwer Academic Publishers) 3–17
- Tian, Y., Krishnan, D., and Isola, P. (2020). *Contrastive multiview coding* (Cham: Springer), 776–94
- Wilson, G. F., Swain, C. R. and Ullsperger, P. (1999). EEG power changes during a multiple level memory retention task *Int. J. Psychophysiol.* 32 107–18
- Tzagarakis, C., Thompson, A., Rogers, R. D. & Pellizzer, G. (2019). The Degree of Modulation of Beta Band Activity During Motor Planning Is Related to Trait Impulsivity. *Frontiers in Integrative Neuroscience* 13, 1–16, <https://doi.org/10.3389/fnint.2019.00001>.
- Wan, Z., Yang, R., Huang, M., Zeng, N. and Liu, X. (2021). A review on transfer learning in EEG signal analysis *Neurocomputing* 421 1–14
- Wróbel, A. (2014). Attentional Activation in Corticothalamic Loops of the Visual System. In: *The New Visual Neurosciences*, Eds John S. Werner and Leo M. Chalupa, pp. 339-349. The MIT press
- Wu, Z., Xiong, Y., Yu, S. X. and Lin, D. (2018). Unsupervised feature learning via non-parametric instance discrimination *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*, 3733–42
- Vernon, D., Frick, A., and Gruzelier, J. H. (2004). Neurofeedback as a treatment for ADHD: a methodological review with implications for future research. *J. Neurother.* 8, 53–82. doi: 10.1300/J184v08n02_04

Vollebregt, M. A., van Dongen-Boomsma, M., Buitelaar, J. K., and Slaats-Willemse, D. (2014). Does EEG-neurofeedback improve neurocognitive functioning in children with attention-deficit/hyperactivity disorder? A systematic review and a double-blind placebo-controlled study. *J. Child Psychol. Psychiatry* 55, 460–472. doi: 10.1111/jcpp.12143

Zappasodi, F. et al. (2014). Fractal dimension of EEG activity senses neuronal impairment in acute stroke. *PLoS ONE* 9, 1–8, <https://doi.org/10.1371/journal.pone.0100199>.

Zuberer, A., Brandeis, D., and Drechsler, R. (2015). Are treatment effects of neurofeedback training in children with ADHD related to the successful regulation of brain activity? A review on the learning of regulation of brain activity and a contribution to the discussion on specificity. *Front. Hum. Neurosci.* 9:135. doi: 10.3389/fnhum.2015.00135

5. Aktywność Naukowa

5.1. Neurofeedback-EEG

Jeszcze przed zakończeniem przewodu doktorskiego w Instytucie Biologii Doświadczalnej zostałem zaproszony przez Profesora Andrzeja Wróbla, kierującego wówczas Zakładem Neurofizjologii w Instytucie Biologii Doświadczalnej PAN im. M. Nenckiego, do współpracy w ramach grantu Narodowego Centrum Nauki, dotyczącego badania mechanizmów wzmacniania funkcji poznawczych metodą N-EEG. W trakcie realizacji, gdy pierwsze analizy wskazywały na brak istotnych efektów stosowanych szeroko paradygmatów N-EEG, podczas wspólnej narady z zespołem pracowni, powstała idea dalszych badań nad rozwojem metod neurofeedbacku, i opracowania nowych, skutecznych paradygmatów. W wyniku przeprowadzonych badań i analiz złożyliśmy, wspólnie z jednym z przedsiębiorstw obecnych na rynku aparatury EEG, wniosek grantowy do Narodowego Centrum Badań i Rozwoju w celu weryfikacji opracowanych paradygmatów. Wniosek ten uzyskał finansowanie a grant, którego efektem jest m.in. powstanie części artykułów opisanych w tej dysertacji, został zrealizowany i rozliczony, a założenia leżące u podstaw zastosowanej metody zaowocowały złożeniem wniosku patentowego, którego jestem współautorem.

Realizacja badań nad N-EEG pozwoliła opracować szczegółową metodę obiektywizacji i automatyzacji procedur treningowych, poprzez zastosowanie metod uczenia maszynowego. Analiza tej metody stała się podstawą drugiego wniosku grantowego, skierowanego do Funduszy Regionalnych. Ten wniosek również otrzymał finansowanie. W toku realizacji grantu nawiązałem współpracę z Wydziałem Fizyki oraz Wydziałem Matematyki i Informatyki, Uniwersytetu Jagiellońskiego oraz Wydziałem Fizyki Uniwersytetu Warszawskiego, w którym jestem obecnie zatrudniony.

Wyniki badań dotyczących skuteczności treningów N-EEG z wykorzystaniem sztucznych sieci neuronowych potwierdzają zasadność tego podejścia i są obecnie przygotowywane do publikacji. Testy psychofizjologiczne, weryfikujące skuteczność nowej metody, przeprowadzone przed i po serii treningów N-EEG, wykazały istotną poprawę w grupie eksperymentalnej poddanej treningowi z wykorzystaniem sprzężenia zwrotnego nadzorowanego przez sztuczną sieć neuronową. Poprawy takiej nie obserwowaliśmy natomiast w grupie kontrolnej (poddanej identycznej procedurze jak

grupa badana z wyjątkiem mechanizmu sprzężenia zwrotnego, który w tym przypadku był symulowany przez algorytm generujący odpowiedzi niezależne od starań osób badanych).

5.2. Analiza EEG z wykorzystaniem metod uczenia maszynowego

Zakończone sukcesem prace nad zastosowaniem metod uczenia maszynowego w N-EEG zainspirowały mnie do rozwijania badań związanych z wykorzystaniem sztucznej inteligencji do szeroko pojętej analizy sygnału EEG. Posiadając unikatowy i bardzo obszerny zestaw danych podłużnych ze spoczynkowych rejestracji EEG (pozyskanych w trakcie realizacji badań nad N-EEG) wspólnie z pracownikami naukowymi Warszawskiego Uniwersytetu Technicznego (WUT) podjęliśmy badania nad skutecznością weryfikacji tożsamości na podstawie sygnału spoczynkowego EEG. Dotychczasowe badania w tym zakresie opierały się na treningu sztucznych sieci neuronowych i potwierdzenia tożsamości na podstawie jednej rejestracji EEG podzielonej na wiele odcinków. Metoda ta obarczona jest kilkoma zasadniczymi wadami: po pierwsze pojedyncza rejestracja nie odpowiada założonym zastosowaniom tej metody, która ma służyć wielokrotnej weryfikacji tożsamości tej samej osoby, po drugie ogranicza zmienność sygnału wynikającą m.in. z różnic w impedancji elektrod, ich rozmieszczenia oraz stanu emocjonalnego danej osoby i wreszcie, używanie sygnału z tej samej rejestracji do treningu i testowania sztucznej sieci neuronowej prowadzi do przecieku danych ze zbioru treningowego do testowego. Uważałem, że powyższe ograniczenia powodują zawyżoną dokładność i czułość raportowanych wyników. W wyniku badań przeprowadzonych na danych podłużnych udało mi się udowodnić (Plucińska ... i Rogala, 2022, 2023), że testy prowadzone na pojedynczych rejestracjach zawyżają wyniki klasyfikacji. Ponadto, w trakcie badań określono minimalną liczbę sesji EEG zapewniającą stabilne wyniki.

Kolejnym krokiem w wykorzystaniu metod uczenia maszynowego do analizy sygnału EEG było pozyskanie, od jednego z głównych dostawców sprzętu EEG dla służby zdrowia, licencji na korzystanie z, prawdopodobnie największej na świecie, bazy klinicznych rejestracji EEG. Baza ta obejmuje ponad sto tysięcy zapisów i znajduje się obecnie w posiadaniu Centrum Badania Ryzyka Systemowego przy Uniwersytecie Warszawskim (o mojej działalności w ramach tego centrum wspominam na końcu niniejszego paragrafu). Ma ona docelowo służyć do opracowania biomarkerów zmian neurodegeneracyjnych oraz procesu starzenia. W celu realizacji tego zamierzenia nawiązałem współpracę z Profesorem Przemysławem Biekiem z Warszawskiego Uniwersytetu Technicznego. Już pierwsze efekty naszej współpracy zostały dostrzeżone na forum międzynarodowym – nasza prezentacja dotycząca predykcji wieku na podstawie EEG oraz EKG zdobyła drugie miejsce na “W3PHIAI-23 Aging Hackathon” organozowanego w ramach 7th International workshop on Health Intelligence (W3PHIAI-23) na konferencji AAAI-23 w Waszyngtonie. Starzenie się wpływa na organizmy w różny sposób, a wiek chronologiczny nie zawsze pokrywa się z wiekiem biologicznym, co można stosunkowo łatwo zaobserwować w przypadku chorób takich jak zespoły progeroidalne czy inne stany przyspieszonego starzenia się. Możliwość wykorzystania wiarygodnych predyktorów wieku chronologicznego, wieku biologicznego i ich wzajemnych relacji jest ważne zarówno dla celów diagnostycznych i prognostycznych (np. w przypadku współzachorowalności i śmiertelności), jak i dla badań oraz zastosowań klinicznych.

W celu zapewnienia dalszego finansowania badań nad biomarkerami starzenia się i zmian neurodegeneracyjnych złożyliśmy wniosek o dofinansowanie do europejskiego programu Horizon Europe. Dla realizacji tego wniosku udało mi się utworzyć Konsorcjum z udziałem WUT, Instytutu Technion z Izraela oraz Uniwersytetem w Pizie, we Włoszech.

5.3. Badania nad percepcją sztuki

Sztuka i mechanizm jej oddziaływania na człowieka stanowi przedmiot rozważań już od czasów starożytnej Grecji, dopiero jednak wyodrębnienie się psychologii, jako samodzielnej dziedziny wiedzy spowodowało, że badania nad odbiorem sztuki zostały poddane naukowej dyscyplinie. Za sprawą prac Fechner'a (1876) estetyka stała się jednym z pierwszych obiektów dociekań naukowych psychologii. Nowsze badania psychologiczne sugerują, że przeżycia wywołane kontaktem z dziełem sztuki mogą wynikać z odebrania komunikatu nadanego przez autora (Leder 2004), w którym dzieło gra rolę nośnika informacji. Nasuwa to myśl o wykorzystaniu teorii informacji, jako narzędzia badawczego w zrozumieniu mechanizmów oddziaływania sztuki. Pierwsze prace stosujące takie podejście pojawiły się w latach 60-tych XX wieku. Moles (1966) i Bense (1969), niezależnie od siebie, opisali dzieło artystyczne w kontekście porządku i złożoności wywodzących się z teorii informacji Shannona (1948).

Proces przepływu informacji od autora do odbiorcy, kluczowy z punktu widzenia odbioru intencjonalnego zamysłu autora i związanego z tym oddziaływania dzieła, nie był jednak dotychczas badany w całości. Teoretyczne rozważania nad potencjalnym mechanizmem kodowania/odkodowywania informacji, który mógłby się opierać na wspólnym zestawie pojęć używanych do opisu otaczającego świata, ukształtowanych przez zbliżone wpływy środowiskowe takie jak wykształcenie, pełnioną funkcją społeczną, obszar kulturowo-cywilizacyjny czy osobiste doświadczenie, zostały zawarte w opublikowanym artykule (Rogala i wsp. 2020). Opisane założenia teoretyczne posłużyły do opracowania i przeprowadzenia, wspólnie z Uniwersytetem Mikołaja Kopernika w Toruniu, eksperymentu badającego odbiór intencji zakodowanej w obrazach abstrakcyjnych. Eksperyment obejmował dwie wystawy, które odbyły się w renomowanej galerii sztuki w Toruniu i dwóch grup osób badanych. Pierwsza wystawa obejmowała prace abstrakcyjne współczesnej polskiej artystki, a druga obrazy wygenerowane przez losowo zaburzoną sztuczną sieć neuronową BigGAN (sieć typu GAN - Generative Adversarial Network). Sztuczna sieć neuronowa BigGAN jest siecią generatywną zdolną do wytwarzania fotorealistycznych obrazów na podstawie wpisania jednej z tysiąca wcześniej zdefiniowanych kategorii. W wyniku losowego zaburzenia wag sieci BigGAN powstały pseudo abstrakcyjne obrazy pozbawione intencji. W przeprowadzonym badaniu zebrano dane okulograficzne, EEG i kwestionariuszowe, a pierwsze wyniki przedstawione na dorocznej Konferencji Perypatetycznej organizowanej przez pracownię Human Interactivity and Language Laboratory na Uniwersytecie Warszawskim wskazują na istotne różnice w odbiorze tych wystaw, pomimo zastosowania tego samego formatu, wykonania (druk cyfrowy) i podstawowych właściwości wizualnych (dających podobne pobudzenie kory wzrokowej) prac prezentowanych na obu wystawach. Obecnie, we współpracy z Uniwersytetem Hertfordshire w Wielkiej Brytanii analizowane są również różnice w zakresie topologii obliczeniowej pomiędzy obrazami prezentowanymi na obu wystawach. Pierwsze wyniki wskazują na odmienną charakterystykę homologii algebraicznej pomiędzy obrazami wytworzonymi przez człowieka i wygenerowanymi przez zaburzoną sztuczną sieć neuronową.

6. Osiągnięcia organizacyjne oraz popularyzujące naukę

6.1. Centrum Badania Ryzyka Systemowego

Centrum Badania Ryzyka Systemowego (<https://cbrs.uw.edu.pl>), którego jestem współzałożycielem, powstało w ramach realizacji Działania I.3.2 „Zainicjowanie projektu badania ryzyka systemowego” w Priorytetowym Obszarze Badawczym V „W poszukiwaniu regionalnych rozwiązań dla globalnych wyzwań”, stanowiącym część projektu „Inicjatywa Doskonałości – Uniwersytet Badawczy” realizowanego przez Uniwersytet Warszawski.

Istotą działalności Centrum jest łączenie perspektywy i refleksji nauk społecznych i humanistycznych z bogactwem danych, które są domeną badaczy z obszaru nauk ścisłych i przyrodniczych. Wynika to z przekonania, że dla zrozumienia kryzysu cywilizacyjnego i znalezienia dróg wyjścia z niego trzeba łączyć precyzję modeli tworzonych przez nauki ścisłe z głębokim rozumieniem człowieka, społeczeństw i kultury właściwym naukom społecznym i humanistycznym. Wypracowane przez nauki ścisłe podejście do badań układów złożonych oferuje narzędzia pozwalające zrozumieć wieloaspektową dynamikę kryzysu i integrować perspektywy innych działów nauki.

Wśród zadań realizowanych przez Centrum znajduje się projekt, którego jestem współtwórcą i wykonawcą, dotyczący dynamiki społecznych i biologicznych układów złożonych. Celem tego projektu jest zaadaptowanie i wykorzystanie metod modelowania wypracowanych przez nauki przyrodnicze do rozumienia dynamiki złożonych układów społecznych. W ramach projektu przeprowadzana jest między innymi analiza procesów starzenia się. Starzenie się społeczeństw jest jednym z głównych zagrożeń systemowych współczesnej cywilizacji. Dzięki dostępowi do dużej bazy danych sygnałów EEG osób w różnym wieku (ponad 100 tysięcy rekordów) przy zastosowaniu zaawansowanych metod fizyki teoretycznej w połączeniu z możliwością budowania narzędzi i metod do klasyfikacji dużych baz danych prowadzimy prace zmierzające do opracowania modeli procesów starzenia się i rozpadu układów złożonych, które umożliwią wczesną diagnozę niekorzystnych zmian, zarówno na poziomie społeczeństwa jak i na poziomie fizjologii pojedynczego człowieka. Umożliwi to identyfikację potencjalnych mechanizmów kompensacyjnych pozwalających na wydłużenie sprawności intelektualnej i fizycznej. Projekt ten obejmuje również badanie mechanizmów oddziaływania sztuki na ośrodkowy układ nerwowy. Współczesne badania wskazują, że dzieło sztuki może być innym, niż bezpośredni opis, nośnikiem informacji pomiędzy artystą a odbiorcą. Badając przepływ informacji między metodami zapożyczonymi z metod teorii informacji, analizy tekstów oraz metodami obrazowania aktywności mózgu zamierzamy pokazać transfer informacji oraz jej oddziaływanie na sieci neuronowe mózgu odbiorcy. Pozwoli to lepiej zrozumieć społeczne mechanizmy funkcjonowania dzieła sztuki w aspekcie semantycznym.

6.2. Innowacyjność

Wykorzystując moje doświadczenia, które zebrałem podczas pracy nad badaniem N-EEG, wspólnie z jednym z polskich przedsiębiorstw złożyliśmy w kwietniu b.r. wniosek patentowy dotyczący prowadzenia treningu N-EEG w oparciu o paradygmat opóźnionego dopasowania do wzorca i zastosowania wielokanałowej głowicy EEG.

Doświadczenia składające się na część merytoryczną tego wniosku pozwoliły już na opracowanie, wspólnie z Instytutem Matki i Dziecka, wczesnego markera autyzmu u dzieci na podstawie rejestrowanych sygnałów EEG.

6.3. Współpraca krajowa i zagraniczna

W ramach prowadzonych badań naukowych udało mi się nawiązać bliską współpracę z następującymi instytucjami naukowymi:

- Instytut Matki i Dziecka w Warszawie: opracowanie markera EEG autyzmu;
- Uniwersytet Mikołaja Kopernika w Toruniu: badania nad percepcją sztuki;
- Warszawski Uniwersytet Techniczny: biomarkery starzenia i chorób neurodegeneracyjnych, weryfikacja tożsamości na podstawie sygnałów EEG;
- Uniwersytet Jagielloński: badania nad percepcją sztuki, analiza EEG z wykorzystaniem metod uczenia maszynowego;
- Instytut Biologii Doświadczalnej im. M. Nenckiego: badanie zmian w sygnale EEG wywołanych udarem;
- University of Hertfordshire: Topologia obliczeniowa obrazów artystycznych