

Klasyfikacja sygnałów EEG w interfejsach mózg-komputer z wykorzystaniem sieci neuronowych

Krzysztof Galas

Uniwersytet Kazimierza Wielkiego, Wydział Informatyki
Kopernika 1, 85-074 Bydgoszcz
e-mail: krzysztof.galas@ukw.edu.pl

Streszczenie: Celem pracy jest zaprezentowanie metod klasyfikacji sygnałów EEG w interfejsach mózg-komputer (BCI) z wykorzystaniem sieci neuronowych. Dzięki ich zdolności do modelowania złożonych zależności w danych, możliwe jest skuteczniejsze rozpoznawanie wzorców aktywności mózgowej, co przyczynia się do poprawy dokładności i szybkości działania systemów BCI. W pracy omówiono architektury sieci neuronowych wykorzystywane do analizy sygnałów EEG, takie jak sieci konwolucyjne (CNN) czy rekurencyjne (RNN). Badania pokazują, że te metody mają ogromny potencjał w zastosowaniach takich jak sterowanie urządzeniami wspomagającymi, komunikacja oraz rozrywka.

Słowa kluczowe: Interfejs mózg-komputer; EEG; Sieci neuronowe; Klasyfikacja sygnału przetwarzanie sygnałów

Classification of EEG signals at brain-computer interfaces using neural networks

Abstract: The aim of this paper is to present methods for classifying EEG signals in brain-computer interfaces (BCIs) using neural networks. Thanks to their ability to model complex relationships in the data, it is possible to recognise patterns of brain activity more effectively, which contributes to improving the accuracy and speed of BCI systems. This paper discusses neural network architectures used to analyse EEG signals, such as convolutional networks (CNNs) or recurrent networks (RNNs). The research shows that these methods have immense potential in applications such as assistive device control, communication, and entertainment.

Keywords: Brain-computer interface; EEG; Neural networks; Signal classification; Signal processing

1. Wprowadzenie

Współczesne interfejsy mózg-komputer otwierają nowe możliwości interakcji człowiek-komputer, wykorzystując aktywność mózgu do sterowania urządzeniami zewnętrznymi. Kluczowym elementem BCI jest efektywna klasyfikacja sygnałów elektroencefalograficznych, która pozwala na rozpoznanie intencji użytkownika. Sieci neuronowe, ze swoją zdolnością do uczenia się złożonych wzorców z danych, stały się dominującym podejściem w klasyfikacji sygnałów EEG dla BCI. Niniejsza praca przedstawia przegląd zastosowań sieci neuronowych w tej dziedzinie, omawiając różne architektury sieci, ich efektywność oraz wyzwania związane z ich implementacją. Sieci neuronowe odgrywają kluczową rolę w przetwarzaniu i klasyfikacji sygnałów EEG, ponieważ mogą wydobywać złożone wzorce z danych oraz adaptować się do indywidualnych różnic w aktywności mózgowej. Dzięki

ciągłym postępom w dziedzinie uczenia maszynowego i wzrastającej mocy obliczeniowej, zastosowania sieci neuronowych w interfejsach mózg-komputer będą się rozwijać, umożliwiając coraz bardziej precyzyjne i intuicyjne sterowanie urządzeniami zewnętrznymi za pomocą aktywności mózgu. Ponadto, integracja sieci neuronowych z innowacyjnymi technologiami, takimi jak rzeczywistość wirtualna, otwiera nowe możliwości interakcji człowiek-komputer, które mogą znacząco poprawić jakość życia osób z niepełnosprawnościami lub wspierać zdrowe osoby w codziennych czynnościach.

2. Sygnał EEG i interfejsy mózg-komputer


Elektroencefalografia jest techniką pomiarową pozwalającą na rejestrację aktywności elektrycznej mózgu [1]. Sygnały EEG odzwierciedlają dynamiczne zmiany potencjałów elektrycznych powstających na powierzchni głowy w

wyniku procesów neuronalnych [2]. Interfejsy mózg-komputer wykorzystują te sygnały do komunikacji i sterowania urządzeniami zewnętrznymi bez konieczności fizycznego ruchu.

Kluczową rolę w działaniu BCI odgrywa dokładna klasyfikacja wzorców aktywności mózgowej. Sieci neuronowe, ze względu na zdolność do modelowania złożonych zależności w danych, stały się dominującym podejściem w tej dziedzinie. Dzięki swojej mocy przetwarzania, sieci neuronowe umożliwiają efektywne wydobywanie istotnych cech z surowych sygnałów EEG, co przekłada się na wysoką skuteczność w rozpoznawaniu złożonych wzorców aktywności mózgowej. Dokładna klasyfikacja jest kluczowa dla prawidłowego działania interfejsów mózg-komputer, pozwalając na precyzyjne wykrywanie intencji użytkownika na podstawie rejestrowanych sygnałów EEG.

2.1. Pozyskiwanie sygnału EEG

W kontekście analizy EEG przez sieci neuronowe, pozyskiwane sygnały można podzielić na kilka rodzajów, w zależności od paradygmatu BCI i celu badania. Sygnały wywołane, takie jak P300 lub SSVEP, są często wykorzystywane w systemach BCI opartych na zadaniach wzrokowych. Sygnały związane z aktywnością ruchową, takie jak potencjały związane z ruchem, są wykorzystywane do sterowania protetycznymi kończynami lub innymi urządzeniami. Praca [3] opisuje wykorzystanie sygnałów EEG w wirtualnej rzeczywistości. Sygnały synchroniczne, takie jak aktywność mu i beta, odzwierciedlają stan spoczynku i aktywności kory ruchowej. Mogą być wykorzystywane do monitorowania zmęczenia lub koncentracji i pomagać w wykrywaniu senności u kierowców [4]. Wreszcie, sygnały EEG mogą być analizowane pod kątem aktywności oscylacyjnej w różnych pasmach częstotliwości, takich jak delta, theta, alfa, beta i gamma, co pozwala na badanie różnych stanów mózgu, np. snu, medytacji czy epilepsji [5]. Wybór odpowiedniego rodzaju sygnału EEG jest kluczowy dla skuteczności analizy przez sieci neuronowe i zależy od konkretnego zastosowania BCI. Ogólny schemat pozyskiwania sygnału EEG został przedstawiony (Rysunek 1).



Rysunek 1. Schemat działania przygotowania sygnału EEG.

3. Wyniki

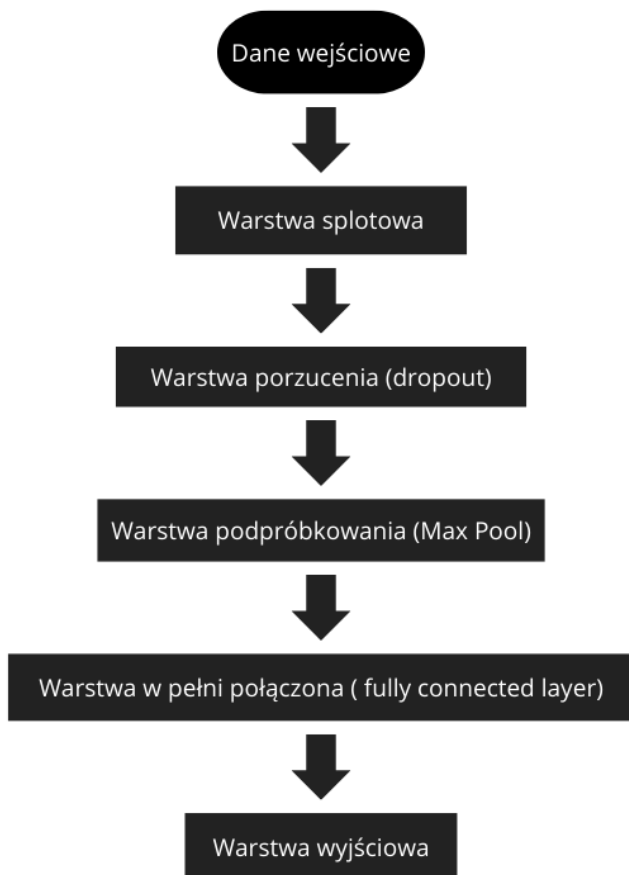
3.1. Architektury sieci neuronowych dla EEG w BCI

Sieci neuronowe zrewolucjonizowały dziedzinę interfejsów mózg-komputer, oferując skuteczne narzędzia do analizy złożonych sygnałów EEG. Ich możliwości w uczeniu się istotnych cech i klasyfikacji wzorców aktywności mózgowej pozwalają na znaczącą poprawę wydajności systemów BCI w różnych zastosowaniach, od rehabilitacji po interakcję w środowiskach wirtualnych.

3.1.1. Sieci konwolucyjne

Ten rodzaj sieci jest popularnym rozwiązaniem do analizy sygnałów EEG w BCI [7]. Ich struktura z warstwami konwolucyjnymi i podpróbkowania (Rysunek 2) pozwala na wydobycie cech z surowych danych EEG w sposób efektywny. Sieci rekurencyjne, takie jak LSTM, sprawdzają się z kolei w modelowaniu sekwencyjnych sygnałów EEG, uchwytyjąc czasowe zależności w aktywności mózgowej. Sieci konwolucyjne są szczególnie skuteczne w wyodrębnianiu istotnych cech z danych obrazowych, a ich zastosowanie do analizy sygnałów EEG okazało się przełomowe. Warstwy konwolucyjne w sieciach CNN wykorzystują filtry do przetwarzania surowych danych EEG, pozwalając na wykrywanie lokalnych wzorców i cech. Podejście to nie wymaga ręcznego wyodrębniania cech, upraszczając tym samym proces analizy i umożliwiając automatyczne uczenie się reprezentacji cech z surowych danych EEG. Przykładowe zastosowania obejmują detekcję artefaktów w sygnałach EEG oraz klasyfikację stanów mentalnych na podstawie EEG. Zdolność do automatycznego uczenia się cech z surowych danych EEG sprawia, że sieci CNN są o wiele wydajniejsze niż tradycyjne metody oparte na ręcznym projektowaniu cech. W rezultacie, sieci CNN osiągają wyższą dokładność

klasyfikacji i umożliwiają rozpoznawanie bardziej subtelnych wzorców w sygnałach EEG w porównaniu do wcześniejszych podejść. Co więcej, architektury CNN są na tyle elastyczne, że pozwalają na dalsze udoskonalenia, takie jak integracja z sieciami rekurencyjnymi w celu uwzględnienia zależności czasowych w sygnałach EEG.



Rysunek 2. Schemat działania sieci konwolucyjnej (splotowej).

Praca [8] proponuje hybrydowy interfejs mózg-komputer oparty na dwustrumieniowej sieci konwolucyjnej, łączącej paradygmaty stanu ustalonego wywołanego wzrokowo i wyobrażeń ruchowych. Sieć TSCNN automatycznie uczy się wyodrębnić cechy EEG w obu paradygmatach, co skutkuje wysoką dokładnością klasyfikacji na zestawie danych BCI Competition IV.

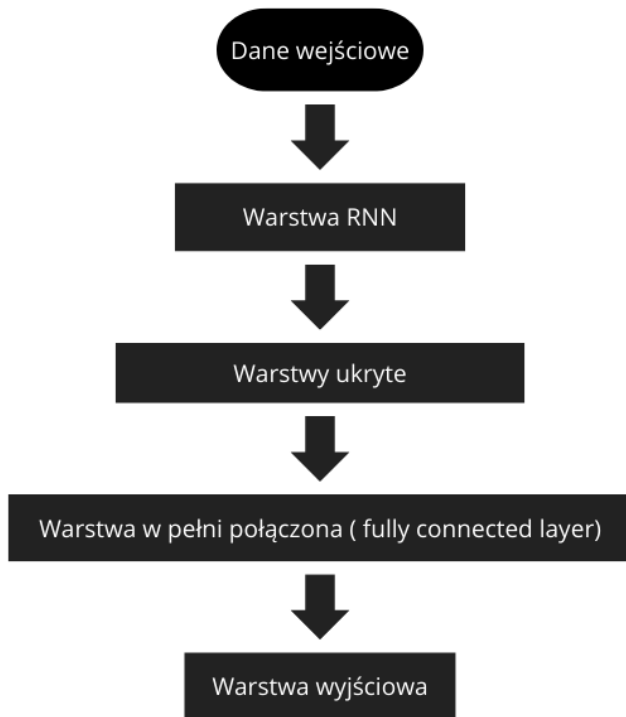
Praca naukowa [4] prezentuje nową, interpretowalną sieć neuronową przeznaczoną do wykrywania senności u kierowców na podstawie analizy sygnałów EEG. Proponowany model, określany jako "InterpretableCNN",

wykorzystuje separowalne sploty do przetwarzania danych EEG w sekwencji przestrzenno-czasowej. Kluczową zaletą tego rozwiązania jest możliwość interpretacji decyzji podejmowanych przez model, co umożliwia identyfikację konkretnych regionów sygnału wejściowego mających istotne znaczenie dla dokonywanych predykcji. W pracy autorzy koncentrują się na detekcji senności u kierowców, ten opracowany model może potencjalnie znaleźć zastosowanie w rozpoznawaniu innych stanów mentalnych.

3.1.2. Sieci rekurencyjne

Sieci rekurencyjne (Rysunek 3) są dobrze przystosowane do analizy danych sekwencyjnych, takich jak sygnały EEG, które mają wyraźny charakter czasowy. Ich architektura z pętlami sprzężenia zwrotnego umożliwia przechowywanie informacji o poprzednich stanach sygnału, pozwalając na modelowanie złożonych zależności czasowych w aktywności mózgowej rejestrowanej za pomocą EEG. Szczególnym typem RNN są sieci LSTM, które skutecznie rozwiązują problem zanikającego gradientu, czyniąc je bardziej wydajnymi w uczeniu się długoterminowych zależności w sygnałach EEG. W związku z tym, sieci rekurencyjne znajdują szerokie zastosowanie w interfejsach mózg-komputer, pozwalając na efektywne sterowanie tymi systemami w czasie rzeczywistym oraz precyzyjne przewidywanie intencji użytkownika na podstawie analizy sygnałów EEG.

Praca naukowa [9] przedstawia proste sieci neuronowe oparte na LSTM, które przetwarzają surowe sygnały EEG bezpośrednio w celu wykrywania napadów padaczkowych. Autorzy wykazali, że ich rozwiązanie cechuje się wysoką skutecznością w rozpoznawaniu tego typu zdarzeń na podstawie EEG, przy jednocześnie niskim zapotrzebowaniu na dane treningowe.



Rysunek 3. Schemat działania sieci rekurencyjnej.

3.1.3. Hybrydowe architektury sieci neuronowych

Hybrydowe architektury sieci neuronowych łączą w sobie elementy sieci CNN i RNN, aby wykorzystać zalety obu architektur. Na przykład, CNN mogą być używane do wyodrębniania istotnych cech z surowych danych EEG, zaś sieci rekurencyjne, takie jak LSTM, do modelowania zależności czasowych w aktywności mózgowej. Połączenie tych podejść pozwala na bardziej kompleksową analizę sygnałów EEG, co czyni je przydatnymi w zastosowaniach wymagających zarówno rozpoznawania wzorców, jak i analizy kontekstu czasowego, takich jak klasyfikacja stanów emocjonalnych czy detekcja zamierzeń użytkownika na podstawie sygnałów EEG. Hybrydowe architektury sieci neuronowych łączą siłę automatycznego wydobywania cech z danych CNN oraz zdolność do modelowania zależności czasowych RNN, co umożliwia skuteczniejsze wykrywanie i interpretację złożonych wzorców w sygnałach EEG w porównaniu do pojedynczych architektur. W efekcie, hybrydowe modele sieci neuronowych mogą osiągać lepsze wyniki w kluczowych zastosowaniach interfejsów mózg-

komputer, takich jak sterowanie urządzeniami, komunikacja lub rozpoznawanie emocji [8].

4. Dyskusja

Postęp w dziedzinie analizy EEG z wykorzystaniem sieci neuronowych doprowadził do znaczącej poprawy dokładności i wydajności w rozpoznawaniu wzorców i klasyfikacji stanów mentalnych. Badania, takie jak te opisane w pracy [5], demonstrują skuteczność CNN w wykrywaniu napadów padaczkowych na podstawie obrazów wykresów EEG, co ma istotne implikacje dla diagnostyki i leczenia epilepsji. Rozwój sieci rekurencyjnych, w szczególności LSTM, umożliwił efektywne modelowanie zależności czasowych w sygnałach EEG, co znajduje zastosowanie w interfejsach mózg-komputer [3]. Praca [10] omawia zastosowanie algorytmów machine learning i deep learning opartych na BCI w rehabilitacji poudarowej. Dodatkowo, hybrydowe architektury łączące CNN i RNN [11] pozwalają na jeszcze bardziej precyzyjną analizę sygnałów EEG, otwierając nowe możliwości w rozpoznawaniu emocji, intencji i innych złożonych stanów mentalnych. Te osiągnięcia przyczyniają się do rozwoju bardziej zaawansowanych i niezawodnych systemów BCI, które mogą zrewolucjonizować interakcję człowiek-komputer w różnych dziedzinach, od medycyny po rozrywkę.

4.1. Ograniczenia

Pomimo znacznego postępu w wykorzystaniu sieci neuronowych do analizy sygnałów EEG, wciąż istnieją wyzwania, które wymagają dalszej pracy badawczej. Należą do nich między innymi wrażliwość na artefakty, duża ilość danych potrzebna do uczenia oraz interpretacyjność modeli. Sieci neuronowe, choć wykazują wysoką skuteczność w klasyfikacji sygnałów EEG, są wciąż podatne na zakłócenia spowodowane przez artefakty ruchowe czy elektryczne. Opracowanie bardziej odpornych metod przetwarzania sygnału jest kluczowe dla zwiększenia niezawodności interfejsów mózg-komputer w warunkach rzeczywistych. Ponadto, głębokie uczenie wymaga dużych zbiorów starannie oznakowanych danych EEG, co może stanowić wyzwanie w niektórych zastosowaniach. Wreszcie, zrozumienie wewnętrznych mechanizmów sieci neuronowych klasyfikujących sygnały EEG pozostaje trudne, co ogranicza możliwość interpretacji ich decyzji i dalszego doskonalenia tych modeli. Przewyciężenie tych ograniczeń poprzez innowacyjne metody przetwarzania

sygnału, pozyskiwania danych oraz zwiększanie wyjaśnialności modeli będzie kluczowe dla dalszego rozwoju interfejsów mózg-komputer opartych na sieciach neuronowych.

Dokładność klasyfikacji sygnałów EEG przez różne sieci neuronowe jest zróżnicowana i zależy od wielu czynników, takich jak architektura sieci, specyfika zadania, jakość danych oraz metody przetwarzania wstępnego. Sieci CNN często osiągają wysoką dokładność w zadaniach klasyfikacji opartych na wyodrębnianiu cech, podczas gdy sieci RNN, takie jak LSTM, wykazują lepsze wyniki w analizie danych sekwencyjnych z zależnościami czasowymi. Hybrydowe architektury, łączące elementy CNN i RNN, mogą osiągać jeszcze wyższą dokładność, wykorzystując mocne strony obu podejść. Bezpośrednie porównanie dokładności różnych sieci jest trudne, gdyż publikowane wyniki odnoszą się do specyficznych zbiorów danych i warunków eksperymentalnych. Niemniej jednak, metaanalizy i przeglądy literatury sugerują, że sieci neuronowe generalnie przewyższają tradycyjne metody klasyfikacji sygnałów EEG, osiągając dokładność często przekraczającą 90% w optymalnych warunkach.

4.2. Wyzwania i kierunki rozwoju

Choć sieci neuronowe przyniosły znaczący postęp w klasyfikacji sygnałów EEG dla BCI, wciąż istnieją wyzwania, które wymagają dalszych badań:

- mała ilość danych treningowych: Problemy ze zbieraniem i etykietowaniem dużych zbiorów danych EEG ograniczają możliwości głębokiego uczenia. Pozyskanie większej ilości starannie oznakowanych danych EEG, na przykład poprzez automatyczne metody pozyskiwania i anotacji sygnałów, będzie kluczowe dla dalszego rozwoju modeli opartych na sieciach neuronowych,
- odporność na artefakty: Sieci neuronowe są wrażliwe na różnego rodzaju artefakty występujące w sygnałach EEG, takie jak mrugnięcia oczu czy napięcie mięśniowe,
- różnice międzysobnicze: Sygnały EEG charakteryzują się dużą zmiennością pomiędzy użytkownikami, co komplikuje opracowanie uniwersalnych modeli. Podejścia adaptacyjne lub personalizowane, uwzględniające indywidualne cechy sygnałów EEG, mogą pomóc w przewycięzeniu tych różnic [12],
- wydajność i niska liczba elektrod: Wymóg użycia wielu elektrod EEG utrudnia wdrażanie rozwiązań BCI poza laboratoriami. Opracowanie bardziej wydajnych algorytmów, zdolnych do działania na ograniczonej

liczbie elektrod, zwiększy mobilność i dostępność interfejsów mózg-komputer [12],

- interpretacja i wyjaśnialność modeli: Sieci neuronowe są często traktowane jak "czarne skrzynki", co komplikuje zrozumienie sposobu, w jaki klasyfikują sygnały EEG. Zwiększenie wyjaśnialności tych modeli, na przykład poprzez wizualizacje lub zastosowanie technik objaśniających, może pomóc w lepszym zrozumieniu i udoskonaleniu systemów BCI opartych na sieciach neuronowych [13].

5. Wnioski

Badania nad wykorzystaniem sieci neuronowych do analizy sygnałów EEG dla interfejsów mózg-komputer wykazały znaczną poprawę dokładności klasyfikacji w porównaniu z tradycyjnymi metodami. Architektury CNN, LSTM i hybrydowe, łączące oba podejścia, osiągają wysoką dokładność w zadaniach rozpoznawania stanów mentalnych, detekcji napadów padaczkowych oraz innych aplikacjach BCI rzędu 90% [9].

Mimo tych osiągnięć, wciąż istnieją wyzwania wymagające dalszych badań, takie jak wrażliwość na artefakty, duża ilość danych potrzebna do uczenia oraz interpretacyjność modeli. Przewycięzenie tych ograniczeń poprzez innowacyjne metody przetwarzania sygnału, pozyskiwania danych oraz zwiększanie wyjaśnialności modeli będzie kluczowe dla dalszego rozwoju interfejsów mózg-komputer opartych na sieciach neuronowych.

Literatura

1. Wosiak A., Dura A. Hybrid Method of Automated EEG Signals' Selection Using Reversed Correlation Algorithm for Improved Classification of Emotions. *Multidiscip Digit Publ Inst.* 2020. doi: 10.3390/s20247083.
2. Berestov R.M., Bobkov E.A., Belov V.S., Nevedin A.V. Brain-computer interface technologies for monitoring and control of bionic systems. *IOP Publ.* 2021. doi: 10.1088/1742-6596/2058/1/012030.
3. Piszcz A. BCI w VR: imersja sposobem na sprawniejsze wykorzystywanie interfejsu mózg-komputer. *Studia i Materiały Informatyki Stosowanej.* 2021, 13(1), 5-10.
4. Jian C. et al. EEG-Based Cross-Subject Driver Drowsiness Recognition With an Interpretable CNN. 2022.
5. Emami A., Kunii N., Matsuo T., Shinozaki T., Kawai K., Takahashi H. Seizure detection by convolutional neural network-based analysis of scalp electroencephalography plot images. Elsevier BV. 2019.
6. Piszcz A., Rojek I., Mikołajewski D. Impact of Virtual Reality on Brain-Computer Interface Performance in IoT Control—

- Review of Current State of Knowledge. *Multidiscip Digit Publ Inst.* 2024. doi: 10.3390/app142210541.
7. Gu X. et al. EEG-Based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and Their Applications. *IEEE/ACM Trans Comput Biol Bioinform.* 2021, 18(5), 1645. doi: 10.1109/tcbb.2021.3052811.
 8. Luo W., Yin W., Liu Q., Qu Y. A hybrid brain-computer interface using motor imagery and SSVEP Based on convolutional neural network. 2023. doi: 10.1080/27706710.2023.2258938.
 9. Ahmedt-Aristizabal D., Fookes C., Nguyen K., Sridharan S. Deep Classification of Epileptic Signals. 2018. doi: 10.1109/embc.2018.8512249.
 10. El-Ashmawi W.H. et al. A Comprehensive Review on Brain–Computer Interface (BCI)-Based Machine and Deep Learning Algorithms for Stroke Rehabilitation. *Multidiscip Digit Publ Inst.* 2024, 14(14), 6347.
 11. Zhang L, Xia B., Wang Y., Zhang W., Han Y. A Fine-Grained Approach for EEG-Based Emotion Recognition Using Clustering and Hybrid Deep Neural Networks. *Multidiscip Digit Publ Inst.* 2023.
 12. Carrara I., Aristimunha B., Corsi M., de Camargo R.Y., Chevallier S., Papadopoulo T. Geometric Neural Network based on Phase Space for BCI decoding. Cornell University. 2024. doi: 10.48550/arxiv.2403.05645.
 13. Ali O., Saif-ur-Rehman M., Dyck S., Glasmachers T., Iossifidis I., Klaes C. Enhancing the decoding accuracy of EEG signals by the introduction of anchored-STFT and adversarial data augmentation method. *Nature Portfolio.* 2022. doi: 10.1038/s41598-022-07992-w.