

Sztuczna inteligencja w analizie EEG

Artificial Intelligence in EEG Analysis

Mateusz Stachowicz

Specjalista zarządzania, specjalista AI (zarządzanie danymi z wykorzystaniem AI w badaniach psychologicznych).

Cytowanie:

Stachowicz, M. (2025). Sztuczna inteligencja w analizie EEG. *Zeszyty Naukowe Wyższej Szkoły Kadr Menedżerskich*, 15 (2025), art. 167, s. 79–83. DOI: 10.5281/zenodo.16993471

Przyjęto: 25.07.2025

Zaakceptowano: 28.08.2025

Opublikowano: 05.09.2025

Abstrakt: Postęp w dziedzinie sztucznej inteligencji (SI) znacząco przyspiesza rozwój neurologii i neurofizjologii, umożliwiając precyzyjną analizę sygnałów EEG. Artykuł omawia kluczowe komponenty systemów SI w kontekście danych EEG, w tym przepływy danych, modele danych oraz algorytmy uczenia maszynowego. Przedstawiono strukturę danych EEG, uwzględniając surowe szeregi czasowe obarczone artefaktami oraz metadane dotyczące urządzeń, protokołów i kontekstu klinicznego. Omówiono zaawansowane metody, takie jak connectomics, analiza sieci dynamicznych, symulacyjne wnioskowanie bayesowskie oraz harmonizacja danych. Podkreślono integrację systemów RAG z wiedzą medyczną, architektury augmented memory oraz neuro-inspired approaches. Wyodrębniono kluczowe zastosowania SI w neurologii, w tym diagnostykę obrazową, detekcję napadów i medycynę precyzyjną. Przedstawiono nowe kierunki, obejmujące modele foundation, podejścia multimodalne oraz interfejsy adaptacyjne. Analiza opiera się na standardach, takich jak EEG-BIDS i HED, zapewniających spójność przetwarzania. Wyniki wskazują na poprawę dokładności i efektywności modeli dzięki wysokiej jakości danych i zaawansowanym algorytmom. Wnioski podkreślają konieczność integracji biologicznych inspiracji w SI dla lepszego wspomagania decyzji klinicznych.

Słowa kluczowe: sztuczna inteligencja, EEG, uczenie maszynowe, neurologia, analiza sygnałów

Wstęp

Obecny postęp technologiczny w obszarze sztucznej inteligencji (SI) pozwala oczekiwać znaczącego przyspieszenia badań w neurologii i neurofizjologii. Historyczne demonstracje, takie jak zwycięstwo systemu Deep Blue (IBM) nad Garrim Kasparowem w 1997 roku, pokazały, że systemy obliczeniowe mogą osiągać doskonałe wyniki w wąsko zdefiniowanych zadaniach. Od tego czasu nastąpił znaczący wzrost wiedzy w dziedzinie inżynierii danych i uczenia maszynowego, co spowodowało spadek kosztów eksperymentowania i rozwijają coraz nowsze metody, dzięki którym sztuczna inteligencja osiąga wyższą precyzję w wielu dziedzinach.

Aby zdefiniować model sztucznej inteligencji, należy rozróżnić trzy komplementarne składowe, które wspólnie determinują jakość wyników:

Licencja:

This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>)

- przepływy danych – struktury dynamiczne (szeregi czasowe) opisujące wartość w czasie, przetwarzane i kierowane do modeli;
- modele danych – struktury statyczne (schematy, słowniki, reprezentacje) definiujące sposób reprezentacji informacji oraz jej powiązanie z metadanymi;
- modele uczenia maszynowego – algorytmy prognostyczne i opisowe, które uczą się z danych i formułują predykcje lub reprezentacje.

Przepływy danych stanowią fundament całego procesu, ponieważ determinują wymiary przestrzeni liczbowej. W obszarze EEG są to szeregi czasowe opisujące zachowanie amplitudy w czasie.

Modele danych definiują wymiarowość i skalę pomiarową przestrzeni cech, narzucają ograniczenia (np. kompletność metadanych, spójność kanałów i montażu) oraz łączą surowe pomiary z reprezentacjami użytecznymi dla modeli (np. PSD, cechy czasowo-częstotliwościowe, macierze łączności, kategorie klastrów zdarzeń).

Metody prognostyczne można klasyfikować według struktury modelu na: modele liniowe (regresja liniowa, regresja logistyczna, maszyny wektorów nośnych), modele drzew decyzyjnych (drzewa decyzyjne, lasy losowe, XGBoost) oraz modele sieci neuronowych (w tym architektury konwolucyjne, rekurencyjne i transformerowe). Rezultatem działania modelu jest uogólnienie zjawiska oraz – w stopniu zależnym od modelu i strumienia danych – zdolność interpretacji zmiennych objaśniających. Górną granicę jakości predykcji wyznacza nie tylko sam model, lecz przede wszystkim jakość i spójność danych oraz przyjęty model danych.

W praktyce badawczej i komercyjnej to badacz wybiera procedury wstępnego przetwarzania danych (data preprocessing), inżynierię cech (feature engineering) oraz selekcję cech (feature selection). Każda z tych procedur istotnie wpływa na wynik i stabilność modeli. Z praktycznego punktu widzenia kolejność prac nad budową systemu sztucznej inteligencji powinna być następująca:

Identyfikacja zmiennej objaśnianej (target variable) – wartość, którą model statystyczny próbuje oszacować lub przewidzieć. Zmienna objaśniana może być ciągła lub kategoriowa. Jest to kluczowa procedura ze względu na

wpływ na dobór zmiennych objaśniających i algorytmów.

Identyfikacja zmiennych objaśniających, zdefiniowanie modelu danych, w którym ta zmienna występuje i jest mierzalna. Głównym ograniczeniem może być słaba jakość danych. Jest to kluczowa procedura projektowania modelu sztucznej inteligencji.

Dobór algorytmów i procedur uczenia. Aplikowanie metod uczenia maszynowego na model danych sztucznej inteligencji. Najtrudniejszy technicznie etap. Wymaga pogłębionej znajomości specjalistycznych bibliotek związanych z SI. Wiele bibliotek nie zawiera kluczowych komponentów.

Badacz dobiera modele uczenia maszynowego zgodnie z celem i ograniczeniami danych, trenuje je na precyzyjnie zdefiniowanym modelu danych, a wyniki raportuje zawsze wraz z wersją modelu i strumienia przepływu danych (parametry, normy). Ta spójność zapewnia replikowalność badań i umożliwia porównywanie wyników między różnymi studiami.

Model Danych EEG

Dane EEG są z natury surowe, gęsto próbkowane i obarczone artefaktami (mrugnięcia, ruchy, EMG, dryf elektrod). Ich pozyskanie i oznaczanie wymagają dyscypliny protokołu oraz rozbudowanych metadanych, podzielonych na:

- urządzenia i formaty: różne systemy (laboratoryjne, kliniczne, mobilne) zapisują sygnał w formatach EDF, BrainVision, XDF lub strumieniują za pomocą LSL; różnią się impedancją, wzmocnieniem, pasmem i liczbą kanałów,
- protokoły i znaczniki: paradygmaty zadaniowe lub odpoczynkowe, znaczniki zdarzeń (trigger), warunki (otwarte lub zamknięte oczy), leki, sen lub stan czuwania,
- montaż i parametry: układy 10–20 lub 10–10, częstotliwość próbkowania, referencja, filtry sprzętowe,
- kontekst kliniczny lub behawioralny: rozpoznania, skale, wyniki testów, lewo- lub prawostronność, wiek.

Te elementy metadanych zapewniają kontekst niezbędny do prawidłowej interpretacji danych i ich integracji w modelach SI.

Connectomics i analiza sieci dynamicznych

Connectomics w EEG wykracza poza statyczne macierze łączności, obejmując dynamiczne modele sieciowe i metryki topologiczne. Te metody umożliwiają identyfikację hierarchicznych wzorców organizacji sieciowej oraz przejść między stanami funkcjonalnymi mózgu. Kluczowe metody obejmują:

- modularność i partycjonowanie sieci – algorytmy Louvain i k-means modularity, które identyfikują spójne społeczności węzłów;
- metody analizy grafów – degree centrality, eigenvector centrality, diffusion efficiency oraz participation coefficient, które mierzą rolę poszczególnych węzłów w architekturze sieci;
- dynamiczne modele łączności – sliding windows, hidden Markov models (HMM) oraz time-varying graphs, które uchwytują ewolucję wzorców łączności w czasie;
- co-activity gradients – niskowymiarowe reprezentacje aktywności sieciowej, które można aproksymować przez komponenty sieci co-neighbor (współsąsiedzkich), gdzie węzły łączą się na podstawie liczby wspólnych najbliższych sąsiadów.

Te podejścia pozwalają na głębsze zrozumienie dynamiki mózgu, co jest kluczowe dla zastosowań klinicznych.

Zaawansowane metody analizy sygnału

Współczesne strumienie analizy EEG integrują metody uczenia głębokiego z klasycznymi technikami przetwarzania sygnału.

- Simulation-Based Inference (SBI) reprezentuje nowe podejście bayesowskie, które wykorzystuje sieci neuronowe do estymacji rozkładów a posteriori bez potrzeby jawnej funkcji wiarygodności, co jest szczególnie użyteczne w analizie złożonych modeli neurofizjologicznych.
- Ensemble-based approaches łączą różne metryki łączności (korelacja Pearsona, standardowe odchylenia, średnie wartości) w pojedyncze grafy zespołowe, osiągając wyższą dokładność klasyfikacji niż tradycyjne grafy korelacyjne.
- Neuro-inspired architectures czerpią inspirację z biologicznych obwodów neuronalnych, implementując modularną, hierarchiczną i rzadką łączność, co prowadzi do bardziej efektywnych energetycznie i interpretowalnych modeli.

Integracja tych metod poprawia precyzję analizy, umożliwiając lepsze wykrywanie subtelnych wzorców w sygnałach EEG.

Zaawansowane metody harmonizacji i ulepszenia danych

Współczesne podejścia do poprawy jakości danych neuroobrazowych wykraczają poza tradycyjne metody preprocessingu.

- FastFOD-Net (Wang, 2025) reprezentuje przełomowe podejście do ulepszania obrazowania dyfuzyjnego (DWI), które wykorzystuje uczenie głębokie do transformacji danych.
- ComBat harmonization (Orlhcac i in., 2022) rozszerza te podejścia o harmonizację międzyośrodkową, która adresuje systematyczne różnice w protokołach akwizycji i sprzęcie poprzez modelowanie efektów batch i normalizację rozkładów cech.

Te techniki zapewniają spójność danych z różnych źródeł, co jest niezbędne w badaniach wieloośrodkowych.

Standardy i praktyki

- EEG-BIDS (BEP006) definiuje strukturę katalogów i plików, słowniki metadanych (np. channels.tsv, electrodes.tsv, events.tsv) oraz konwencje nazewnictwa, co ułatwia replikację i łączenie zbiorów (BIDS - The Brain Imaging Data Structure, b.d.);
 - HED (Hierarchical Event Descriptors) umożliwia precyzyjne, hierarchiczne tagowanie zdarzeń i warunków eksperymentalnych w events.tsv (Hierarchical Event Descriptors, b.d.);
 - dobra praktyka MNE: filtracja pasmowo-przepustowa z filtrami liniowymi FIR o zerowej fazie, notch 50/60 Hz, ostrożność wobec filtrów o zbyt stromych zboczach i przedłużaniu sygnału (edge effects), rereferencja do średniej lub odniesień określonych protokołem, ICA/SSP po filtracji i usunięciu segmentów skrajnych (MNE Developers, b.d.);
 - LSL: synchronizacja zegarów strumieni i znaczników czasu pozwala uzyskać małe błędy czasowe; zaleca się pomiar latencji/jittera w docelowej konfiguracji i logowanie opóźnień przy projektach BCI (Swartz Center for Computational Neuroscience, b.d.).
- Ręczne oznaczanie artefaktów, segmentów patologicznych czy odpowiedzi wywołanych jest czasochłonne i poznawczo obciążające dla neurologa lub psychologa, a przy tym mało

skalowalne. Bez zaplecza statystyczno-matematycznego i umiejętności programistycznych trudno budować spójne modele danych dla uczenia maszynowego. Dlatego standardy te ułatwiają automatyzację i współpracę między specjalistami.

Human-Machine Interface

BCI stanowi w praktyce dominujący kontekst akwizycji danych EEG dla zastosowań SI. Integracja interfejsów człowiek-maszyna z zaawansowanymi modelami SI otwiera nowe możliwości w neurologii.

Systemy RAG i integracja wiedzy medycznej

Współczesne podejścia do BCI wykraczają poza klasyczne paradygmaty, integrując systemy Retrieval-Augmented Generation (RAG) z analizą EEG. EEG-MedRAG (Yi, 2025) reprezentuje przełomowe podejście, które wykorzystuje trójwarstwową strukturę hipergrafu do integracji sygnałów EEG, danych pacjenta i wiedzy medycznej. System ten adresuje kluczowe wyzwania: (i) modelowanie relacji między encjami klinicznymi, (ii) wspólne pobieranie semantyczno-czasowych danych EEG wraz ze strukturalnymi rekordami pacjenta, oraz (iii) unifikację cross-disease, cross-role benchmarków EEG. EEG-MedRAG funkcjonuje jako inteligentny asystent diagnostyczny dla lekarzy, system monitorowania dla pielęgniarek, narzędzie treningowe dla stażystów oraz platforma edukacyjna dla pacjentów, demonstrując potencjał integracji multimodalnych danych w wspomaganiu decyzji klinicznych.

Memory-augmented architectures i neuro-inspired approaches

Nowoczesne architektury BCI integrują mechanizmy pamięciowe inspirowane neurobiologią, które adresują fundamentalne ograniczenia standardowych transformerów. Memory-Augmented Transformers (Wu, 2020) implementują dynamiczne mechanizmy pamięciowe, które umożliwiają ciągłe uczenie się, adaptację do nowych kontekstów oraz efektywne energetycznie przetwarzanie informacji. Te architektury czerpią inspirację z hierarchicznej organizacji pamięci biologicznej: pamięci sensorycznej (krótkotrwałe retencje bodźców), pamięci roboczej (krótkoterminowe przetwarzanie) oraz pamięci długoterminowej (uczenie się przez całe życie). Neuro-inspired Ensemble-to-Ensemble

Communication Primitives (Konstantaropoulos, 2025) implementują rzadkie, modułowe wzorce łączności inspirowane biologicznymi obwodami neuronalnymi, osiągając wyższą wydajność w zadaniach wizyjnych przy jednoczesnym zmniejszeniu obciążenia obliczeniowego.

Kluczowe obszary zastosowań ML w neurologii

- diagnostyka obrazowa: segmentacja i klasyfikacja w MRI/CT (np. UNet/CNN) dla guzów, udarów, zaniku; wsparcie diagnozy i planowania terapii;
- EEG – detekcja napadów i nieprawidłowości: klasyczne cechy + CNN/LSTM; znaczniki kliniczne i alarmy czasu rzeczywistego;
- medycyna precyzyjna: modele łączące dane kliniczne, neuroobrazowe i omiczne do przewidywania odpowiedzi na leczenie i stratyfikacji ryzyka;
- monitorowanie i systemy wspomagania decyzji: dane z urządzeń noszonych lub łóżek szpitalnych, wykrywanie pogorszenia, rekomendacje terapii; wymagane silne metadane i nadzór kliniczny.

Te obszary demonstrują praktyczne korzyści z zastosowania uczenia maszynowego w codziennej praktyce neurologicznej.

- Emotion mapping i analiza afektywna
- Calcium imaging i analiza aktywności neuronalnej
- Language models alignment i reprezentacje koncepcyjne
- Zaawansowane modele dla neuroobrazowania
- Nowe kierunki w SI dla neurologii
- Foundation models i modele pretrenowane
- Multimodalne podejścia i integracja danych
- Neuro-inspired architectures i bio-inspirowane mechanizmy
- Accessibility i interfejsy adaptacyjne
- Wybrane standardy i wytyczne związane z EEG

W ekosystemie EEG ugruntowały się standardy organizacji i przetwarzania danych (EEG-BIDS, HED, zalecenia MNE, formaty EDF/BrainVision/XDF oraz strumienie LSL), które porządkują akwizycję, opis zdarzeń, przetwarzanie i wymianę informacji między ośrodkami. (stan na sierpień 2025)

Abstract

Advances in artificial intelligence (AI) significantly accelerate progress in neurology and neurophysiology, enabling precise EEG signal analysis. The article discusses key components of AI systems in the context of EEG data, including data flows, data models, and machine learning algorithms. The structure of EEG data is presented, considering raw time series burdened with artifacts and metadata regarding devices, protocols, and clinical context. Advanced methods such as connectomics, dynamic network analysis, simulation-based Bayesian inference, and data harmonization are reviewed. The integration of RAG systems with medical knowledge, memory-augmented architectures, and neuro-inspired approaches is emphasized. Key applications of AI in neurology are highlighted, including imaging diagnostics, seizure detection, and precision medicine. New directions are outlined, encompassing foundation models, multimodal approaches, and adaptive interfaces. The analysis relies on standards like EEG-BIDS and HED, ensuring processing consistency. Results indicate improved model accuracy and efficiency through high-quality data and advanced algorithms. Conclusions stress the need for integrating biological inspirations in AI for better clinical decision support.

Keywords: artificial intelligence, EEG, machine learning, neurology, signal analysis

Bibliografia

- American Clinical Neurophysiology Society. (b.d.). *Guideline 1: Minimum technical requirements for performing clinical EEG*. <https://www.acns.org/pdf/guidelines/Guideline-1.pdf>
- BIDS - The Brain Imaging Data Structure. (b.d.). <https://bids.neuroimaging.io/>
- Brain Products. (b.d.). *BrainVision Analyzer 2 - Supported file formats*. <https://www.brainproducts.com/support-resources/brainvision-analyzer-supported-file-formats/>
- European Data Format (EDF). (b.d.). <https://www.edfplus.info/>
- Hierarchical Event Descriptors (HED). (b.d.). <https://www.hedtags.org/>
- Konstantaropoulos, O. (2025). *Neuro-inspired ensemble-to-ensemble communication primitives for sparse and efficient ANNs*. arXiv. <https://doi.org/10.48550/arXiv.2508.14140>
- MNE Developers. (b.d.). *MNE best practices*. <https://mne.tools/stable/>
- National Institute of Neurological Disorders and Stroke. (b.d.). *NINDS common data elements*. <https://www.ninds.nih.gov/current-research/scientific-resources/ninds-common-data-elements>
- Orlhac, F., Eertink, J. J., Cottureau, A.-S., Zijlstra, J. M., Thieblemont, C., Meignan, M., Boellaard, R., & Buvat, I. (2022). A guide to ComBat harmonization of imaging biomarkers in multicenter studies. *Journal of Nuclear Medicine*, 63(2), 172–179. <https://doi.org/10.2967/jnumed.121.262464>
- Swartz Center for Computational Neuroscience. (b.d.). *Extensible data format (XDF)* [Repository]. GitHub. <https://github.com/sccn/xdf>
- Swartz Center for Computational Neuroscience. (b.d.). *Lab streaming layer (LSL)*. <https://labstreaming-layer.readthedocs.io/>
- Wang, X. (2025). *From promise to practical reality: Transforming diffusion MRI analysis with fast deep learning enhancement*. arXiv. <https://doi.org/10.48550/arXiv.2508.10950>
- Wu, Q. (2020). *Memformer: A memory-augmented transformer for sequence modeling*. arXiv. <https://doi.org/10.48550/arXiv.2010.06891>
- Yi, W. (2025). *EEG-MedRAG: Enhancing EEG-based clinical decision-making via hierarchical hypergraph retrieval-augmented generation*. arXiv. <https://doi.org/10.48550/arXiv.2508.13735>