

КЛАСИФІКАЦІЯ СТАНУ ОЧЕЙ НА ОСНОВІ ДЕКОМПОЗИЦІЇ ЕЛЕКТРОЕНЦЕФАЛОГРАМ З УРАХУВАННЯМ ДИПОЛЬНОЇ ПРИРОДИ СИГНАЛІВ МОЗКУ

Анотація. Запропоновано підхід до класифікації стану очей (відкриті/закриті) за 64-канальними ЕЕГ-даними на основі ІСА-декомпозиції з валідацією компонент підбором еквівалентних диполів. Для підбору диполя розроблено оригінальну функцію втрат із L2-регуляризацією та еліпсоїдним анатомічним обмеженням на основі тривимірної моделі мозку. Серед ІСА-компонент ідентифіковано джерела з характерними альфа-, му-, бета- та гамма-ритмами, що підтверджує фізіологічну інтерпретованість методу. Класифікація нейронною мережею на основі 507 ознак досягла точності 97% на навчальній та 90% на тестовій вибірці.

Ключові слова: ЕЕГ, електроенцефалограма, ІСА, диполь, класифікація станів мозку, нейронна мережа, спектральний аналіз, декомпозиція сигналів, сліпе розділення сигналів, локалізація джерел, обчислювальна нейронаука, просторово-часова динаміка біокібернетика, BCI, NeuroAnalyzer, Julia.

Постановка проблеми. Класифікація станів мозкової активності за даними електроенцефалографії (ЕЕГ) є важливим завданням як для фундаментальних нейронаук, так і для практичних застосувань у сфері нейроінтерфейсів. Зокрема, розрізнення станів відкритих та закритих очей дозволяє оцінити рівень розслабленості та концентрації, що є базовою задачею для мозково-комп'ютерних інтерфейсів.

У попередніх роботах [1] та [2] було досліджено спектральний аналіз ЕЕГ-сигналів, який забезпечив точність класифікації на рівні 70–80%, а також кількісний рекурентний аналіз, що підвищив точність до 95% для потиличних електродів. Однак обидва підходи базувалися на безпосередньому аналізі сигналів окремих електродів, які є сумішшю активності багатьох мозкових джерел та артефактів. Це обмежує як точність класифікації, так і можливість фізіологічної інтерпретації результатів.

Перспективним напрямком є використання аналізу незалежних компонент (ІСА), який дозволяє розділити змішані електродні сигнали на статистично незалежні джерела. У поєднанні з підбором еквівалентних диполів це дає змогу валідувати отримані компоненти як фізіологічно достовірні мозкові сигнали та відсіяти артефакти. Такий підхід потенційно забезпечує більш надійну класифікацію, оскільки працює безпосередньо з мозковими джерелами, а не з їхніми змішаними проєкціями на електроди.

Аналіз останніх досліджень і публікацій. Класифікація стану очей за EEG-даними досліджувалася авторами раніше. У першій роботі [1] застосовувався спектральний аналіз із використанням швидкого перетворення Фур'є, який продемонстрував стабільну точність розпізнавання на рівні 70–80%. У подальшій роботі було запропоновано метод класифікації на основі кількісного рекурентного аналізу, який дозволив підвищити точність до 95% для потиличних електродів (O1, O2) при використанні класифікатора на основі методу опорних векторів (SVM, Support Vector Machine). Обидва дослідження проводилися на базі даних *EEG Motor Movement/Imagery Dataset* [3], що містить записи від 109 учасників. Однак подальший аналіз з використанням методів детектування пошкоджених каналів виявив значні проблеми з якістю частини записів у цьому датасеті, що мотивувало пошук більш надійних методів попередньої обробки сигналів.

Одним із найбільш перспективних підходів до попередньої обробки EEG-даних є аналіз незалежних компонент (ICA, Independent Component Analysis). Фундаментальні засади цього методу описано у роботі Гіварінена та Ойя [4], де ICA визначається як метод знаходження лінійного представлення негаусівських даних таким чином, щоб компоненти були максимально статистично незалежними. У цій роботі представлено алгоритм FastICA — ефективну ітераційну схему з фіксованою точкою для знаходження незалежних компонент шляхом максимізації негаусівськості. Метод має широке застосування, зокрема для сліпого розділення сигналів (класична «задача коктейльної вечірки»), виділення ознак у зображеннях та обробки біомедичних сигналів.

Першу успішну спробу застосування ICA до електроенцефалографічних даних було здійснено Мейкігом та співавторами [5]. Автори показали, що ICA-алгоритм Белла та Сейновського ефективно розділяє проблему ідентифікації джерела від його локалізації. Результати продемонстрували: (1) нечутливість навчання до різних початкових умов; (2) здатність ICA сегрегувати артефактні компоненти (шум мережі, рухи очей, м'язову активність) від мозкових сигналів; (3) можливість ізолювання накладених EEG-феноменів, включаючи альфа- та тета-сплески; (4) відстеження нестационарностей у EEG та поведінковому стані через зміни залишкової кореляції між ICA-каналами.

Глибоке порівняння різних ICA-алгоритмів для EEG-даних було проведено Делором та співавторами [6]. Автори застосували 22 різних алгоритми ICA та сліпого розділення джерел (BSS, Blind Source Separation) до 13 наборів 71-каналних EEG-даних і оцінили їх за трьома показниками: зменшення взаємної інформації (MIR, Mutual Information Reduction), залишкова попарна взаємна інформація (PMI, Pairwise Mutual Information) та ступінь відповідності дипольній моделі (dipolarity) — відповідність скальпових карт проекції одного еквівалентного диполя. Найменш ефективним виявився метод головних компонент (PCA, Principal Component Analysis), а найкращі результати показали AMICA та інші ICA-методи на основі правдоподібності. Було встановлено практично лінійний зв'язок між ефективністю зменшення взаємної інформації та кількістю компонент із високою відповідністю дипольній моделі, що підтверджує: алгоритми, які краще розділяють незалежні компоненти, також створюють більш фізіологічно достовірні скальпові карти. Незважаючи на менші абсолютні показники

FastICA порівняно з Infomax, результати цього алгоритму є загалом задовільними для практичного застосування.

Ефективність ICA для очищення ЕЕГ від артефактів наочно продемонстрована у роботі Делорма та співавторів [7], де метод застосовувався для видалення рухів очей та м'язового шуму з даних візуальної селективної уваги. Авторам вдалося ідентифікувати темпорально незалежний медіальний фронтальний ЕЕГ-процес, що відповідав за тета-сплески, які передували швидким моторним реакціям. Крім того, стаття Галлего-Рудольфа та співавторів [8] досліджує ефективність ICA для корекції балістокардіографічного артефакту при одночасному записі ЕЕГ та фМРТ. Автори встановили, що ICA-методи корекції найкраще зберігають реактивність задньої альфа-потужності під час завдання на закриття та відкриття очей, що є безпосередньо релевантним для нашого дослідження. Застосування ICA до аналізу даних фМРТ також описано Макіоуном та співавторами [9], де метод продемонстрував перевагу над методом головних компонент та стандартним кореляційним аналізом у визначенні просторово-часових характеристик мозкової активації.

Ключовим аспектом валідації ICA-компонент як мозкових сигналів є їхня дипольна природа. Фундаментальні принципи дипольного аналізу потенціалів було описано Шергом [10], який запропонував просторово-часовий підхід до ідентифікації нейронних генераторів. Автор ввів поняття «регіонального дипольного джерела» з трьома ортогональними компонентами та показав, що модель із 6 диполями здатна пояснити 99,4% дисперсії скальпового потенціалу в просторі та часі, демонструючи високу надійність методу. Ключовим показником якості підбору диполя є залишкова дисперсія (residual variance), що визначається як відносна помилка між виміряними та модельними потенціалами.

Кількісну міру відповідності між потенціалами, обчисленими різними методами, було формалізовано Остенвельдом та Остендорпом [11] як relative error (RE):

$$RE = \sqrt{\frac{\sum_{i=1}^N (\phi_i - V_i)^2}{\sum_{i=1}^N V_i^2}} \quad (1)$$

де V_i — потенціал на електроді i , обчислений одним методом, ϕ_i — потенціал на тому ж електроді, обчислений іншим методом, а N — кількість електродів. У інших роботах ця ж формула використовується під терміном residual variance (RV). На основі неї визначається дипольний показник (dipole score) як $(1 - RV) \times 100\%$. Обчислення RV реалізовано у програмному пакеті FieldTrip [12], від якого залежить модуль DIPFIT, що використовується в EEGLAB для підбору еквівалентних диполів.

Фізичну основу для дипольної моделі мозкової активності описує підручник Малмівуо та Плонсі [13], де описано модель об'ємного провідника у вигляді концентричних сферичних областей. Відповідно до цієї моделі, радіус голови становить 9,2 см, а провідність мозкової тканини та скальпа — 0,33 С/м. Ці параметри підтверджуються також у роботі Гірі та співавторів [14], де для чотиришарової моделі голови

(мозок, ЦСР, череп, скальп) обрано радіуси 8,0, 8,2, 8,7 та 9,2 см відповідно, а провідність мозку та скальпа — $0,33 \text{ (Ом}\cdot\text{м)}^{-1}$.

Якість ICA-декомпозиції оцінюється через ступінь відповідності дипольній моделі компонент. Артоні та співавтори [15] визначають дипольний показник компоненти IC_n як:

$$\text{dip}(IC_n) = 100(1 - \text{resvar}(IC_n))\% \quad (2)$$

де $\text{resvar}(IC_n)$ — частка залишкової дисперсії між скальповою картою компоненти та її моделлю одного еквівалентного диполя. Для «квазідипольних» компонент з $\text{dip} > 85\%$ та особливо для «майже дипольних» компонент із $\text{dip} > 95\%$ позиція та орієнтація еквівалентного диполя є надійною оцінкою розташування джерела. У тій же роботі показано, що зменшення розмірності даних за допомогою методу головних компонент перед ICA суттєво погіршує якість декомпозиції — навіть видалення лише 1% дисперсії знижує кількість компонент із високою відповідністю дипольній моделі із 30 до 10 на набір даних.

Метод RELICA, запропонований Артоні та співавторами [16], дозволяє оцінити надійність незалежних компонент. RELICA класифікує компоненти за трьома класами: Клас I — стабільні та фізіологічно достовірні, Клас II — стабільні, але менш дипольні, Клас III — нестабільні. Порівняння FastICA та Infomax ICA показало, що Infomax є більш надійним: приблизно 20% декомпозицій FastICA не збігалися, а ті, що збігалися, давали менше зменшення взаємної інформації. У середньому RELICA ідентифікував 15 надійних та фізіологічно достовірних компонент на учасника з 71 можливих. Поріг відповідності дипольній моделі у 85% як критерій прийнятності компоненти також підтверджується роботою Онтон та співавторів [17], де компоненти із залишковою дисперсією понад 15% виключалися з подальшого аналізу.

Для практичної реалізації обробки EEG-даних існує низка програмних засобів. EEGLAB [18] є одним із найпотужніших інструментів для аналізу EEG, реалізованим як тулбокс для MATLAB. Він підтримує імпорт різних форматів даних, попередню обробку, ICA-декомпозицію, часово-частотний аналіз та багатопробну візуалізацію. Однак для нашого дослідження було обрано NeuroAnalyzer.jl [19] — тулбокс для мови Julia, що надає комплексний набір інструментів для аналізу нейрофізіологічних даних. Julia була обрана завдяки швидкодії (JIT-компіляція), відкритому коду та орієнтації на наукові обчислення. NeuroAnalyzer.jl підтримує імпорт форматів EDF/BDF/GDF, видалення поганих каналів (методи flat, amp, var, ransac), фільтрацію (FIR/IIR/Butterworth), ICA- та PCA-декомпозицію та візуалізацію. За результатами порівняння, NeuroAnalyzer.jl приблизно в 1,7 рази швидший за MNE (Python) і в 3 рази швидший за EEGLAB (MATLAB) для типових операцій обробки.

Перспективним напрямком подальших досліджень є математичне моделювання EEG-сигналів. Білозьоров та співавтори [20] запропонували нові моделі на основі сингулярних диференціальних рівнянь для опису сильно осциляційних процесів кори головного мозку. Модель здатна розрізняти сигнали здорового мозку та мозку пацієнта з

епілепсією, причому фрактальна розмірність атрактора здорового мозку є більшою, що свідчить про складнішу структуру хаосу. Інкін та Білозьоров [21] розвинули цей підхід, запропонувавши гібридну модель ФітцХью-Нагумо-Лоренца для моделювання ЕЕГ із оптимізацією параметрів на основі нейронних мереж. Потенційно NODE (Neural Ordinary Differential Equations) може бути застосована для моделювання очищених ІСА-сигналів ЕЕГ.

Таким чином, аналіз літератури свідчить, що ІСА є потужним інструментом для розділення мозкових сигналів від артефактів у ЕЕГ-даних, а підбір еквівалентних диполів дозволяє валідувати отримані компоненти як фізіологічно достовірні джерела. Поєднання ІСА-декомпозиції з класифікацією на основі спектральних та дипольних характеристик компонент може забезпечити більш надійну класифікацію стану очей порівняно з прямим аналізом сигналів електродів. Водночас математичне моделювання очищених ІСА-сигналів за допомогою систем диференціальних рівнянь відкриває перспективи для глибшого розуміння динаміки мозкової активності.

Мета дослідження. Мета цієї роботи полягає у розробці та дослідженні підходу до класифікації стану відкритих та закритих очей на основі незалежних компонент, отриманих методом ІСА з багатоканальних ЕЕГ-даних. На відміну від попередніх робіт, де класифікація виконувалася безпосередньо за сигналами окремих електродів, у цьому дослідженні пропонується використовувати ІСА-декомпозицію для виділення незалежних мозкових джерел із подальшою їх валідацією за допомогою підбору еквівалентних диполів. Особлива увага приділяється побудові послідовного алгоритму обробки: від детектування та видалення пошкоджених каналів, фільтрації шумів та ІСА-декомпозиції до підбору еквівалентних диполів, відбору фізіологічно достовірних компонент та класифікації стану очей за їхніми спектральними та просторовими характеристиками з використанням нейронної мережі. Крім того, досліджується якість датасету *EEG Motor Movement/Imagery Dataset* та вплив попередньої обробки на результати класифікації.

Викладення основного матеріалу дослідження. Для аналізу використовувалася база даних *EEG Motor Movement/Imagery Dataset* [3], що містить понад 1500 записів ЕЕГ тривалістю від однієї до двох хвилин, отриманих від 109 учасників. У ході експерименту учасники виконували різні моторні та уявні завдання, під час яких реєструвалися 64-канальні ЕЕГ-сигнали за допомогою системи *BCI2000* [22].

Кожен учасник проходив 14 експериментальних сесій, серед яких дві базові проби (по одній хвилині) – одна з відкритими очима, інша із закритими. Окрім цього, виконувалися три двоххвилинні проби для кожного з чотирьох завдань. Учасники мали відкривати та закривати кулак відповідно до появи мішені на лівій або правій стороні екрана або лише уявляти виконання цього руху. Додатково передбачалися завдання, у яких потрібно було відкривати та закривати обидва кулаки або обидві ноги залежно від позиції мішені.

Записи представлені у форматі *EDF+*, що містить 64 ЕЕГ-сигнали, зареєстровані з частотою 160 Гц, а також канал анотацій. Анотації включають коди, що позначають

різні стани: $T0$ для спокою, $T1$ для початку руху (реального або уявного) лівого кулака або обох кулаків та $T2$ для руху правого кулака або обох ніг. Запис здійснено з використанням електродів за міжнародною системою $10-10$, яка виключає деякі специфічні електроди. Формат $EDF+$ адаптований для використання із програмним забезпеченням *PhysioToolkit* [23].

Кожен учасник має унікальний ідентифікатор від $S001$ до $S109$, а також 14 файлів із позначками $R01-R14$, що містять відповідні ЕЕГ-записи. Таким чином, для кожного запису файли представлені у форматі $SsssRrr.edf$, де S позначає номер учасника, а r – номер етапу експерименту. У цьому дослідженні були використані записи наступних етапів:

- 1 – стан без завдання, очі відкриті;
- 2 – стан без завдання, очі закриті.

Імпорт даних. Формат $EDF+$, у якому зберігаються записи датасету, не містить інформації про просторове розташування електродів, що є необхідним для подальшого підбору еквівалентних диполів та візуалізації топографічних карт. Для вирішення цієї проблеми було використано файл розташування електродів *Standard-10-20-Cap81.ced* з пакету *EEGLAB* [18], який містить координати електродів за стандартною системою $10-10$. Оскільки порядок електродів у файлі розташування не збігався з порядком каналів у датасеті, було проведено адаптацію: координати електродів були переупорядковані відповідно до послідовності каналів у записах $EDF+$.

Видалення пошкоджених каналів. Перед застосуванням ІСА-декомпозиції необхідно виявити та видалити пошкоджені канали, оскільки вони можуть суттєво погіршити якість розділення компонент і сповільнити збіжність алгоритму. Для цього у *NeuroAnalyzer.jl* [19] було послідовно застосовано три методи детектування:

1. **Метод flat** — виявляє канали з практично відсутнім сигналом, тобто ті, де амплітуда залишається майже незмінною протягом усього запису. Такі канали не несуть корисної інформації та є результатом поганого контакту електрода зі скальпом.

2. **Метод amp** — відсіює канали з аномальним діапазоном амплітуд, що виходить за межі фізіологічно обґрунтованих значень. Це дозволяє виключити записи з апаратними артефактами або надмірним шумом.

3. **Метод var** — визначає канали, дисперсія (*variance*) яких значно відрізняється від решти каналів. Канали з аномально високою або низькою дисперсією свідчать про нестабільний контакт або зовнішні перешкоди. Недоліком цього методу є те, що він може відсіяти лобні або потиличні електроди, оскільки вони природно мають більший рівень шуму від моргань та м'язів шиї відповідно.

Альтернативним підходом є метод *RANSAC*, який порівнює сигнал кожного каналу лише з його найближчими сусідами, що теоретично дозволяє уникнути хибного відсіювання каналів із специфічними, але фізіологічно обумовленими характеристиками. Однак у ході експериментів цей метод виявився занадто агресивним, відсіюючи надмірну кількість каналів, тому від його використання було вирішено відмовитися.

Аналіз результатів детектування пошкоджених каналів по всьому датасету показав, що приблизно 25% записів мають значну кількість непридатних каналів, що ставить під сумнів якість відповідних даних. За результатами фільтрації було залишено 82 учасники зі 109, у яких кількість валідних каналів була достатньою для подальшої обробки. Розподіл кількості придатних каналів наведено на рис. 1.




Рисунок 1 - Розподіл кількості каналів ЕЕГ, придатних для аналізу.

Пунктирна вертикальна лінія — поріг 43 канали; 75,2% учасників з усього датасету мають кількість каналів вище порогу

Фільтрація сигналу. Після видалення пошкоджених каналів було виконано частотну фільтрацію сигналу, яка є необхідною передумовою для коректної роботи ІСА-декомпозиції. Без попередньої фільтрації низькочастотні дрейфи та мережевий шум значно сповільнюють збіжність ІСА-алгоритму, а в окремих випадках призводять до того, що алгоритм не збігається взагалі.

Першим етапом було застосовано фільтр верхніх частот (highpass) з частотою зрізу 2 Гц та шириною перехідної смуги (bandwidth) 0,7 Гц. Це означає, що спектральна характеристика фільтра плавно зростає від 2,0 до 2,7 Гц, забезпечуючи поступовий перехід без різких артефактів. Порядок фільтра Баттерворта підбирався автоматично засобами NeuroAnalyzer.jl [19]. Цей фільтр видаляє низькочастотні складові сигналу, що можуть бути спричинені повільними рухами голови, дрейфом базової лінії електродів або потовиділенням.

Другим етапом було застосовано режекторний фільтр (notch filter) на частоті 50 Гц з шириною смуги 0,8 Гц для видалення шуму електричної мережі. Ширину смуги було обрано як середнє значення по датасету, хоча в ідеальному випадку цей параметр варто підбирати індивідуально для кожного запису залежно від ширини мережевого піку у його спектрі.

Як показали експерименти, після застосування обох фільтрів та видалення пошкоджених каналів швидкість ІСА-декомпозиції суттєво зросла: в середньому по датасету обчислення займало близько однієї секунди на 60 секунд запису для приблизно 40–50 залишених каналів.

ІСА-декомпозиція. Після попередньої обробки до сигналів було застосовано алгоритм ІСА, реалізований у NeuroAnalyzer.jl [19] як обгортка над бібліотекою MultivariateStats.jl. Математично ІСА-модель описується як лінійне змішування незалежних джерел [4]:

$$\mathbf{x}(t) = \mathbf{A} \cdot \mathbf{s}(t) \quad (3)$$

де $\mathbf{x}(t)$ — вектор спостережуваних ЕЕГ-сигналів розміру n (кількість електродів), $\mathbf{s}(t)$ — вектор незалежних компонент розміру m (кількість джерел), \mathbf{A} — матриця змішування розміру $n \times m$. Задача ІСА полягає у знаходженні матриці розмішування \mathbf{W} розміру $m \times n$, такої що:

$$\mathbf{s}(t) = \mathbf{W} \cdot \mathbf{x}(t) \quad (4)$$

Знаходження матриці \mathbf{W} виконується шляхом максимізації негаусівськості компонент. Згідно з центральною граничною теоремою, сума незалежних випадкових величин має розподіл, ближчий до гаусівського, ніж кожна з них окремо, тому максимально негаусівські компоненти є найбільш незалежними. Негаусівськість оцінюється апроксимацією негентропії на основі принципу максимальної ентропії [4]:

$$J(y) \approx \sum_{i=1}^p k_i [E\{G_i(y)\} - E\{G_i(v)\}]^2 \quad (5)$$

де $E\{\cdot\}$ — оператор математичного сподівання, k_i — додатні константи, v — стандартна гаусівська випадкова величина, а G_i — неквадратичні функції. Ця міра є завжди невід'ємною та дорівнює нулю лише для гаусівського розподілу y .

Перед застосуванням ІСА виконуються два кроки математичної попередньої обробки [4]. Перший — центрування: від спостережуваного вектора \mathbf{x} віднімається його математичне сподівання $\mathbf{m} = E\{\mathbf{x}\}$, що робить дані нульовосередніми. Другий — відбілювання (whitening): дані лінійно перетворюються так, щоб їхні компоненти стали некорельованими з одиничною дисперсією:

$$\tilde{\mathbf{x}} = \mathbf{E} \mathbf{D}^{-1/2} \mathbf{E}^T \mathbf{x} \quad (6)$$

де \mathbf{E} — ортогональна матриця власних векторів коваріаційної матриці $E\{\mathbf{x}\mathbf{x}^T\}$, $\mathbf{D} = \text{diag}(d_1, \dots, d_n)$ — діагональна матриця її власних значень. Після відбілювання матриця змішування $\tilde{\mathbf{A}} = \mathbf{E} \mathbf{D}^{-1/2} \mathbf{E}^T \mathbf{A}$ стає ортогональною, що вдвічі зменшує кількість параметрів для оцінки.

Наприклад, для 64 ЕЕГ-каналів та 12 обраних незалежних компонент матриця \mathbf{W} має розмір 12×64 , а матриця \mathbf{A} — 64×12 . Кожен стовпець матриці \mathbf{A} відповідає скальповій карті однієї компоненти, тобто описує, з якою вагою дана компонента впливає на кожен електрод. Саме ці стовпці є практичними значеннями потенціалу, які далі використовуються для підбору дипольної моделі.

Підбір дипольної моделі. Для валідації отриманих ІСА-компонент як мозкових сигналів було реалізовано алгоритм підбору еквівалентного диполя (dipole fitting). Мозок функціонує як сукупність електричних диполів, кожен з яких генерує електромагнітне поле, що реєструється електродами на поверхні скальпа [13]. Потенціал, створений одним диполем у точці розташування i -го електрода, визначається формулою [13]:

$$V_i = \frac{\mathbf{p} \cdot (\mathbf{r}_{e_i} - \mathbf{r}_d)}{4\pi\sigma|\mathbf{r}_{e_i} - \mathbf{r}_d|^3} \quad (7)$$

де \mathbf{r}_d — позиція диполя, \mathbf{r}_{e_i} — позиція i -го електрода, \mathbf{p} — вектор дипольного моменту, σ — провідність тканини.

Зв'язок між цією формулою та ІСА-моделлю є наступним. Якщо j -та незалежна компонента відповідає одному мозковому джерелу-диполю, то j -й стовпець матриці змішування \mathbf{A} має збігатися з розподілом потенціалів, створених цим диполем на всіх електродах. Тобто елемент a_{ij} матриці \mathbf{A} повинен бути пропорційним теоретичному потенціалу V_i , обчисленому для i -го електрода.

Задача підбору диполя полягає у знаходженні таких параметрів \mathbf{r}_{d_j} та \mathbf{p}_j , при яких теоретичний розподіл потенціалів максимально відповідає j -му стовпцю матриці \mathbf{A} . Пропорційність замість рівності пояснюється тим, що ІСА нормалізує компоненти, втрачаючи інформацію про абсолютну амплітуду.

Для наближення до фізичного сенсу було обрано параметри відповідно до літературних даних: провідність мозкової тканини та скальпа $\sigma = 0,33$ С/м [13,14], а радіус голови — 9,2 см [13]. Оскільки координати електродів у файлі розташування зберігаються у нормалізованому діапазоні від -1 до 1 , їх було масштабовано множенням на $0,092$ м для переведення у систему СІ.

Оскільки нормалізація ІСА впливає лише на довжину $|\mathbf{p}|$, яка є лінійним множником у формулі потенціалу, вона не змінює нелінійну залежність від відстані між диполем та електродом, і підбір позиції диполя залишається коректним. Водночас масштабування координат електродів у систему СІ є необхідним саме тому, що відстань $|\mathbf{r}_{e_i} - \mathbf{r}_{d_j}|$ входить у формулу нелінійно.

Для оцінки якості підбору використовувалася залишкова дисперсія [11]:

$$RV = \frac{\sum_{i=1}^N (a_i - \hat{a}_i)^2}{\sum_{i=1}^N a_i^2} \quad (8)$$

де a_i — практичне значення потенціалу зі стовпця матриці змішування ІСА, \hat{a}_i — теоретичне значення потенціалу, обчислене за дипольною моделлю, N — кількість елек-

тродів. Відповідно, дипольний показник визначається як $(1 - RV) \times 100\%$: значення 100% означає ідеальний збіг, а 0% — повну невідповідність.

Задача підбору диполя формулюється як задача мінімізації функції втрат, параметрами якої є вектор $\boldsymbol{\theta} = (\mathbf{r}_d, \mathbf{p})$, де $\mathbf{r}_d \in \mathbb{R}^3$ — позиція диполя, $\mathbf{p} \in \mathbb{R}^3$ — вектор дипольного моменту. Функція втрат складається з кількох компонент.

Основною частиною є залишкова дисперсія, де теоретичний потенціал \hat{a}_i на i -му електроді обчислюється за дипольною моделлю:

$$\hat{a}_i(\mathbf{r}_d, \mathbf{p}) = \frac{\mathbf{p} \cdot (\mathbf{r}_{e_i} - \mathbf{r}_d)}{4\pi\sigma|\mathbf{r}_{e_i} - \mathbf{r}_d|^3} \quad (9)$$

Для запобігання надмірним значенням параметрів введено L2-регуляризацію:

$$L_{reg} = \lambda_1 \|\boldsymbol{\theta}\|^2 \quad (10)$$

Оскільки без обмежень оптимізатор може розмістити диполь за межами голови, додано сферичний штраф, що різко зростає при виході позиції диполя за межі сфери:

$$L_{sphere} = \lambda_2 [\max(0, |\mathbf{r}_d|^2 - R^2)]^2 \quad (11)$$

де $R = 0,092$ м — радіус голови.

Однак навіть із сферичним обмеженням диполь міг опинитися у зонах, що не відповідають мозковій тканині. Для більш точного обмеження було використано тривимірну модель (меш) мозку, отриману з бази даних NIH 3D Print Exchange. Меш було масштабовано до сфери радіусом 0,092 м та спрощено до низькополігональної опуклої оболонки (low-poly convex hull). Далі було підібрано еліпсоїди виду:

$$\frac{(x - c_{x_k})^2}{a_k^2} + \frac{(y - c_{y_k})^2}{b_k^2} + \frac{(z - c_{z_k})^2}{c_k^2} = 1 \quad (12)$$

що найкраще покривають точки мешу. Для кожного еліпсоїда обчислюється міра віддаленості точки \mathbf{r}_d від його поверхні:

$$d_k(\mathbf{r}_d) = \frac{(r_{dx} - c_{x_k})^2}{a_k^2} + \frac{(r_{dy} - c_{y_k})^2}{b_k^2} + \frac{(r_{dz} - c_{z_k})^2}{c_k^2} - 1 \quad (13)$$

де $d_k \leq 0$ означає, що точка знаходиться всередині k -го еліпсоїда. Еліпсоїдний штраф дорівнює нулю, коли диполь знаходиться всередині хоча б одного еліпсоїда, та різко зростає при виході за межі всіх:

$$L_{ell} = \lambda_3 [\max(0, \min_{k=1, \dots, K} d_k(\mathbf{r}_d))]^2 \quad (14)$$

Таким чином, фінальна задача мінімізації для пошуку параметрів еквівалентного диполя j -ї ICA-компоненти набуває вигляду:

$$\begin{aligned}
 L(\mathbf{r}_d, \mathbf{p}) = & \frac{\sum_{i=1}^N (a_{ij} - \hat{a}_i(\mathbf{r}_d, \mathbf{p}))^2}{\sum_{i=1}^N a_{ij}^2} + \lambda_1 \|\boldsymbol{\theta}\|^2 \\
 & + \lambda_2 [\max(0, |\mathbf{r}_d|^2 - R^2)]^2 \\
 & + \lambda_3 [\max(0, \min_k d_k(\mathbf{r}_d))]^2 \rightarrow \min_{\mathbf{r}_d, \mathbf{p}}
 \end{aligned}
 \tag{15}$$

де a_{ij} — елемент j -го стовпця матриці змішування \mathbf{A} , N — кількість електродів, а коефіцієнти штрафів обрано емпірично: $\lambda_1 = 10^{-3}$ (регуляризація), $\lambda_2 = 10^6$ (сферичне обмеження), $\lambda_3 = 10^8$ (анатомічне обмеження). Перший доданок забезпечує відповідність моделі спостережуваним даним, другий — обмежує зростання параметрів, третій та четвертий — утримують диполь у фізіологічно обґрунтованій області.

Візуалізація спрощеної моделі поверхні кори з двома підібраними еліпсоїдами (синій та червоний каркас) наведена на рис. 2: показано три орієнтації — зверху, збоку та ззаду. Еліпсоїди накладаються на меш, масштабований до сфери радіусом 0,092 м, і визначають область, усередині якої положення диполя не отримує еліпсоїдного штрафу L_{ell} .




Рисунок 2 - Спрощена модель кори (меш) з двома еліпсоїдами, підібраними для апроксимації опуклої оболонки мозку: синій і червоний каркас — межі допустимої області для диполя L_{ell} ; вид зверху, збоку та ззаду

Аналіз отриманих ІСА-сигналів. Після застосування алгоритму підбору диполя до всього датасету для кожної ІСА-компоненти було отримано: топографічну карту (скальповий розподіл потенціалів зі стовпця матриці \mathbf{A}), часовий ряд незалежної компоненти та криву спектральної щільності потужності (PSD, Power Spectral Density), обчислену методом Велча (Welch). На рис. 3–7 для кожного прикладу показано часовий ряд, оцінку спектральної щільності потужності та скальпову топографію з накладеним положенням підбраного еквівалентного диполя.

Візуальний аналіз результатів дозволив виявити кілька характерних типів компонент. Першу групу складають компоненти з домінуванням альфа-ритму — характерним

піком спектральної щільності на частоті близько 10 Гц. Топографічна карта таких компонент демонструє найбільшу активність у потиличній ділянці, а підібраний еквівалентний диполь розташовується в задній частині голови, що підтверджує потиличне походження сигналу (рис. 3).




Рисунок 3 - ICA-компонента з домінуванням альфа-діапазону: на спектрі видно підсилення близько 10 Гц, топографія узгоджується з потиличною локалізацією джерела ($s=1$, R02, компонента $i = 2$)

Другу групу складають компоненти з вираженим мю-ритмом — аналогом альфа-ритму у сенсомоторній корі. На топографічній карті такі компоненти мають максимум активності у центральній ділянці скальпа, а еквівалентний диполь локалізується у сенсомоторній зоні (рис. 4).




Рисунок 4 - Приклад компоненти з вираженим мю-ритмом у сенсомоторному діапазоні ($s=80$, R02, $i = 3$)

Окремі компоненти демонструють підвищену активність у бета-діапазоні (13–30 Гц). Топографія таких компонент зазвичай вказує на лобну або центральну локалізацію джерела (рис. 5).

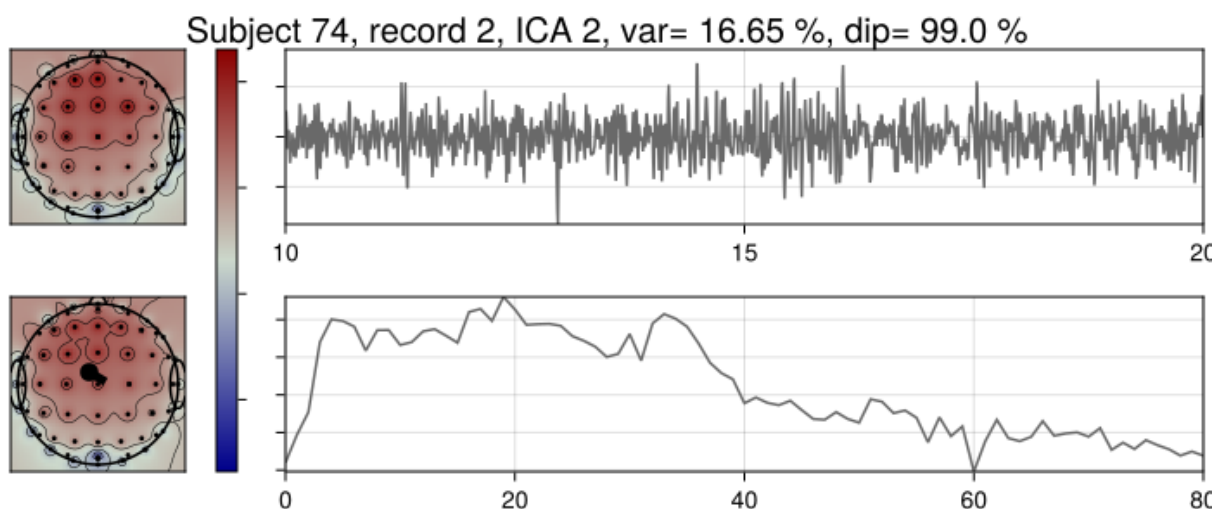


Рисунок 5 - Приклад компоненти з акцентом у бета-діапазоні ($s=74$, $R02$, $i = 2$)

Також було виявлено компоненти з підвищеною відносною потужністю у гамма-діапазоні (понад 30 Гц), природа яких потребує подальшого дослідження, оскільки вони можуть відображати як нейрональну активність, так і залишкові м'язові артефакти (рис. 6).

Нарешті, значна кількість компонент має низький дипольний показник, що свідчить про їхнє артефактне або змішане походження. На рис. 7 показано компоненту, що відповідає артефакту моргання: на часовому ряді видно різку короточасну зміну амплітуди, типову для моргання. Топографічна карта демонструє максимальну активність у лобно-полярній ділянці, що є характерною ознакою окорухових артефактів. Дипольний показник цієї компоненти становить лише 73%, що суттєво нижче порогу 85% для квазідипольних мозкових компонент.




Рисунок 6 - Приклад компоненти з підвищеною відносною потужністю у гамма-діапазоні ($s=73$, $R01$, $i = 2$)




Рисунок 7 - Артефакт моргання: топографія з лобно-полярним максимумом, характерна різка зміна амплітуди на часовому ряді; дипольний показник 73% ($s=8$, $R01$, $i = 1$)

Фільтрація датасету за якістю. Для систематичного відбору даних побудовано гістограми розподілу ключових характеристик якості. Кількість придатних каналів на запис (рис. 1) визначила перший етап фільтрації — відбір 82 учасників зі 109.

Розподіл дипольного показника по всіх ICA-компонентах датасету (рис. 8) свідчить, що 57% компонент мають показник вище порогу 85%, рекомендованого у літературі [15,17] для ідентифікації квазідипольних мозкових компонент. Компоненти з нижчим показником було відсіяно як такі, що мають недостатню відповідність дипольній моделі.



Рисунок 8 - Розподіл дипольного показника по всіх ICA-компонентах датасету.

Пунктир — поріг 85%; 57% компонент мають показник вище порогу

Для другого етапу фільтрації було обчислено мінімальну (між базовими сесіями R01 та R02) кількість компонент із дипольним показником понад 85% на кожного учасника (рис. 9). Результати показали, що 93,6% учасників із решти датасету мають

щонайменше дві такі компоненти. Додатково було виключено 3 учасників, для яких не залишилося жодної компоненти з достатнім дипольним показником.




Рисунок 9 - Кількість ІСА-компонент із дипольним показником > 85% на учасника (мінімум між сесіями R01 та R02). Пунктир — поріг 2 компоненти; 93,6% учасників з решти датасету перевищують поріг

Таким чином, фінальний датасет складається з 79 учасників, кожен із яких має принаймні одну ІСА-компоненту з дипольним показником > 85%, а в середньому залишається близько 43 валідних ЕЕГ-каналів на запис.

Формування ознак для класифікації. Для кожної відібраної ІСА-компоненти було сформовано вектор ознак, що включає: дипольний показник (1 значення), дисперсію компоненти (variance, 1 значення), позицію диполя у тривимірному просторі (3 значення), вектор дипольного моменту (3 значення) та значення спектральної щільності потужності (161 значення). Загалом це становить 169 ознак на одну компоненту.

Для кожного учасника було відібрано три компоненти з найбільшою дисперсією, оскільки вони вносять найбільший вклад у загальну потужність сигналу. Таким чином, вектор ознак одного учасника має розмірність $3 \times 169 = 507$ значень.

Класифікація за допомогою нейронної мережі. Для класифікації стану очей (відкриті чи закриті) на основі сформованих ознак було використано повнозв'язну нейронну мережу прямого поширення (feedforward neural network). Архітектура мережі складається з вхідного шару розмірністю 507, двох прихованих шарів із 256 та 128 нейронами відповідно та вихідного шару з двома нейронами для бінарної класифікації. У якості функції активації для прихованих шарів використано ReLU (Rectified Linear Unit).

Датасет із 79 учасників (по два записи на кожного — з відкритими та закритими очима, тобто 158 зразків) було розділено на тренувальну (80%) та тестову (20%) вибірки. До тестової вибірки було відібрано учасників із кращими показниками дисперсії компонент, щоб оцінити здатність моделі узагальнювати на даних більш високої якості.

Найкращий результат класифікації становив 97% точності на тренувальній вибірці та 90% на тестовій, що означає помилкову класифікацію лише одного учасника з тестового набору. Однак було виявлено суттєву проблему перенавчання (*overfitting*), зумовлену малим обсягом датасету. При подальшому навчанні без ранньої зупинки точність на тренувальних даних зростала до 100%, тоді як на тестових знижувалася до 75%. Це свідчить про те, що мережа починає запам'ятовувати конкретні зразки замість вивчення узагальнених закономірностей. Тому для досягнення оптимальних результатів було необхідно застосовувати ранню зупинку навчання (*early stopping*), відстежуючи момент, коли точність на тестовій вибірці починає знижуватися.

Порівняно з результатами попередніх робіт, де класифікація виконувалася безпосередньо за сигналами електродів, підхід на основі ІСА-компонент із дипольною валідацією демонструє конкурентоспроможну точність навіть при значно меншому обсязі даних (79 замість 109 учасників) та при використанні характеристик лише трьох найпотужніших незалежних компонент. Точність 90% на тестовій вибірці є порівнянною з результатами SVM-класифікатора на основі рекурентних показників (95% для O1), проте слід враховувати, що ІСА-підхід працює не з окремими електродами, а з розділеними мозковими джерелами, що надає результатам більшої фізіологічної інтерпретованості.

Висновки. У роботі запропоновано та досліджено підхід до класифікації стану відкритих і закритих очей, що базується на аналізі незалежних компонент багатоканальних ЕЕГ-даних із їх валідацією за допомогою підбору еквівалентних диполів. На відміну від попередніх робіт, де класифікація виконувалася безпосередньо за сигналами окремих електродів, запропонований метод працює з розділеними мозковими джерелами, що забезпечує більшу фізіологічну інтерпретованість результатів.

Побудовано послідовний алгоритм обробки ЕЕГ-даних: детектування та видалення пошкоджених каналів, частотна фільтрація, ІСА-декомпозиція, підбір еквівалентних диполів та відбір фізіологічно достовірних компонент за порогом дипольного показника 85%.

Аналіз датасету *EEG Motor Movement/Imagery Dataset* виявив значні проблеми з якістю частини записів: із 109 учасників лише 79 (72%) мали достатню кількість валідних каналів та ІСА-компонент із прийнятним дипольним показником. Це підтверджує необхідність ретельної попередньої обробки та контролю якості даних перед аналізом. Аналіз отриманих ІСА-компонент виявив джерела з характерними частотними профілями у альфа-, мю-, бета- та гамма-діапазонах, що підтверджує здатність методу виділяти фізіологічно інтерпретовані сигнали.

Для підбору еквівалентного диполя розроблено оригінальну функцію втрат, що окрім залишкової дисперсії включає L2-регуляризацию, сферичне обмеження та еліпсоїдне анатомічне обмеження на основі тривимірної моделі мозку. Еліпсоїдний штраф забезпечує розташування диполя у фізіологічно обґрунтованій області, що підвищує надійність результатів.

Класифікація на основі нейронної мережі з використанням 507 ознак (дипольний показник, дисперсія, просторові характеристики диполя та спектральна щільність пот-

ужності для трьох найпотужніших компонент) досягла точності 97% на навчальній та 90% на тестовій вибірці. Виявлено проблему перенавчання, зумовлену малим обсягом датасету (79 учасників, 158 зразків), що потребує застосування ранньої зупинки навчання.

Перспективними напрямками подальших досліджень є: збільшення обсягу даних шляхом залучення додаткових датасетів; застосування методів регуляризації та аугментації даних для боротьби з перенавчанням; використання математичного моделювання очищених ІСА-сигналів за допомогою систем диференціальних рівнянь для глибшого розуміння динаміки мозкової активності; а також дослідження впливу окремих частотних діапазонів ІСА-компонент на якість класифікації.

ЛІТЕРАТУРА

1. Ye. S. Panasenko, V. Ye. Belozyorov. THE APPLICATION OF SPECTRAL ANALYSIS OF EEG DATA FOR THE IDENTIFICATION OF OPEN AND CLOSED EYE STATES. *System technologies*. 2024. Т. 6, № 155, 155. С. 101–115. DOI: 10.34185/1562-9945-6-155-2024-11.
2. Panasenko Y.S., Belozyorov V.Y. CLASSIFICATION OF EYE STATE BASED ON EEG DATA USING RECURRENCE ANALYSIS. *Системні технології*. 2025. Т. 3, № 158, 158. С. 58–73. DOI: 10.34185/1562-9945-3-158-2025-07.
3. EEG Motor Movement/Imagery Dataset [Електронний ресурс]. URL: <https://archive.physionet.org/pn4/eegmmidb/> (дата звернення: 21.02.2024).
4. Hyvärinen A., Oja E. Independent Component Analysis: Algorithms and Applications. *Neural Networks*. 2000. Т. 13, № 4. С. 411–430. DOI: 10.1016/S0893-6080(00)00026-5.
5. Makeig S., Bell A., Jung T.-P., Sejnowski T.J. Independent Component Analysis of Electroencephalographic Data. *Advances in Neural Information Processing Systems*. MIT Press, 1995. Т.8. https://papers.nips.cc/paper_files/paper/1995/hash/754dda4b1ba34c6fa89716b85d68532b-Abstract.html.
6. Delorme A., Palmer J., Onton J., Oostenveld R., Makeig S. Independent EEG Sources Are Dipolar. *PLOS ONE*. Public Library of Science, 2012. Т. 7, № 2. С. e30135. DOI: 10.1371/journal.pone.0030135.
7. Delorme A., Westerfield M., Makeig S. Medial Prefrontal Theta Bursts Precede Rapid Motor Responses during Visual Selective Attention. *Journal of Neuroscience*. Society for Neuroscience, 2007. Т. 27, № 44. С. 11949–11959. DOI: 10.1523/JNEUROSCI.3477-07.2007.
8. Gallego-Rudolf J., Corsi-Cabrera M., Concha L., Ricardo-Garcell J., Pasaye-Alcaraz E. Preservation of EEG Spectral Power Features during Simultaneous EEG-fMRI. *Frontiers in Neuroscience*. 2022. Т. 16. С. 951321. DOI: 10.3389/fnins.2022.951321.
9. Mckeown M.J., Makeig S., Brown G.G., Jung T., Kindermann S.S., Bell A.J., Sejnowski T.J. Analysis of fMRI Data by Blind Separation into Independent Spatial Components. *Human Brain Mapping*. 1998. Т. 6, № 3. С. 160–188. DOI: 10.1002/(SICI)1097-0193(1998)6:3<160::AID-HBM5>3.0.CO;2-1.

10. SCHERG M. Fundamentals of Dipole Source Potential Analysis. *Fundamentals of dipole source potential analysis*. Basel: Karger, 1990. Т. 6. С. 40–69.
11. Oostenveld R., Oostendorp T.F. Validating the Boundary Element Method for Forward and Inverse EEG Computations in the Presence of a Hole in the Skull. *Human Brain Mapping*. 2002. Т. 17, № 3. С. 179–192. DOI: 10.1002/hbm.10061.
12. Oostenveld R., Fries P., Maris E., Schoffelen J.-M. FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data. *Computational Intelligence and Neuroscience*. 2011. Т. 2011, № 1. С. 156869. DOI: 10.1155/2011/156869.
13. Malmivuo J., Plonsey R. Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields. New York: Oxford University Press, 1995. 512 с.
DOI: 10.1093/acprof:oso/9780195058239.001.0001.
14. Giri A., Kumar L., Kurwale N., Gandhi T.K. Anatomical Harmonics Basis Based Brain Source Localization with Application to Epilepsy. *Scientific Reports*. 2022. Т. 12. С. 11240. DOI: 10.1038/s41598-022-14500-7.
15. Artoni F., Delorme A., Makeig S. Applying Dimension Reduction to EEG Data by Principal Component Analysis Reduces the Quality of Its Subsequent Independent Component Decomposition. *NeuroImage*. 2018. DOI: 10.1016/j.neuroimage.2018.03.016.
16. Artoni F., Menicucci D., Delorme A., Makeig S., Micera S. RELICA: A Method for Estimating the Reliability of Independent Components. *NeuroImage*. 2014. Т. 103. С. 391–400. DOI: 10.1016/j.neuroimage.2014.09.010.
17. Onton J., Delorme A., Makeig S. Frontal Midline EEG Dynamics during Working Memory. *NeuroImage*. 2005. Т. 27, № 2. С. 341–356.
DOI: 10.1016/j.neuroimage.2005.04.014.
18. Delorme A., Makeig S. EEGLAB: An Open Source Toolbox for Analysis of Single-Trial EEG Dynamics Including Independent Component Analysis. *Journal of Neuroscience Methods*. 2004. Т. 134, № 1. С. 9–21. DOI: 10.1016/j.jneumeth.2003.10.009.
19. Wysokiński A. NeuroAnalyzer: Julia Toolbox for Analyzing Neurophysiological Data. *Journal of Open Source Software*. 2025. Т. 10, № 107. С. 7734. DOI: 10.21105/joss.07734.
20. Belozyorov V.Y., Volkova S.A., Zaytsev V.G. Singular Differential Equations and Their Applications for Modeling Strongly Oscillating Processes. *Journal of Optimization, Differential Equations and Their Applications*. 2023. Т. 31, № 1, 1. С. 22–52. DOI: 10.15421/142302.
21. Inkin O.A., Belozyorov V.E. Hybrid Modeling of Eeg: The Fitzhugh-Nagumo-Lorenz Model. *System technologies*. 2025. Т. 3, № 158. С. 87–95. DOI: 10.34185/1562-9945-3-158-2025-09.
22. Schalk G., McFarland D.J., Hinterberger T., Birbaumer N., Wolpaw J.R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE transactions on bio-medical engineering*. 2004. Т. 51, № 6. С. 1034–1043. DOI: 10.1109/TBME.2004.827072.
23. Goldberger A.L., Amaral L.A., Glass L., Hausdorff J.M., Ivanov P.C., Mark R.G., Mietus J.E., Moody G.B., Peng C.K., Stanley H.E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation*. 2000. Т. 101, № 23. С. E215–220. DOI: 10.1161/01.cir.101.23.e215.

REFERENCES

1. Ye. S. Panasenko, & V. Ye. Belozyorov. (2024). THE APPLICATION OF SPECTRAL ANALYSIS OF EEG DATA FOR THE IDENTIFICATION OF OPEN AND CLOSED EYE STATES. *System Technologies*, 6(155, 155), 101–115. <https://doi.org/10.34185/1562-9945-6-155-2024-11>
2. Panasenko, Y.S., & Belozyorov, V.Y. (2025). CLASSIFICATION OF EYE STATE BASED ON EEG DATA USING RECURRENCE ANALYSIS. *Системні Технології*, 3(158, 158), 58–73. <https://doi.org/10.34185/1562-9945-3-158-2025-07>
3. *EEG Motor Movement/Imagery Dataset*. (б. д.). Вилучено 21, Лютий 2024, із <https://archive.physionet.org/pn4/eegmdb/>
4. Hyvärinen, A., & Oja, E. (2000). Independent Component Analysis: Algorithms and Applications. *Neural Networks*, 13(4), 411–430. [https://doi.org/10.1016/S0893-6080\(00\)00026-5](https://doi.org/10.1016/S0893-6080(00)00026-5)
5. Makeig, S., Bell, A., Jung, T.-P., & Sejnowski, T. J. (1995). Independent Component Analysis of Electroencephalographic Data. *Advances in Neural Information Processing Systems*, 8. https://papers.nips.cc/paper_files/paper/1995/hash/754dda4b1ba34c6fa89716b85d68532b-Abstract.html
6. Delorme, A., Palmer, J., Onton, J., Oostenveld, R., & Makeig, S. (2012). Independent EEG Sources Are Dipolar. *PLOS ONE*, 7(2), e30135. <https://doi.org/10.1371/journal.pone.0030135>
7. Delorme, A., Westerfield, M., & Makeig, S. (2007). Medial Prefrontal Theta Bursts Precede Rapid Motor Responses during Visual Selective Attention. *Journal of Neuroscience*, 27(44), 11949–11959. <https://doi.org/10.1523/JNEUROSCI.3477-07.2007>
8. Gallego-Rudolf, J., Corsi-Cabrera, M., Concha, L., Ricardo-Garcell, J., & Pasaye-Alcaraz, E. (2022). Preservation of EEG Spectral Power Features during Simultaneous EEG-fMRI. *Frontiers in Neuroscience*, 16, 951321. <https://doi.org/10.3389/fnins.2022.951321>
9. Mckeown, M. J., Makeig, S., Brown, G. G., Jung, T., Kindermann, S. S., Bell, A. J., & Sejnowski, T. J. (1998). Analysis of fMRI Data by Blind Separation into Independent Spatial Components. *Human Brain Mapping*, 6(3), 160–188. [https://doi.org/10.1002/\(SICI\)1097-0193\(1998\)6:3<160::AID-HBM5>3.0.CO;2-1](https://doi.org/10.1002/(SICI)1097-0193(1998)6:3<160::AID-HBM5>3.0.CO;2-1)
10. SCHERG, M. (1990). Fundamentals of Dipole Source Potential Analysis. *Fundamentals of dipole source potential analysis*, 6, 40–69.
11. Oostenveld, R., & Oostendorp, T. F. (2002). Validating the Boundary Element Method for Forward and Inverse EEG Computations in the Presence of a Hole in the Skull. *Human Brain Mapping*, 17(3), 179–192. <https://doi.org/10.1002/hbm.10061>
12. Oostenveld, R., Fries, P., Maris, E., & Schoffelen, J.-M. (2011). FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data. *Computational Intelligence and Neuroscience*, 2011(1), 156869. <https://doi.org/10.1155/2011/156869>
13. Malmivuo, J., & Plonsey, R. (1995). *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. Oxford University Press. <https://doi.org/10.1093/acprof:oso/9780195058239.001.0001>

14. Giri, A., Kumar, L., Kurwale, N., & Gandhi, T. K. (2022). Anatomical Harmonics Basis Based Brain Source Localization with Application to Epilepsy. *Scientific Reports*, 12, 11240. <https://doi.org/10.1038/s41598-022-14500-7>
15. Artoni, F., Delorme, A., & Makeig, S. (2018). Applying Dimension Reduction to EEG Data by Principal Component Analysis Reduces the Quality of Its Subsequent Independent Component Decomposition. *NeuroImage*. <https://doi.org/10.1016/j.neuroimage.2018.03.016>
16. Artoni, F., Menicucci, D., Delorme, A., Makeig, S., & Micera, S. (2014). RELICA: A Method for Estimating the Reliability of Independent Components. *NeuroImage*, 103, 391–400. <https://doi.org/10.1016/j.neuroimage.2014.09.010>
17. Onton, J., Delorme, A., & Makeig, S. (2005). Frontal Midline EEG Dynamics during Working Memory. *NeuroImage*, 27(2), 341–356. <https://doi.org/10.1016/j.neuroimage.2005.04.014>
18. Delorme, A., & Makeig, S. (2004). EEGLAB: An Open Source Toolbox for Analysis of Single-Trial EEG Dynamics Including Independent Component Analysis. *Journal of Neuroscience Methods*, 134(1), 9–21. <https://doi.org/10.1016/j.jneumeth.2003.10.009>
19. Wysokiński, A. (2025). NeuroAnalyzer: Julia Toolbox for Analyzing Neurophysiological Data. *Journal of Open Source Software*, 10(107), 7734. <https://doi.org/10.21105/joss.07734>
20. Belozyorov, V. Y., Volkova, S. A., & Zaytsev, V. G. (2023). Singular Differential Equations and Their Applications for Modeling Strongly Oscillating Processes. *Journal of Optimization, Differential Equations and Their Applications*, 31(1, 1), 22–52. <https://doi.org/10.15421/142302>
21. Inkin, O. A., & Belozyorov, V. E. (2025). Hybrid Modeling of Eeg: The Fitzhugh-Nagumo-Lorenz Model. *System technologies*, 3(158), 87–95. <https://doi.org/10.34185/1562-9945-3-158-2025-09>
22. Schalk, G., McFarland, D. J., Hinterberger, T., Birbaumer, N., & Wolpaw, J. R. (2004). BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Bio-Medical Engineering*, 51(6), 1034–1043. <https://doi.org/10.1109/TBME.2004.827072>
23. Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C. K., & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation*, 101(23), E215–220. <https://doi.org/10.1161/01.cir.101.23.e215>

Received 07.04.2026.

Accepted 10.04.2026.

Published 30.04.2026

***Eye state classification based on electroencephalogram decomposition
considering the dipole nature of brain signals***

Classification of brain activity states from electroencephalography (EEG) data is a relevant task for neuroscience and brain-computer interfaces. In previous works, spectral analysis of electrode signals provided eye state classification accuracy of 70–80%, while quantitative recurrence analysis with an SVM classifier achieved up to 95% for occipital electrodes, but both approaches operated on mixed signals from multiple sources and artifacts, limiting accuracy and physiological interpretability.

The aim is to develop an approach to eye state classification (open/closed) based on independent component analysis (ICA) of multichannel EEG data with component validation through equivalent dipole fitting.

The EEG Motor Movement/Imagery Dataset (109 participants, 64-channel EEG) was used. A sequential processing pipeline was implemented in Julia using the NeuroAnalyzer.jl toolbox: bad channel detection (flat, amp, var methods), frequency filtering (highpass 2 Hz, notch 50 Hz), ICA decomposition, and equivalent dipole fitting. An original loss function was developed with L2 regularization and ellipsoidal anatomical constraint based on a three-dimensional brain model.

Dataset quality analysis showed that only 79 of 109 participants (72%) had sufficient reliable channels and components with dipole scores above 85%. Among ICA components, sources with characteristic alpha, mu, beta, and gamma rhythms were identified, confirming physiological interpretability of the method.

Neural network classification based on 507 features (dipole score, variance, spatial dipole characteristics, power spectral density of three most powerful components) achieved 97% accuracy on training and 90% on test data. An overfitting problem was observed due to the small dataset size (158 samples), requiring the application of early stopping.

Unlike previous works, the proposed approach operates on separated brain sources, providing greater physiological interpretability and opening perspectives for mathematical modeling of cleaned ICA signals using systems of differential equations.

Keywords: EEG, electroencephalogram, ICA, dipole, brain state classification, neural network, spectral analysis, signal decomposition, blind source separation, source localization, computational neuroscience, spatiotemporal dynamics, biocybernetics, BCI, NeuroAnalyzer, Julia.

Панасенко Єгор Сергійович — аспірант кафедри комп'ютерних технологій Дніпровського національного університету імені Олеся Гончара.

ORCID: <http://orcid.org/0009-0008-2790-767X>.

Panasenko Yehor Serhiyovych — PhD student, Department of Computer Technologies, Oles Honchar Dnipro National University.

ORCID: <http://orcid.org/0009-0008-2790-767X>.