

МЕТОДИ АУГМЕНТАЦІЇ ДАНИХ ДЛЯ ПОКРАЩЕННЯ УЗАГАЛЬНЕННЯ МОДЕЛЕЙ ЕЕГ-КЛАСИФІКАЦІЇ

Київський національний університет імені Тараса Шевченка

Анотація

Електроенцефалографічні інтерфейси мозок-комп'ютер (Brain-Computer Interface, BCI) мають проблему обмеженості навчальних даних та значної міжсесійної варіативності сигналів, особливо у недорогих конфігураціях систем на основі інтерфейсів мозок-комп'ютер. Це призводить до повторюваної адаптації моделей: висока точність на навчальних даних не зберігається на нових записах з інших сесій. У роботі представлено підхід до аугментації епох сигналу електроенцефалографії (ЕЕГ), що зберігає фізіологічну правдоподібність сигналу та покращує узагальнення моделей. Розглянуто три групи перетворень: додавання гаусового шуму (моделювання сенсорного шуму), часові зсуви (варіативність моменту реакції) та амплітудне масштабування (зміни імпедансу та підсилення між сесіями). Реалізовано динамічну аугментацію, що виконується безпосередньо під час навчання без збереження модифікованих копій на диску. Для корекції незбалансованого розподілу класів застосовано вагові коефіцієнти у функції втрат. Підкреслено важливість коректного протоколу валідації між сесіями та необхідність контролю правдоподібності перетворень для збереження частотної структури сенсомоторних ритмів. Результати демонструють, що аугментація є ефективним інструментом покращення узагальнення лише за умови, що вона відображає реальні джерела варіацій у сигналах ЕЕГ та оцінюється на протоколі, що відповідає прикладному використанню системи.

Ключові слова: ЕЕГ, BCI, сенсомоторні ритми, аугментація даних, валідаційні дані.

Abstract

Electroencephalographic brain-computer interfaces suffer from limited training data and pronounced inter-session signal variability, particularly in low-cost BCI system configurations. This leads to repeated model overfitting: high accuracy achieved on training data does not persist when evaluated on recordings from new sessions. This paper presents an EEG epoch augmentation approach that preserves the physiological plausibility of the signal and improves model generalization. Three groups of transformations are considered: the addition of Gaussian noise (to model sensor noise), temporal shifts (to account for variability in response timing), and amplitude scaling (to reflect inter-session changes in electrode impedance and signal amplification). Dynamic augmentation is implemented directly during training without storing modified copies on disk. To address class imbalance, weighting coefficients are applied in the loss function. The importance of an appropriate inter-session validation protocol is emphasized, along with the need to control the plausibility of transformations in order to preserve the frequency structure of sensorimotor rhythms. The results demonstrate that augmentation is an effective tool for improving generalization only when it reflects real sources of variability in EEG signals and is evaluated using a protocol aligned with the intended practical application of the system.

Keywords: EEG, BCI, sensorimotor rhythms, data augmentation, validation data.

Вступ

Електроенцефалографія є однією з найбільш доступних неінвазивних технологій реєстрації мозкової активності, що широко використовується в BCI для формування команд керування у реабілітації та інтерактивних застосуваннях [1]. Водночас ЕЕГ характеризується низькою амплітудою корисних компонент, високою чутливістю до артефактів і значною міжсесійною варіативністю, особливо у недорогих конфігураціях BCI систем із малою кількістю каналів [2]. У практичних умовах це призводить до того, що розмічених даних зазвичай недостатньо: на етапі калібрування збираються десятки проб, а на наступних сесіях змінюється контакт електродів, рівень шуму середовища, психофізіологічний стан користувача та навіть стиль виконання дії. У результаті моделі класифікації мають тенденцію до повторної адаптації: демонструють високу точність на навчальних даних і помірну точність на валідаційних даних (виділених з тієї ж сесії запису), але не зберігають точність на нових записах з інших сесій, де змінюються умови реєстрації. Саме тому аугментація даних розглядається як практичний інструмент підвищення різноманітності навчального набору без додаткового часу на збір і розмітку [3].

Метою доповіді є представлення узагальненого, відтворюваного підходу до аугментації ЕЕГ-епох, який зберігає фізіологічну правдоподібність сигналу та сумісний з типовою попередньою обробкою сигналу.

Результати дослідження

У доповіді акцент робиться на простих деформаціях, які відображають реальні джерела варіацій у сигналах і не руйнують частотну структуру сенсомоторних ритмів. У практичній частині аналізу використано дані формату «епоха-канали-час» з 8-канальною конфігурацією при частоті дискретизації 250 Гц і тривалістю епохи близько 4 секунд що складає приблизно 1000-1011 відліків на канал. Розглядаються три класи моторної активності, типові для прикладного BCI: стан спокою, стискання кисті та розтискання кисті. Базова попередня обробка передбачає стабілізацію масштабу й спектрального вмісту сигналу, включаючи видалення зсуву, застосування режекторного фільтра для усунення мережевої складової 50 Гц, смугову фільтрацію 8-30 Гц (μ - та β -діапазони) та нормалізацію по каналах. Такий підхід відповідає практичним рекомендаціям щодо цифрової фільтрації електрофізіологічних даних і дозволяє відокремити ефект аугментації від ефектів «очищення» сигналу.

У доповіді розглянуто методи аугментації, реалізовані в навчальній послідовності проекту. Перша група перетворень – додавання Гаусового шуму до сигналу – моделює сенсорний шум та дрібні флуктуації, характерні для реальних записів, підвищуючи стійкість моделі до неконтрольованих домішок. Друга група – часові зсуви епохи в межах невеликого інтервалу – відображає варіативність моменту початку реакції та різницю в темпі виконання дії; така аугментація є особливо релевантною для парадигм, де епоха формується за чітко встановленим протоколом, а реальний нейрофізіологічний ефект з'являється не миттєво. Третя група – амплітудне масштабування – узгоджується з практикою недорогих систем, де імпеданс електродів та налаштування підсилення можуть змінювати загальний масштаб сигналу між сесіями, не змінюючи принципову структуру ритмів. Комбіновані перетворення (поєднання шуму й масштабування) відображають типову ситуацію, коли в записі одночасно присутні різні джерела варіацій. Окремо розглядається динамічна аугментація, що виконується під час процесу навчання. При традиційному підході спочатку створюються та зберігаються на диску копії епох з застосованими перетвореннями, і модель навчається на цьому фіксованому наборі. У динамічному підході перетворення застосовуються миттєво: коли система навчання вибирає епоху для показу моделі, до неї одразу застосовуються випадкові перетворення (наприклад, додається шум з випадковою амплітудою, виконується випадковий часовий зсув), і ця змінена версія передається моделі для обробки. Наступного разу, коли та сама епоха буде використана для навчання, до неї застосовуються інші випадкові перетворення. Такий підхід дозволяє уникнути зберігання великої кількості модифікованих копій на диску та забезпечує максимальну варіативність: модель бачить різні варіації однієї й тієї ж епохи при кожному її повторному використанні, що значно підвищує різноманітність навчального набору без збільшення обсягу даних що повинні зберігатися.

Ключовим методологічним принципом є те, що аугментація для ЕЕГ повинна бути контрольованою: надто агресивні перетворення здатні створювати нереалістичні приклади, що погіршує узагальнення замість його покращення. Для задач моторної активності критично зберегти інформативні компоненти в цільовій смузі частот, а також не руйнувати відносні відмінності між каналами. Тому при виборі параметрів аугментації необхідно обмежувати амплітудні множники, масштаб шуму та максимальний часовий зсув до значень, які відповідають реальним коливанням у записах. У роботі підкреслюється практична потреба контролю правдоподібності: доцільно перевіряти декілька прикладів у часовій області та порівнювати спектральні характеристики до та після аугментації, щоб переконатися, що перетворення не породжує артефактних частотних компонент і не пригнічує необхідні релевантні діапазони.

Оцінювання ефективності аугментації потребує коректного протоколу валідації, адже випадкове розбиття епох на тренувальну та валідну може завищувати оцінку узагальнення, оскільки епохи однієї сесії часто мають спільне джерело шумів та умов запису. Більш інформативним є «стрес-тест» між сесіями, коли тестова частина формується з іншого запису: саме в цьому сценарії аугментація демонструє свою практичну цінність, і саме тут її параметри і повинні підбиратися. Додатково підкреслюється ризик витоку інформації: всі параметри нормалізації та стандартизації повинні обчислюватися лише на навчальних даних, а аугментація не повинна використовувати жодних характеристик тестового набору. Також аугментація даних не вирішує проблему незбалансованого

розподілу класів: якщо деякі класи містять значно більше епох, ніж інші (наприклад, клас «спокій» може містити втричі більше прикладів, ніж класи «стискання» або «розтискання»), то стандартна аугментація, що застосовується до всіх класів однаково, лише пропорційно збільшує кількість прикладів кожного класу, зберігаючи або навіть посилюючи початкову асиметрію розподілу. Для корекції незбалансованого розподілу класів у роботі застосовано вагові коефіцієнти класів у функції втрат. Вагові коефіцієнти обчислюються автоматично на основі розподілу класів у навчальному наборі: спочатку визначається середня кількість прикладів на клас (загальна кількість прикладів, поділена на кількість класів), а потім для кожного класу ваговий коефіцієнт встановлюється як відношення цієї середньої кількості до фактичної кількості прикладів даного класу. Таким чином, рідкісні класи (з меншою кількістю прикладів) отримують вищі ваги, а часті класи (з більшою кількістю прикладів) – нижчі. Під час обчислення функції втрат кожна помилка класифікації множить на відповідний ваговий коефіцієнт класу справжньої мітки, тому помилки на рідкісних класах вносять більший внесок у загальну функцію втрат, і процес оптимізації моделі більше фокусується на правильній класифікації цих прикладів. Альтернативним підходом є контрольоване формування навчальних наборів, де при формуванні кожної групи прикладів, що обробляється одночасно під час навчання, забезпечується приблизно рівна представленість кожного класу; однак у практичній реалізації використання вагових коефіцієнтів є більш ефективним, оскільки не вимагає модифікації навчального набору та зберігає всі доступні дані.

З практичної точки зору аугментація розглядається як компонент «мінімально достатнього» процесу роботи для малих наборів даних ЕЕГ сигналів, який дозволяє знизити повторювану адаптацію і підвищити перенос між сесіями без значного ускладнення реалізації. Очікуваний результат аугментації проявляється у більш узгоджених тренувальних і валідаційних даних, зменшенні розриву між якістю навчальних і тестових сигналів та підвищенні стабільності класифікації на нових записах. Рекомендації щодо вибору типів аугментації для недорогих ВСІ систем можна підсумувати наступним чином: починати з малих шумових збурень та часових зсувів, обережно додавати масштабування, а комбіновані перетворення застосовувати лише після візуальної та кількісної перевірки їх правдоподібності. Підсумковий висновок полягає у тому, що аугментація є ефективною лише тоді, коли вона відображає реальні джерела варіацій у сигналів ЕЕГ, а її вплив оцінюється на протоколі, який відповідає прикладному використанню системи.

Окрему увагу доцільно приділити співвідношенню аугментації та архітектури моделі. Для компактних нейромережових моделей, орієнтованих на малі набори даних, аугментація зменшує залежність від випадкових особливостей конкретної сесії та підсилює інваріантність до незначних зсувів у часі й масштабі сигналу. Водночас для класичних методів, де ознаки формуються явно (наприклад, через спектральні або дисперсійні характеристики), надмірні амплітудні перетворення можуть змінювати статистики, на яких базується класифікація, і тому потребують більш обережного підбору параметрів. Практичним правилом є узгодження аугментації із тим, які властивості сигналу модель вважає інформативними: якщо модель переважно опирається на ритмічний вміст у смузі μ - та β -діапазонів, то перевагу слід надавати тим деформаціям, які не змінюють спектральну форму, а лише моделюють шум і часову невизначеність.

Перспективи подальших досліджень

Перспективним напрямом подальшої роботи є доповнення розглянутих методів аугментації процедурами адаптації до користувача та міжсесійної калібровки. У прикладних ВСІ-сценаріях якість часто обмежується не лише обсягом даних, а й дрейфом умов запису у часі; тому комбінація помірної аугментації з протоколами подальшого навчання або адаптивної нормалізації може забезпечити кращу стабільність без збільшення навантаження на користувача. Також доцільно вивчити, які саме типи аугментації найбільше впливають на перенос між сесіями в моторних задачах, та сформувати профіль рекомендованих перетворень для недорогих ВСІ-систем з малою кількістю каналів, де можливості складного просторового очищення сигналу є обмеженими.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. BKT. EEG Based Brain Computer Interfaces: Unlocking New Communication Pathways [Electronic resource] / BKT // Integris Neuro. – Mode of access: <https://www.integrisneuro.com/post/eeg-based-brain-computer-interfaces-unlocking-new-communication-pathways> (date of access: 03.01.2026).

2. Nayak S. Normal EEG Waveforms [Electronic resource] / S. Nayak, C. Anilkumar // StatPearls [Internet]. Treasure Island (FL). – 2025. – Mode of access: <https://www.ncbi.nlm.nih.gov/books/NBK539805/> (date of access: 04.01.2026).
3. EEG Data Augmentation Method Based on the Gaussian Mixture Model [Electronic resource] // MDPI. – Mode of access: <https://doi.org/10.3390/math13050729> (date of access: 03.01.2026).

Соловей Сергій – аспірант, факультет радіофізики, електроніки та комп'ютерних систем, Київський національний університет імені Тараса Шевченка, Київ, e-mail: maximum.lenolo.ml@gmail.com.

Науковий керівник: **Барабанов Олександр** – канд. фіз.-мат. наук, доц., Київський національний університет імені Тараса Шевченка, Київ.

Serhii SOLOVEY – PhD Student, Faculty of Radiophysics, Electronics and Computer Systems, Taras Shevchenko National University of Kyiv, Kyiv, e-mail: maximum.lenolo.ml@gmail.com.

Supervisor: **Oleksandr BARABANOV** – PhD (Phys. & Math.), Assoc. Prof., Taras Shevchenko National University of Kyiv, Kyiv.