

МЕТОДОЛОГІЯ КЛАСИФІКАЦІЇ МАГНІТОЕНЦЕФАЛОГРАФІЧНИХ СИГНАЛІВ ІЗ ВИКОРИСТАННЯМ НАПІВКЕРОВАНОГО НАВЧАННЯ

Магнітоенцефалографія (МЕГ) — це неінвазивний метод дослідження мозку з високою часовою та просторовою роздільною здатністю, що робить його цінним інструментом для створення інтерфейсів мозок-комп'ютер (ІМК). На відміну від електроенцефалограми, МЕГ-сигнал менше спотворюється тканинами голови, забезпечуючи точніше визначення активних зон мозку. Для декодування сигналів МЕГ в ІМК застосовують різні методи машинного навчання, постійний розвиток яких сприяє підвищенню ефективності ІМК та розширенню їх застосування в медицині, реабілітації та інших галузях.

У даній роботі запропоновано методологію напівкерованої класифікації МЕГ-сигналів за допомогою моделі кодер-декодер та кластеризації. Цей підхід дозволяє використовувати нерозмічені дані для виявлення прихованих структур та покращення точності класифікації в інтерфейсах мозок-комп'ютер, що є важливим з огляду на обмежений обсяг доступних розмічених даних МЕГ. Методологія включає вибір архітектури моделі, конфігурацію кодера та декодера, кластеризацію сигналів, розширення розмічених даних та класифікацію з використанням макро-усередненої F1-міри як критерію оцінки.

Запропонована методологія надає перспективну основу для подальших досліджень у сфері інтерфейсів мозок-комп'ютер. Завдяки ефективному використанню нерозмічених даних МЕГ, вона може бути застосована до різних сценаріїв, де марковані дані є обмеженими або дорогими для отримання. Це може призвести до розробки точніших та надійніших ІМК для ширшого спектру застосувань, включаючи відновлення рухових функцій, когнітивне покращення та комунікаційну допомогу людям з обмеженими можливостями.

Ключові слова: інтерфейс мозок-комп'ютер, нейронна мережа, напівкероване навчання, кластеризація, класифікація.

KHOMIAK ANDRII

Ternopil Ivan Puluj National Technical University

METHODOLOGY OF MAGNETOENCEPHALOGRAPHY SIGNAL CLASSIFICATION USING SEMI-SUPERVISED LEARNING

Magnetoencephalography (MEG) is a non-invasive brain imaging technique that offers high temporal and spatial resolution, making it a valuable tool for the development of brain-computer interfaces (BCIs). In contrast to electroencephalography (EEG), MEG is less affected by distortions caused by head tissues, allowing for more precise localization of active brain regions. Various machine learning methods have been applied to decode MEG signals for use in BCIs. The continuous advancement of these methods has contributed to enhancing the efficiency of BCIs and expanding their applications in fields such as medicine, rehabilitation, and beyond.

This article introduces a semi-supervised classification methodology for MEG signals, which employs an encoder-decoder model combined with clustering techniques. This approach enables the utilization of unlabeled data to uncover hidden structures within the data, thereby improving classification accuracy in BCIs. This is particularly important given the limited availability of labeled MEG data. The methodology involves several key steps: selecting an appropriate model architecture, configuring the encoder and decoder components, clustering the signals, augmenting the labeled dataset, and ultimately performing classification. The macro-averaged F1-score is used as the evaluation metric to assess the performance of the classification.

The proposed methodology presents a promising framework for future research in the realm of brain-computer interfaces. By effectively leveraging unlabeled MEG data, this approach can be applied in various scenarios where labeled data is scarce or costly to obtain. The potential applications of this methodology are broad, encompassing areas such as motor rehabilitation, cognitive enhancement, and communication assistance for individuals with disabilities. By improving the accuracy and reliability of BCIs, this research could significantly impact the development and implementation of these technologies across a wide range of applications.

Keywords: brain-computer interface, neural network, semi-supervised learning, clustering, classification.

Аналіз досліджень та публікацій

Нестача маркованих даних для навчання моделей інтерфейсів мозок-комп'ютер є давнім викликом, що ускладнює розробку надійних та точних систем. Традиційні підходи, що базуються на навчанні з учителем, часто вимагають великої кількості маркованих даних для досягнення задовільних результатів, що особливо складно в дослідженнях ІМК через мінливість сигналів мозку та тривалість процесу маркування. Ця проблема висвітлена в дослідженні [1], де автори зазначають необхідність нових підходів для вирішення проблеми обмеженої кількості маркованих даних в ІМК.

Напівкероване навчання (НКН) розглядається як перспективна альтернатива, що дозволяє використовувати як марковані, так і немарковані дані. Це ефективно збільшує обсяг навчальних даних та потенційно покращує результати навіть за умов обмеженої кількості маркованих зразків. Цей підхід показав позитивні результати в різних застосуваннях ІМК, зокрема в аналізі даних ЕЕГ. У роботі [2] продемонстрували, як напівкерована генеративна змагальна мережа може покращити класифікацію рухової яви за умов обмеженої кількості маркованих ЕЕГ-даних.

В області ЕЕГ методи НКН, такі як спільне навчання [3], самонавчання [4] та методи на основі графів [5], застосовувалися для покращення точності класифікації в задачах рухової уяви, Р300-спелерів та розпізнавання емоцій.

Хоча НКН показало потенціал в ЕЕГ-базованих ІМК, його застосування до даних МЕГ досліджено менше. МЕГ має переваги перед ЕЕГ, зокрема вищу просторову роздільність та меншу чутливість до артефактів. Проте, брак маркованих МЕГ-даних створює аналогічну проблему. Лише деякі дослідження, такі як [6], розглядали НКН в МЕГ для класифікації рухової уяви.

На основі проведеного аналізу літературних джерел можна зробити висновок що адаптація методів НКН до МЕГ-даних є перспективним напрямом досліджень. Використання великої кількості немаркованих МЕГ-даних може призвести до створення точніших та надійніших МЕГ-базованих ІМК, що має значення для нейрореабілітації, комунікаційних пристроїв та нейроігор. Подальше вивчення НКН в МЕГ може відкрити нові можливості для використання інформації з МЕГ-сигналів та розвитку взаємодії мозку та комп'ютера.

Формулювання цілей статті

Мета даного дослідження полягає у розробці нового напівкерованого методу для інтерфейсів мозок-комп'ютер, що базуються на магнітоенцефалографії. Цей метод поєднуватиме переваги моделей кодер-декодер, алгоритмів кластеризації та попередньо отриманих центроїдів класів. Модель кодер-декодер буде навчена на немаркованих МЕГ-даних для виявлення ключових характеристик активності мозку. Потім алгоритм кластеризації буде застосований до маркованих МЕГ-даних у цьому просторі для визначення кластерів та їх центроїдів. Навчений кодер та центроїди будуть використані для маркування немаркованих МЕГ-даних, що дозволить розширити набір даних та покращити роботу МЕГ-ІМК. Запропонований метод спрямований на вирішення проблеми обмеженої кількості маркованих МЕГ-даних та підвищення точності та надійності МЕГ-ІМК для різних застосувань.

Виклад основного матеріалу

Набір даних [7] містить записи магнітоенцефалографії мозкової активності двох здорових праворуких людей під час виконання ними рухів зап'ястям у чотирьох різних напрямках. Учасники сиділи в кріслі МЕГ та рухали джойстик з центральної позиції до однієї з чотирьох мішеней, використовуючи лише праву руку та зап'ястя. Мішені були розташовані у формі ромба, вказуючи вліво, вправо, від та до тіла учасника.

Кожне випробування включало рух за сигналом, який ініціювався зникненням кола на екрані. Сигнали МЕГ записувалися з частотою дискретизації 625 Гц з десяти каналів, розташованих над моторними центрами мозку, потім фільтрувалися та передискретизувалися для аналізу (див. рисунки 1-2). Набір даних поділено на навчальний набір, який можна використовувати для розробки моделей класифікації напрямку руху, та тестовий набір для оцінки точності цих моделей. Основна увага приділяється низькочастотному компоненту сигналу МЕГ, який, як вважається, містить інформацію про напрямок руху.




Рис. 1. Приклад реалізації одного каналу МЕГ сигналу при руху зап'ястя вперед




Рис. 2. Приклад реалізації одного каналу МЕГ сигналу при руху зап'ястя вправо

Оскільки дані МЕГ є складними та високорозмірними, а отримання розмічених даних є ресурсозатратним процесом, існує нагальна потреба в розробці методів, які можуть ефективно використовувати нерозмічені дані для покращення точності класифікації в ІМК. Запропонована методологія напівкерованої класифікації послідовностей з використанням енкодер-декодерної архітектури безпосередньо вирішує цю проблему.

Використання енкодер-декодерної моделі дозволяє не лише стиснути дані до більш інформативної репрезентації, але й виявити приховані закономірності та структури в нерозмічених даних МЕГ [8]. Це особливо цінно, оскільки сигнали МЕГ містять складні часові та просторові залежності, які можуть бути важко виявити традиційними методами [9].

Застосування кластеризації до отриманих репрезентацій дозволяє групувати сигнали МЕГ на основі їх схожості, що може відповідати різним нейронним процесам або станам мозку [10]. Це дає змогу використовувати нерозмічені дані для виявлення потенційно значущих класів та шаблонів, які можуть бути використані для подальшої класифікації [11].

Розширення розмічених даних за допомогою кластеризації є ключовим елементом методології, оскільки дозволяє значно збільшити обсяг навчальних даних для класифікаційної моделі [12]. Це особливо важливо для даних МЕГ, де кількість розмічених зразків зазвичай обмежена.

Запропонована методологія включає наступні етапи [13]:

1 Вибір архітектури моделі. Для обробки послідовностей сигналів МЕГ пропонується використовувати рекурентні нейронні мережі (RNN), довго-короткотривалі мережі (LSTM) або архітектуру Transformer. Остаточний відбір архітектури нейронної мережі пропонується виконати шляхом навчання та оцінки якості проміжних моделей різних архітектур на валідаційній вибірці, створеній на основі навчального набору даних.

2 Конфігурація енкодера та декодера. Енкодер перетворює вхідні МЕГ-сигнали в низькорозмірну репрезентацію, а декодер відновлює оригінальні дані з цієї репрезентації. Навчання такого автоенкодера дозволяє енкодеру вивчити інформативні ознаки вхідних даних без необхідності розмітки (див. рисунок 3).

3 Кластеризація. Використовуючи репрезентації, отримані енкодером, проводиться кластеризація МЕГ-сигналів методом k-середніх. Отримані кластери можуть відповідати певним напрямкам або шаблонам руху кисті (див. рисунок 3).

4 Розширення розмічених даних. Сигналам, що належать до кластерів з відомою розміткою, присвоюються відповідні мітки класів, що дозволяє розширити обсяг розмічених даних для навчання класифікаційної моделі (див. рисунок 3).

5 Класифікація. На цьому етапі використовується класифікаційна модель, яка складається з попередньо натренованого енкодера та "голови-класифікатора". Модель навчається на даних, розмічених завдяки кластеризації, що дозволяє досягти вищої точності класифікації порівняно з використанням лише розмічених даних. Критерієм для оцінки класифікатора є макро-усереднена F1-міра.



Рис. 3. Методологія класифікації МЕГ-сигналів

Таким чином, запропонована методологія є інноваційним підходом до вирішення проблеми обмеженості розмічених даних МЕГ. Вона дозволяє ефективно використовувати велику кількість доступних нерозмічених даних, виявляти приховані структури та покращувати точність класифікації в ІМК. Це

відкриває нові можливості для розробки більш ефективних та доступних нейроінтерфейсів, які можуть знайти застосування в медицині, реабілітації та інших галузях.

Висновки

У даній роботі запропоновано нову методологію напівкерованого навчання для класифікації сигналів магнітоенцефалографії (МЕГ) в інтерфейсах мозок-комп'ютер (ІМК). Запропонований підхід поєднує в собі переваги моделей кодер-декодер, алгоритмів кластеризації та використання попередньо отриманих центроїдів класів. Це дозволяє ефективно використовувати як марковані, так і немарковані дані, що є особливо важливим з огляду на обмеженість розмічених даних МЕГ та їх високу вартість отримання.

Основними перевагами запропонованої методології є ефективне використання немаркованих даних, поєднання різних методів машинного навчання, що дозволяє використовувати їх сильні сторони та компенсувати недоліки; застосовність до різних завдань класифікації МЕГ-сигналів, таких як розпізнавання рухових намірів, емоційного стану тощо.

Запропонована методологія відкриває нові перспективи для розробки ефективних та точних ІМК на основі МЕГ, що може мати значний вплив на розвиток нейротехнологій, медицини та реабілітації. Подальші дослідження будуть спрямовані на практичну реалізацію та тестування запропонованого методу на реальних даних МЕГ, зокрема з метою аналізу характеристик його ефективності.

Література

1. Fabien Lotte [et al.] A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of neural engineering*. 2018. Vol. 15, no. 3. P. 031005.
2. Wonjun Ko [et al.] Semi-Supervised generative and discriminative adversarial learning for motor imagery-based brain-computer interface. 2021. <https://doi.org/10.21203/rs.3.rs-677820/v1>.
3. Weiqi Zhang [et al.] A co-training approach for noisy time series learning. *Proceedings of the 32nd ACM international conference on information and knowledge management*. Birmingham, United Kingdom, 2023. – P. 3308-3318. <https://doi.org/10.1145/3583780.3614759>. – Title from screen.
4. Yanghan Ou [et al.] An improved self-supervised learning for {EEG} classification. *Math. biosci. eng.* 2022. Vol. 19, no. 7. P. 6907-6922.
5. Cunbo Li [et al.] An efficient graph learning system for emotion recognition inspired by the cognitive prior graph of EEG brain network. *IEEE transactions on neural networks and learning systems*. 2024. P. 1-15. <https://doi.org/10.1109/TNNLS.2024.3405663>.
6. Halme H.-L., Lauri Parkkonen Comparing features for classification of MEG responses to motor imagery. *Plos one*. 2016. Vol. 11, no. 12. P. 1-21. <https://doi.org/10.1371/journal.pone.0168766>. – Title from screen.
7. Kingma D. P., Max Welling Auto-Encoding variational bayes. 2022.
8. Goodfellow I., Yoshua Bengio, Aaron Courville *Deep learning*. [S. l.] : MIT Press, 2016.
9. Jain A. K. Data clustering: 50 years beyond K-means. *Pattern recognition letters*. 2010. Vol. 31, no. 8. – P. 651-666. <https://doi.org/10.1016/j.patrec.2009.09.011>.
10. Chapelle O., Scholkopf B., Zien A. *Semi-Supervised Learning* (Chapelle, O. et al., Eds.; 2006) [Book reviews]. *IEEE transactions on neural networks*. 2009. Vol. 20, no. 3. P. 542--542. <https://doi.org/10.1109/TNN.2009.2015974>.
11. BCI competition IV. <https://bbci.de/competition/iv/>. <https://web.archive.org/web/20240415211536/https://bbci.de/competition/iv/>.
12. Li Y.-F., Zhi-Hua Zhou Towards making unlabeled data never hurt. *IEEE trans. pattern anal. mach. intell.* 2015. Vol. 37, no. 1. P. 175-188.
13. Хом'як А. С. Класифікація магнітоенцефалограми руху кисті за напрямком руху з використанням напівкерованого навчання, енкодер-декодерної архітектури та алгоритмів кластеризації. *Збірник матеріалів ХХІІІ Міжнародної науково-технічної конференції ПРИЛАДОБУДУВАННЯ: стан і перспективи*, 14-15 травня 2024 р., Київ, 14 трав. 2024 р. С. 173–175.

References

1. Fabien Lotte [et al.] A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of neural engineering*. 2018. Vol. 15, no. 3. P. 031005.
2. Wonjun Ko [et al.] Semi-Supervised generative and discriminative adversarial learning for motor imagery-based brain-computer interface. 2021. <https://doi.org/10.21203/rs.3.rs-677820/v1>.
3. Weiqi Zhang [et al.] A co-training approach for noisy time series learning. *Proceedings of the 32nd ACM international conference on information and knowledge management*. Birmingham, United Kingdom, 2023. – P. 3308-3318. <https://doi.org/10.1145/3583780.3614759>. – Title from screen.
4. Yanghan Ou [et al.] An improved self-supervised learning for {EEG} classification. *Math. biosci. eng.* 2022. Vol. 19, no. 7. P. 6907-6922.
5. Cunbo Li [et al.] An efficient graph learning system for emotion recognition inspired by the cognitive prior graph of EEG brain network. *IEEE transactions on neural networks and learning systems*. 2024. P. 1-15. <https://doi.org/10.1109/TNNLS.2024.3405663>.
6. Halme H.-L., Lauri Parkkonen Comparing features for classification of MEG responses to motor imagery. *Plos one*. 2016. Vol. 11, no. 12. P. 1-21. <https://doi.org/10.1371/journal.pone.0168766>. – Title from screen.

-
7. Kingma D. P., Max Welling Auto-Encoding variational bayes. 2022.
 8. Goodfellow I., Yoshua Bengio, Aaron Courville Deep learning. [S. l.] : MIT Press, 2016.
 9. Jain A. K. Data clustering: 50 years beyond K-means. Pattern recognition letters. 2010. Vol. 31, no. 8. – P. 651-666. <https://doi.org/10.1016/j.patrec.2009.09.011>.
 10. Chapelle O., Scholkopf B., Zien A. Semi-Supervised Learning (Chapelle, O. et al., Eds.; 2006) [Book reviews]. IEEE transactions on neural networks. 2009. Vol. 20, no. 3. P. 542--542. <https://doi.org/10.1109/TNN.2009.2015974>.
 11. BCI competition IV. <https://bbci.de/competition/iv/>. <https://web.archive.org/web/20240415211536/https://bbci.de/competition/iv/>.
 12. Li Y.-F., Zhi-Hua Zhou Towards making unlabeled data never hurt. IEEE trans. pattern anal. mach. intell. 2015. Vol. 37, no. 1. P. 175-188.
 13. Khomiak A. C. Klasyfikatsiia mahnitoentsefalohramy rukhu kysti za napriamkom rukhu z vykorystanniam napivkerovanoho navchannia, enkoder-dekodernoï arkhitektury ta alhorytmiv klasteryzatsii. Zbirnyk materialiv KhXIII Mizhnarodnoi naukovo-tekhnichnoi konferentsii PRYLADOBUDUVANNIA: stan i perspektyvy, 14-15 travnia 2024 r., Kyiv, 14 trav. 2024 r. S. 173–175.