

УДК 004.942

Яненко М.В.

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Попов А.О.

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

ВИЗНАЧЕННЯ РУХУ ПАЛЬЦЯМИ НА ОСНОВІ ЕЛЕКТРОКОРТИКОГРАМИ ЗА ДОПОМОГОЮ ПАРАМЕТРИЧНОГО МОДЕЛЮВАННЯ

У роботі представлено застосування параметричної моделі мозкової активності з використанням машинного навчання для виявлення факту наявності руху пальцями для застосування в нейрокомп'ютерних інтерфейсах.

Представлений підхід на основі побудови параметричної моделі авторегресії-усереднення зі зсувом із попереднім вибором основного каналу та застосуванням моделі машинного навчання із вчителем «багатошарова нейронна мережа», за допомогою якого відбувається визначення руху будь-яким пальцем. У результаті отримується клас фрагмента сигналу, що вказує на рух або відсутність руху пальцями. У результаті використання запропонованого підходу точність класифікації становить 95,5%. Для моментів без руху істинно позитивне визначення становить 91,0%, для моментів з рухом 100%. Запропонований підхід є новим і може бути використаний для створення інтерфейсів мозок-комп'ютер.

Ключові слова: машинне навчання, інтерфейс мозок-комп'ютер, електрокортикограма, параметричне моделювання, класифікація, визначення рухів пальцями.

Постановка проблеми. Наявний певний спектр задач зі створення інтерфейсів мозок-комп'ютер, в якому є достатнім визначення самого факту дії без конкретизації. Наприклад, виклик медсестри або лікаря за рухом пальців для паралізованих пацієнтів, надання відповіді на прості запитання, на які можлива відповідь так/ні, або для контролювання рухової активності мозку. Тому задача визначення факту руху пальців буде розглянута у цій роботі.

Аналіз останніх досліджень і публікацій. Інтерфейс мозок-комп'ютер (Brain Computer Interface – BCI), також відомий як інтерфейс мозок-машина (Brain Machine Interface – BMI), являє собою апаратне і програмне забезпечення системи зв'язку, яка дає змогу людям взаємодіяти з навколишнім світом без участі периферичних нервів і м'язів за допомогою керуючих сигналів, що генеруються на основі електричної активності мозку.

BCI є системою штучного інтелекту, яка може розпізнавати певний набір шаблонів мозкових сигналів у наступних п'яти послідовних етапах, таких як: виявлення сигналу, попередня обробка сигналу, розрахунок ознак, класифікація, інтерфейс управління [1]. Як вхідний сигнал таких систем може бути використана електроміографія [2]

або магнітоенцефалографія [3], проте найчастіше для BCI використовують електроенцефалографічні (ЕЕГ) сигнали, що має низку переваг, таких як неінвазивність, портативність і економічна ефективність. Проте є і низка недоліків, таких як зашумленість і низька роздільна здатність сигналу, тому часто використовують і інші методи отримання сигналів з мозку, зокрема електрокортикографію (Electrocorticalography – ECoG), що використовує електроди, поміщені безпосередньо на відкритій поверхні мозку для запису електричної активності від кори головного мозку [4]. Оскільки трепанація (хірургічний розріз у черепі) є потрібною для імплантації сітки електродів, ECoG є інвазивною процедурою.

BCI створює новий нем'язовий канал для ретрансляції намірів людини до зовнішніх пристроїв, таких як комп'ютери, синтезатори мови, допоміжні прилади і нейронні протези. Це є особливо важливим для осіб з важкими порушеннями рухових функцій [5]. Такий інтерфейс дасть змогу поліпшити якість їхнього життя і призведе водночас до зниження витрат на інтенсивну терапію.

Технологія BCI набула широкого застосування. Було продемонстровано контроль польоту віртуального вертольота за допомогою BCI ЕЕГ [6] та дрона [7]. Створено ігрове поле, де за допомогою




Рис. 1. Сигнал електрокортикограми з одного з електродів

Всі гравець взаємодіє з консоллю без використання контролера. Музика і декорації регулюються залежно від настрою гравця чи судді за його ЕЕГ [8], частоти серцевих скорочень і когнітивних станів, що дає змогу зробити гру більш реалістичною.

Безсумнівно, ВСІ-ЕЕГ є видатною технологією в галузі обробки сигналів і принесе покращення в медицині і нашому житті [9]. Зокрема, така технологія використовується для управління протезами кінцівок на основі ЕЕГ [10]. Для таких систем важливим є розпізнавання рухів кінцівками [11;12], а особливо рухів пальцями. Більшість досліджень зосереджено на передбаченні траєкторії руху пальцями на основі мозкової активності [13].

Постановка завдання. Задачею представленої роботи є визначення факту наявності руху будь-якого пальця або моментів без руху жодного. Ця задача може бути представлена як задача класифікації. Така класифікація є бінарною, оскільки існує лише два класи: 0 – моменти без руху, 1 – моменти з рухом будь-якого пальця.

Виклад основного матеріалу дослідження. Дані були записані у Вашингтонському Університеті на дев'яти добровольцях, що дали інформовану згоду, імена яких були приховані [14]. Безпосередньо на поверхню мозку помістили масив з електродів (від 48 до 64, по-різному для різних пацієнтів), що записували кортикограму. Під час запису пацієнт здійснював рухи пальцями однієї руки по черзі згідно з вказівками на моніторах.

Координати кожного пальця реєструються з частотою дискретизації в 25 Гц, пізніше дані були інтерпольовані до частоти 1000 Гц. Середня тривалість кожного руху становить 2 секунди, як і тривалість спокою. Всього за час руху було здійснено близько 30 рухів кожним пальцем. Дані ЕКоГ були записані з частотою дискретизації 1000 Гц. Запис проводився протягом 10 хвилин.

Задачею цієї роботи є визначення факту руху будь-яким пальцем, що може бути представлена як задача класифікації. Таким чином, існує два класи: перший клас – відсутність будь-якого руху пальцями, другий клас – рух будь-яким пальцем. На вхід класифікатора подається вектор особливостей, на виході маємо 0 (перший клас) або 1 (другий клас).

Важливим є зменшити розмірність вектора ознак, що зменшить складність навчання класифікатора без зменшення точності. Для цього потрібно визначити електроди, на яких реєструється максимальна рухова активність під час руху пальцями. Наявність рухової активності буде означати збільшення дисперсії сигналу порівняно зі станом спокою [15].

Дисперсія сигналу не може бути оцінена класичним способом, оскільки на записі електроенцефалограми завжди присутня фонові активність, що накладається на рухову. Така активність в мозку людини має меншу амплітуду і присутня завжди, тому важливо відділити її від активності мозку, що виникає внаслідок руху, для подальшої оцінки. Отримані дисперсії компоненти руху для

кожного з електродів можуть бути порівняні з дисперсією без руху.

Для виділення головних компонент, що відповідають за рух пальцями, в роботі запропоновано застосувати метод головних компонент для відрізків сигналу, що відповідають руху пальців та моментам без руху, для кожного з електродів. Метод головних компонент (Principal Component Analysis – PCA) – це статистична процедура, яка використовує ортогональне перетворення для перетворення набору спостережень, можливо, корельованих змінних у набір лінійно некорельованих складників, які називаються основними компонентами. Це перетворення визначається таким чином, що перший основний компонент має найбільшу можливу дисперсію, і кожний наступний компонент, своєю чергою, має найвищу дисперсію, досягнувши у разі обмеження, щоб він був ортогональний до попередніх компонентів. Отримані вектори є некорельованим ортогональним базисом. Основні компоненти є ортогональними, тому що вони є власними векторами коваріаційної матриці, яка є симетричною [16]. Частка дисперсії, яку представляє кожен отриманий власний вектор, може бути обчислена шляхом ділення власного значення, що відповідає цьому власному вектору на суму всіх власних значень [17].

Метод PCA був застосований до відрізків сигналу, що відповідають руху пальців для кожного електроду. Знайшовши власні числа для першого компонента кожного електроду і визначивши електрод з максимальною різницею між дисперсією в момент руху і без руху, виберемо його для подальшого формування вектора особливостей. Вибраний сигнал був відфільтрований у смузі частот 65-200 Гц, оскільки в попередніх дослідженнях [12] було знайдено значну кореляцію між рухами пальців однієї руки з електрокортикограмою в смузі частот 65-200 Гц, куди входить і гамма-ритм.

У результаті було отримано головні компоненти запису ЕкоГ для руху пальців та власні числа, що відповідають їм. Також було знайдено власні числа в моменти без руху.

Для одержання вектора особливостей побудовано параметричну модель, параметри якої в подальшому було використано для класифікації. Як параметричну модель було вибрано модель авторегресій-усереднення зі зсувом. Модель авторегресій-усереднення зі зсувом (autoregressive moving average model, ARMA) – одна з математичних моделей, що використовується для аналізу і прогнозування стаціонарних часових рядів у ста-

тистичі. ARMA-модель узагальнює дві більш прості моделі – модель авторегресій (autoregression, AR) і моделі усереднення зі зсувом (moving-average, MA) [18].

Моделлю ARMA(p, q), де p, q – цілі числа, що задають порядок моделі, називається такий процес генерації часового ряду:

$$X_t = c + \varepsilon_t + \sum_{j=0}^q \beta_j \varepsilon_{t-j} + \sum_{j=0}^p \alpha_j X_{t-j},$$

де c – константа, ε_t – білий шум, тобто послідовність незалежних і однаково (як правило, нормально) розподілених випадкових величин, з нульовим середнім, α_j і β_j – дійсні числа, авторегресійні коефіцієнти і коефіцієнти усереднення зі зсувом відповідно.

Для визначення моментів руху потрібно вибрати підходящий класифікатор. У цій роботі було вибрано штучну нейронну мережу, оскільки вона може бути розглянута як модель біологічних нейронних мереж нашого мозку. Штучна нейронна мережа – це деяка математична модель, що складається з групи нейронів, що взаємодіють між собою. Кожен нейрон може лише виконувати просту математичну дію та має справу лише з вхідними і вихідними сигналами [19]. Такий нейрон являє собою суматор з ваговими коефіцієнтами, сигнал з якого додається до зміщення і подається на функцію передачі. Вихідний сигнал a визначається згідно з формулою:

$$a = f(wp + b),$$

- де p – вхідний сигнал;
- w – вагові коефіцієнти;
- b – коефіцієнт зміщення;
- $f(x)$ – цільова функція;

Такі нейрони можуть мати декілька вхідних сигналів і таким чином з'єднуються у мережу з декількома шарами нейронів у ній. Кожен шар може мати різну кількість нейронів та мати різну функцію передачі у них.

У роботі було спроектовано двошарову нейронну мережу. У першому шарі функція передачі була вибрана як лог-сігмоїдна, що задається рівнянням [20]:

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Другий шар має іншу функцію передачі softmax, що є узагальненою логістичною функцією. Вона дає змогу перерахувати вектор p розмірності K у вектор σ аналогічної розмірності, кожна координата якої представлена числом від 1 до 0 [21]. Координати вектора обчислюються таким чином:

$$\sigma_i = \frac{e^{p_i}}{\sum_{k=1}^K e^{p_k}}$$

У машинному навчанні координати цього вектора означають ймовірність того, що об'єкт належить класу i .

Основна особливість таких мереж – здатність до навчання. У технічному сенсі вона виражається у виборі коефіцієнтів кожного нейрона (w та b). У математичному сенсі процес навчання визначається як задача оптимізації, що зводиться до зменшення похибки між вихідними сигналами та реальними даними з навчальної вибірки. Такий процес називається навчанням із вчителем.

У разі використання функції softmax для оцінки похибки використовують перехресну ентропію [22], що і була використана в цій роботі.

$$H(T, q) = -\sum_{i=1}^N \frac{1}{N} \log_2 q(x_i),$$

де T – дані для навчання, N – розмір даних для навчання, $q(x_i)$ – ймовірність події.

Для розв'язання таких задач використовують низку методів, серед них і градієнтні. У цій роботі було використано метод спряжених градієнтів.

Вибірка вхідних даних була сформована з рівною кількістю прикладів для двох класів. Дані були перемішані у випадковому порядку. Для навчання нейронної мережі було використано 70% початкової вибірки, 30% – для тестування.

Результати класифікації тестової вибірки представимо у вигляді матриці невідповідності.

На рисунку 2 зображено матрицю невідповідності для цієї задачі. Рядки матриці відповідають класифікованим класам, стовпці – реальним класам, головна діагональ – правильно визначені класи. Числа поза діагоналлю відповідають неправильно визначеним прикладам. Зелені цифри в крайньому лівому стовпчику відповідають параметру позитивної прогностичної цінності (positive predictive value – PPV), червоні – складності неправильного визначення (false discovery rate – PDR) для кожного класу. Зелені цифри у нижньому рядку – істинно позитивне визначення

Output Class	1	1016 45.5%	0 0.0%	100% 0.0%
	2	100 4.5%	1116 50.0%	91.8% 8.2%
		91.0% 9.0%	100% 0.0%	95.5% 4.5%
		1	2	
		Target Class		

Рис. 2. Матриця невідповідності для шестикласової класифікації

(true positive rate – TPR), червоні – помилково позитивне визначення (false negative rate FNR). Нижня права клітинка – загальна точність (зелені цифри) та загальна похибка (червоні цифри).

Висновки. Застосування параметрів ARMA моделі до сигналу рухової активності мозку з попереднім вибором відведення для класифікації за допомогою PCA дає змогу визначити як факт руху будь-яким пальцем.

Точність визначення наявності руху пальця становить 95.5%, при цьому для моментів без руху істинно позитивне визначення становить 91.0%, для моментів з рухом – 100%. У подальшому цей принцип може бути застосований для створення інтерфейсів мозок–комп'ютер іншого типу.

Список літератури:

1. Pfurtscheller G., Gernot R. Müller-Putz. "Rehabilitation with Brain-Computer Interface Systems", IEEE Computer Society. 2008. Vol 41. P. 58–65.
2. Christoph Reichert, Stefan Dürschmid, Hans-Jochen Heinze, Hermann Hinrichs. A Comparative Study on the Detection of Covert Attention in Event-Related EEG and MEG Signals to Control a BCI. Front. Neurosci. 2017.
3. L.R. Quitadamo, "Support vector machines to detect physiological patterns for EEG and EMG-based human-computer interaction: a review". J. Neural Eng. 2017. Vol. 14.
4. Rouse A.G., D.W. Moran. Neural adaptation of epidural electrocorticographic (EECoG) signals during closed-loop brain computer interface (BCI) tasks. In Proc. IEEE MBS. 2009. P. 5514–5517.
5. Chang-Hee Han, Chang-Hwan Im, "EEG-based brain-computer interface for real-time communication of patients in completely locked-in state". 2018 6th International Conference on Brain-Computer Interface (BCI). 2018.

6. Makeig, S. "First Demonstration of a Musical Emotion BCI". ACII: part 2. P. 487–496. 2011.
7. Abijith Vijayendra, Saumya Kumaar, Ravi M. Vishwanath1, S.N. Omarkar, "A Performance Study of 14-Channel and 5-Channel EEG Systems for Real-Time Control of Unmanned Aerial Vehicles". 2018 Second IEEE International Conference on Robotic Computing. P. 183–188. 2018.
8. "Role of EEG in Brain to Computer Interface", Silicon Mentor, 2015. URL: <http://siliconmentor.blogspot.in/2015/05/role-of-eeeg.html>
9. Palmini A., "The concept of the epileptogenic zone: A modern look at Penfield and Jasper's views on the role of interictal spikes". Epileptic Disorders. Vol 8. 2006.
10. Richard T. Lauer, CA P. Hunter Peckham, Kevin L. Kilgore, "EEG-based control of a hand grasp neuroprosthesis". NeuroReport. Vol. 10. No 8, 1999.
11. Prasant Kumar Pattnaik, Jay Sarraf, "Brain Computer Interface issues on hand movement". Journal of King Saud University – Computer and Information Sciences. Vol. 30. 2018. P 18–24.
12. Alireza Ghaemi, Esmat Rashedi, Ali Mohammad Pourrahimi, Mehdi Kamandar, Farhad Rahdari, "Automatic channel selection in EEG signals for classification of left or right hand movement in Brain Computer Interfaces using improved binary gravitation search algorithm". Biomedical Signal Processing and Control. Vol. 33. P. 109–118. 2017.
13. Onaran I. Classification of Multichannel ECoG Related to Individual Finger Movements with Redundant Spatial Projections. / Ibrahim Onaran, N. Firat Ince, A. Enis Cetin. Conference of the IEEE EMBS. Boston. Massachusetts (USA). 2011. P. 5424–5427.
14. Kai J. Miller1, Dora Hermes, Human Motor Cortical Activity Is Selectively Phase-entrained on Underlying Rhythms. PLOS Computational Biology. Vol. 25. No. 9. P. 1–21. 2012.
15. Alexandre Barachant, Stephane Bonnet, Marco Congedo, Christian Jutten. Common Spatial Pattern revisited by Riemannian Geometry. 2010 IEEE International Workshop on Multimedia Signal Processing (MMSP). 2010.
16. Jolliffe I.T. "Principal Component Analysis, Second Edition". University of Aberden. P. 487. 2002.
17. Lorenzo-Seva U. "How to report the percentage of explained common variance in exploratory factor analysis". Technical Report. Department of Psychology. 2013.
18. Brockwell P.J., Davis R.A. "Time Series: Theory and Methods (2nd ed.)". New York: Springer. P. 273. 2009.
19. Rosenblatt Frank, "Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms". Spartan Books. 1961.
20. Han Jun, Morag Claudio. "The influence of the sigmoid function parameters on the speed of backpropagation learning". From Natural to Artificial Neural Computation. P. 195–201. 1995.
21. Bishop Christopher M. "Pattern Recognition and Machine Learning". Springer. 2006.
22. Murphy Kevin. "Machine Learning: A Probabilistic Perspective". MIT. 2012.

ОПРЕДЕЛЕНИЕ ДВИЖЕНИЙ ПАЛЬЦАМИ НА ОСНОВЕ ЭЛЕКТРОКОРТИКОГРАММЫ С ПОМОЩЬЮ ПАРАМЕТРИЧЕСКОЙ МОДЕЛИ

В работе представлено применение параметрической модели мозговой активности модели авторегрессии-усреднения со сдвигом с предыдущим выбором основного канала и применением многослойной нейронной сети, с помощью которой происходит определение движения любым пальцем, для применения в нейрокомпьютерных интерфейсах. В результате использования подхода точность классификации составляет 95.5%. Для моментов без движения истинно положительное определение составляет 91.0%, для моментов с движением 100%. Предложенный подход является новым и может быть использован для создания интерфейсов мозг–компьютер.

Ключевые слова: машинное обучение, интерфейс мозг–компьютер, электрокортикограмма, параметрическое моделирование, классификация, определение движений пальцами.

FINGERS MOTION DETECTION BASED ON ELECTROCORTICOGRAM USING A PARAMETRIC MODEL

The paper presents application of a parametric model of brain activity to detect the presence of finger motion for use in neurocomputer interfaces. The approach is based on the construction of a parametric autoregressive-moving average model with the previous choice of the main channel and the application of machine learning based on multilayer neural network, for determination of any finger motion. As a result of using the proposed approach the accuracy of the classification is 95.5%. For moments without motion, the true positive determination is 91.0%, for moments with a motion of 100%. The proposed approach is new and can be used to create brain–computer interfaces.

Key words: machine learning, interface brain–computer, electrokorticogram, parametric modeling, classification, finger motion detection.