

Яненко М.В.

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

КЛАСИФІКАЦІЯ РУХІВ ПАЛЬЦЯМИ НА ОСНОВІ ПАРАМЕТРИЧНОЇ МОДЕЛІ МОЗКОВОЇ АКТИВНОСТІ

У статті наведено методи визначення пальця, що здійснює рух у цей момент, на основі параметричних моделей. Також досліджується можливість використання параметрів моделі авто регресії – усереднення зі зсувом (як ознак для подальшої класифікації). Модель застосована до сформованих віртуальних каналів за допомогою методу загальних просторових шаблонів. Класифікатором було обрано метод опорних векторів, що дозволило отримати точність визначення пальця, що здійснює рух 93,1%. Такий принцип може бути використаний для створення пристроїв зв'язку «мозок – комп'ютер».

Ключові слова: машинне навчання, інтерфейс мозок – комп'ютер, електрокортикограма, модель авторегресії-усереднення зі зсувом, класифікація.

Постановка проблеми. Існують типи інтерфейсів зв'язку «мозок – комп'ютер», у яких не потребується точного положення пальця, а є достатнім визначення самого факту руху кожного конкретного пальця. Наприклад, взаємодія з віртуальною клавіатурою або з іншим віртуальним оточенням, зокрема для мультимедіа та комп'ютерних ігор. Також можливе створення простих протезів рук, що повністю стискає палець, на якому був визначений рух, і розтискає, коли рух припиняється. Тому завдання визначення руху конкретного пальця буде розглянуто в цій роботі.

Аналіз останніх досліджень і публікацій. Інтерфейс мозок-комп'ютер (Brain Computer interface (далі – BCI)) – це система апаратних і системних засобів, що дозволяє людському мозку взаємодіяти з об'єктами навколишнього світу без участі периферичних нервів і м'язів за допомогою керуючих сигналів, що генеруються на основі електричної активності мозку.

BCI є системою, що містить штучний інтелект, яка може розпізнавати певний набір шаблонів мозкової активності. Зазвичай, така система матиме такі основні послідовні етапи оброблення мозкового сигналу: попереднє оброблення сигналу, обчислення ознак, класифікація сигналу, генерування сигналів управління [1]. Найчастіше для BCI використовують електроенцефалографію – метод реєстрації біопотенціалів мозку, що генеруються клітинами мозку – нейронами. Зчитування таких потенціалів проводиться за допомогою електродів, що знаходяться на поверхні скальпу і реєструють електроенцефалограму (далі – ЕЕГ), потенціали коркових областей, що розташовані біля поверхні голови [2]. Такий під-

хід має низку таких переваг, як неінвазивність, низька собівартість та невеликі габарити, але, є і низка недоліків: високий рівень шумів і низька роздільної здатність сигналу. У деяких дослідженнях [3] використовують й інші способи отримання сигналів із мозку, зокрема електрокортикографію (Electrocorticography – ECoG), що реєструє мозкову активність використовуючи електроди, розташовані безпосередньо на корі головного мозку [4], яка проте потребує хірургічного розрізу для імплантації електродів, отже є інвазивним методом.

BCI створює додатковий канал в обхід м'язів для управління різноманітними зовнішніми пристроями, тому технологія BCI набула широкого застосування. Зокрема з використанням BCI виконують управління віртуальними транспортними засобами [5] та змодельованим віртуальним оточенням [6], що робить таку взаємодію більш реалістичною і зручною. Також BCI може бути застосований для управління курсором [1]. Також була представлена система управління автомобілем на основі BCI [7] [8]. Було представлено крісло з двигуном для людей з обмеженими можливостями [9] та маніпулятор для паралізованих людей [10] під управлінням BCI.

Безсумнівно, BCI-EEG є видатною технологією в галузі оброблення сигналів і принесе покращення в галузі медицини і нашого життя [11], що є особливо важливим для осіб із важкими порушеннями рухових функцій. Такий інтерфейс дозволить поліпшити якість життя і призведе до зниження витрат на інтенсивну терапію.

Така технологія була використана для управління нейропротезами на основі ЕЕГ [2]. Для




Рис. 1. Сигнал електрокортикограми з одного з електродів

таких систем важливим є розпізнавання рухів кінцівками, а особливо рухів пальцями. Більшість сучасних досліджень зосереджено на передбаченні траєкторії руху кожного пальця на основі мозкової активності [12].

Постановка завдання. Завданням роботи є визначення наявності руху кожного конкретного пальця або моментів без руху, що може бути представлена завданням класифікації. Таким чином, існує шість класів, де перший відповідає моментам без руху, інші п'ять відповідають пальцям від великого до мізинця, лише один клас може бути визначений одночасно. На вхід класифікатора подається вектор особливостей.

Виклад основного матеріалу дослідження. Дані для дослідження були записані у Вашингтонському Університеті на дев'яти анонімних пацієнтах, що були проінформовані про подробиці експерименту [13]. На кору головного мозку було поміщено масив з електродів (від 48 до 64), що реєстрували електрокортикограму. Під час запису пацієнт здійснював рухи пальцями однієї руки по черзі, згідно з написом на екрані. Координати кожного пальця фіксувались із частотою дискретизації в 25 Гц. Середня тривалість кожного руху становить 2 секунди, середня тривалість відсутності руху – 3 секунди. Усього за час руху було здійснено біля 30 рухів кожним пальцем. Дані ЕКоГ були записані з частотою дискретизації 1000 Гц. Запис проводився протягом 10 хвилин.

Для зменшення розмірності даних і формування навчальної вибірки для навчання було використано метод загального просторового шаблону.

Метод загальних просторових шаблонів (Common Spatial Pattern – CSP) дозволяє розкласти багатоканальний сигнал на адитивні компоненти, зважаючи на збільшення дисперсії між двома вибраними вікнами (X_1, X_2), що належать до різних класів. Розклад полягає в знаходженні вагових коефіцієнтів зваженої суми всіх каналів із такого виразу [14]:

$$(P_1 + P_2)^{-1} P_1 W = \Lambda W$$

Де: Λ – вектор власних значень;

W – матриця просторового фільтра;

P_1, P_2 – коваріаційні матриці для вікон X_1, X_2 .

Отриманий вектор $w = W_1$ і буде набором вагових коефіцієнтів, що були нормовані так щоб: $\sum_i w_i = 0$.

Для формування вікон X_1 та X_2 було використано відфільтровані в смузі 65-200 Гц дані. Тривалість вікон 1.9 секунд. Вікно X_1 було вибрано момент без руху, X_2 – момент руху вибраним пальцем. Процедура отримання вагових коефіцієнтів була повторена п'ять разів для кожного з пальців та окремо для всіх пацієнтів. Надалі було сформовано п'ять віртуальних каналів.

Як ознаки для класифікації було використано параметри параметричної моделі, що була побудована під час роботи. Моделлю було вибрано модель авторегресії-усереднення зі зсувом. Модель авторегресії – усереднення із зсувом (autoregressive moving-average model, ARMA) – це математична модель, що використовується для аналізу і прогнозування стаціонарних часових рядів у статистиці. ARMA-модель об'єднує дві більш прості моделі – модель авторегресії (autoregression, AR)

Test dataset 6 classes svm with Gaussian kernel fun.

| | | | | | | | |
|---|---------------|---------------|---------------|----------------|---------------|---------------|----------------|
| 1 | 368 15.8% | 18 0.8% | 8 0.3% | 19 0.8% | 17 0.7% | 19 0.8% | 82.0% 18.0% |
| 2 | 2 0.1% | 359 15.4% | 1 0.0% | 4 0.2% | 3 0.1% | 2 0.1% | 96.8% 3.2% |
| 3 | 0 0.0% | 3 0.1% | 386 16.6% | 8 0.3% | 1 0.0% | 4 0.2% | 96.0% 4.0% |
| 4 | 5 0.2% | 5 0.2% | 3 0.1% | 351 15.1% | 3 0.1% | 3 0.1% | 94.9% 5.1% |
| 5 | 1 0.0% | 3 0.1% | 2 0.1% | 2 0.1% | 374 16.0% | 7 0.3% | 96.1% 3.9% |
| 6 | 2 0.1% | 0 0.0% | 3 0.1% | 6 0.3% | 7 0.3% | 333 14.3% | 94.9% 5.1% |
| | 97.4% 2.6% | 92.5% 7.5% | 95.8% 4.2% | 90.0% 10.0% | 92.3% 7.7% | 90.5% 9.5% | 93.1% 6.9% |
| | 1 | 2 | 3 | 4 | 5 | 6 | |

Рис. 2. Матриця невідповідності для шестикласової класифікації

і моделі усереднення зі зсувом (moving-average, MA) [15].

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 із зсувом відповідно.

Класифікатором було використано метод опорних векторів (Support Vector Machine – SVM). У класичному випадку цей метод навчання з учителем, що полягає в проведенні гіперплощини розмірності n , таким чином, щоб відстань від точок цього простору для двох класів до розділяючої гіперплощини була максимальна [16]. Така гіперплощина проводиться по вибраним опорним векторам. У загальному вигляді такий класифікатор матиме вигляд:

$$a(x) = \text{sign} \left(\sum_{i=1}^n \lambda_i c_i K(x_i, x) + b \right),$$

де $a(x)$ – вихід класифікатора, рівний 1 або -1; λ_i – число складності, що показує те, наскільки корисний приклад вхідних параметрів x_i . Якщо $\lambda_i > 0$ то x_i – опорний вектор; c_i – бінарний вектор вхідних даних; $K(x_i, x)$ – базисна функція методу.

У більшості реальних випадків дані для навчання не можуть бути розділені лінійно. Тому

в цій роботі було застосовано нелінійну радіальну базисну функцію Гауса, що має вигляд [17]:

$$K(x_i, x) = \exp \left(- \frac{\|x - x_i\|^2}{2\sigma^2} \right)$$

Класичний метод опорних векторів є бінарним класифікатором. Оскільки для задачі, що була виконана в цій роботі, потрібно визначення шести класів (моменти без рухів та рухи п'яти пальців), потрібно використати багатокласову модифікацію методу. У цій роботі було використано метод виправлення вихідних помилок (Error-Correcting Output Codes - ECOC). За такого підходу багатокласова проблема розбивається на деяку кількість бінарних [18]. Для цього створюється кодуюча матриця M , кожен елемент якої може бути рівний -1, 0, +1, тобто тактика один проти одного. Рядки матриці відповідають класам, стовпці – класифікаторам. Кількість бінарних класифікаторів рівна $n(n-1)/2$, де n – кількість класів.

Вибірка вхідних даних була сформована з рівною кількістю прикладів для двох класів. Дні 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 цього завдання. Рядки матриці відповідають класифікованим класам, стовпці – реальним класам, головна діагональ – правильно визначені класи. Числа поза діагоналлю відповідають невірно визначеним прикладам. Зелені цифри в крайньому лівому стовпчику відповідає параметру позитивної прогностичної цінності (positive predictive value – PPV), червоні – складність неправильного визначення (false discovery rate – PDR) для кожного класу. Зелені цифри у нижньому рядку мають істинно позитивне визначення (true positive rate – TPR), червоні – помилково-позитивне визначення (false negative rate FNR). Нижня права клітинка – загальна точність (зелені цифри) та загальна похибка (червоні цифри). Як бачимо, точність становить 93,1%.

Висновки. Застосування параметрів ARMA-моделі до сигналу рухової активності мозку з формуванням віртуальних відведень за допомогою CSP дозволяє визначити як факт руху будь-яким пальцем.

Визначення пальця, що рухається, має загальну точність 93,1%, при цьому для моментів без руху істинно позитивне визначення становить 97,4%. Серед пальців найбільший відсоток істинно позитивного визначення має визначення вказівного пальця – 95,8%, найменшу – середній палець – 90,0%.

Список літератури:

1. Pfurtscheller G. Rehabilitation with Brain-Computer Interface Systems. IEEE Computer Society. 2008. P. 58–65.
2. Richard T. Lauer, C. P. Hunter Peckham and Kevin L. Kilgore. EEG-based control of a hand grasp neuroprosthesis. NeuroReport 10. 1999.
3. Leuthardt E.C., Schalk G., Wolpaw J.R., Ojemann J.G., Moran D.W. A brain-computer interface using Electro Cortico Graphic signals in humans. J. Neural Eng., no. 1. 2004. P. 63–71.
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. Makeig S. First Demonstration of a Musical Emotion BCI/ Scott Makeig, Grace Leslie, Tim Mullen, Devpratin Sarma, Nima Bigdely-Shamlo, Christian Kothe. ACII: part 2. Tennessee (USA). 2011. P. 487–496.
6. Role of EEG in Brain to Computer Interface. Silicon Mentor. 2015. URL: <http://siliconmentor.blogspot.in/2015/05/role-of-eeeg.html>
7. BrainDriver: A Mind Controlled Car/ Markus Waibel. IEEE Spectrum. 2011. URL: <http://spectrum.ieee.org/automaton/transportation/human-factors/braindriver-a-mind-controlled-car>
8. Mind-controlled car unveiled in China/ Madhumita Murgia. The Telegraph. 2015. URL: <http://www.telegraph.co.uk/technology/news/12040216/Mind-controlled-cars-unveiled-in-China.html>
9. Iturrate I. A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation/ Inaki Iturrate, Javier M. Antelis, Andrea Kubler, Javier Minguez. IEEE transactions on robotic. 2009. Vol. 25. No. 3. P. 614–627.
10. Wang C. Motor Imagery BCI-based robot arm system/ Cong Wang, Bin Xia, Jie Li, Wenlu Yang, Dianyun Xiao, Alejandro Cardona Velez, Hong Yang. Seventh International Conference on Natural Computation. Shanghai (China). 2011. P. 181–184.
11. Palmieri, A. The concept of the epileptogenic zone: A modern look at Penfield and Jasper's views on the role of interictal spikes. Epileptic Disorders 8. 2006.
12. 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.
13. Kai J. Miller, Dora Hermes, Human Motor Cortical Activity Is Selectively Phase-Entrained on Underlying Rhythms. PLOS Computational Biology. 2012.
14. 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.
15. Brockwell P.J.; Davis R.A. Time Series: Theory and Methods (2nd ed.). New York: Springer. 2009. 273 p.
16. Christianini, N., and J. C. Shawe-Taylor. An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods. Cambridge, UK: Cambridge University Press. 2000.
17. Bernhard Scholkopf, Kah-Kay Sung, Chris J. C. Burges, Federico Girosi, Partha Niyogi, Tomaso Poggio, and Vladimir Vapnik. Comparing Support Vector Machines with Gaussian Kernels to Radial Basis Function Classifiers. IEEE TRANSACTIONS ON SIGNAL PROCESSING. 1997.
18. Sergio Escalera, Oriol Pujol, Petia Radeva. On the Decoding Process in Ternary Error-Correcting Output Codes. IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE. 2010.

КЛАССИФИКАЦИЯ ДВИЖЕНИЙ ПАЛЬЦЕВ НА ОСНОВЕ ПАРАМЕТРИЧЕСКОЙ МОДЕЛИ МОЗГОВОЙ АКТИВНОСТИ

В статье приведены методы определения пальца, осуществляет движение в данный момент, на основе параметрических моделей. Также исследуется возможность использования параметров модели авто регрессии - усреднения со сдвигом в качестве признаков для дальнейшей классификации. Модель применена к сложившимся виртуальным каналам с помощью метода общих пространственных шаблонов. Как классификатор был выбран метод опорных векторов, позволило получить точность определения пальца, который осуществляет движение, 93,1%. Такой принцип может быть использован для создания устройств связи «мозг – компьютер».

Ключевые слова: машинное обучение, интерфейс мозг – компьютер, электрокортикограмма, модель авто регрессии-усреднения со сдвигом, классификация.

**CLASSIFICATION OF FUEL MOVEMENTS BASED
ON PARAMETRIC MODEL OF CARBON ACTIVITY**

The article describes the methods of determining the moment of a moving finger on the basis of parametric models. Also, the possibility of using parameters of the auto regression model – averaging with a shift as signs for further classification is investigated. The model is applied to the generated virtual channels using the method of general spatial patterns. As a classifier, the method of reference vectors was selected, which made it possible to obtain the accuracy of the determination of the finger, moving 93.1%. Such a principle can be used to create communication devices for the brain – a computer.

Key words: *machine learning, interface brain – computer, electrocorticogram, model of auto regression – moving averaging, classification.*