

Н. Л. ШАНАРОВА, М. М. ЛИПКОВИЧ, А. И. ВОЛОШИНА, А. А. АЛЕКСАНДРОВ, В. М. КНЯЗЕВА  
Санкт-Петербургский государственный университет, Санкт-Петербург

## КЛАССИФИКАЦИЯ СИГНАЛОВ ЭЛЕКТРОЭНЦЕФАЛОГРАММ ЧЕЛОВЕКА НА ОПРЕДЕЛЕНИЕ НАМЕРЕНИЯ СОВЕРШИТЬ ДВИЖЕНИЕ

*В данной работе представлены результаты исследования по классификации сигналов электроэнцефалограмм человека на определение намерения совершить движение. Сигналы подвергались удалению артефактов и фильтрации, после чего из них извлекались биомаркеры, отвечающие за самоинициированные движения. Классификация сигналов осуществлялась методами машинного обучения. Было произведено сравнение качества различных моделей, наилучшее из которых продемонстрировал метод опорных векторов. Результаты классификации могут быть использованы для разработки алгоритмов управления на основе нейрообратной связи.*

**Введение.** В настоящее время возрастает актуальность задачи изучения возможностей и повышения эффективности взаимодействия естественного и искусственного интеллекта. Первые шаги в этом направлении породили концепцию биологической обратной связи, которая основана на электроэнцефалографическом исследовании (ЭЭГ) [1]. В системах с биологической обратной связью в компьютер передаются сигналы, записанные с помощью неинвазивных средств, например, электроэнцефалограммы (ЭЭГ). Из этих сигналов через обработку и классификацию извлекается информация о состоянии организма (информация о состоянии нервной системы, в частности, коры головного мозга). Результат классификации поступает на вход регулятору. Многочисленные исследования доказали эффективность этого метода для изменения мощности различных частотных составляющих ЭЭГ [2].

Когнитивные вызванные потенциалы (ВП) являются одним из важнейших параметров, отражающих работу мозга. Они могут применяться для разработки нейроинтерфейсов и реализации парадигмы нейрообратной связи для обучения испытуемых регулированию ритмов головного мозга для решения различных задач управления, например, инвалидными колясками, мобильными робототехническими системами и т. п. Существуют перспективы развития области адаптивного управления и ее пересечения с областью машинного обучения [3]. Проводятся различные исследования по выделению биомаркеров, связанных с подготовкой и выполнением произвольных движений, направленных на разработку систем для преобразования намерения совершить движение в управляющие сигналы для внешних устройств. К примеру, распознавание нейрофизиологических сигналов человеческого мозга используются в таких системах, как «мозг-компьютер» [4, 5], в частности для помощи пациентам с двигательными нарушениями. Предлагаемый доклад посвящен применению методов машинного обучения для распознавания намерения совершить движение.

**Основная часть.** В ходе работ совместно с научной группой биологического факультета Санкт-Петербургского государственного университета (СПбГУ) была поставлена задача классификации вызванных потенциалов при самоинициированном произвольном движении, а именно распознавание намерения выполнить движение.

**Материал для исследования.** Для решения поставленной задачи используется база данных, подготовленная биологическим факультетом СПбГУ. Она состоит из записей электроэнцефалограмм 21 человека, проходивших специальный тест, в котором испытуемые производили самопроизвольные нажатия на клавишу. Перед началом эксперимента каждому испытуемому давалась инструкция избегать ритмических движений, варьировать время между нажатиями, совершать нажатие достаточное количество раз для набора статистики без точного количества нажатия. Для каждого испытуемого было записано 9 каналов. В среднем было совершено 104 нажатия на клавиши на одного испытуемого. Обученная модель по отрезку сигнала ЭЭГ должна быть способна предсказывать совершение движения в момент времени, последующий за данным отрезком [6].

**Удаление артефактов в сигнале ЭЭГ.** Современная электроэнцефалографическая аппаратура регистрирует чрезвычайно малые величины изменений биоэлектрических потенциалов, в связи с чем истинная ЭЭГ запись может искажаться вследствие воздействия разнообразных физических (технических) и/или физиологических артефактов. Нередко это создает значительные трудности при ее расшифровке и интерпретации [7]. В связи с этим было необходимо произвести удаление таких дефектов записи. Для отслеживания артефактов, связанных с движением глаз, у испытуемых осуществлялась запись электроокулограммы (ЭОГ). Удаление этих артефактов было произведено средствами программы «WinEEG»<sup>1</sup>. Области с амплитудой любого из каналов более 100 мкВ были исключены из анализа. Кроме этого, все участки записи ЭЭГ, в которых наблюдались медленные волны в диапазоне от 0.16 до 1 Гц, с амплитудой более 50 мкВ и быстрые колебания сигнала в интервале частот от 20 до 35 Гц, с амплитудой более 50 мкВ, считались артефактными и не рассматривались в анализе.

**Фильтрация сигналов.** Цифровые фильтры играют важную роль в анализе ЭЭГ. Функция фильтров состоит в подавлении частотной компоненты в сигнале и пропускании первоначального сигнала за исключением подавленных компонент. Фильтрация позволяет убрать лишнюю информацию из анализа и выделить интересующие вызванные потенциалы в определенной полосе частот. Сигналы ЭЭГ подвергались полосовой фильтрации в диапазоне частот 0,3–3 Гц. С целью увеличения соотношения сигнал/шум был применен пространственный фильтр Лапласа [8].

**Разделение сигнала на эпохи.** Для каждого нажатия клавиши в качестве положительных примеров брались предшествующие 1500 мс, за исключением тех, которые содержали артефакты. Аналогичные окна такой же длины были извлечены из сигналов, в которых не было ни одного нажатия, в качестве отрицательных примеров. Такие временные интервалы записи ЭЭГ принято называть эпохами, а вышепредставленные примеры положительными и негативными эпохами соответственно. Модели машинного обучения получали на вход отрезок эпохи до момента нажатия. Они должны были предсказать будет ли осуществлено движение сразу после этого отрезка, т.е. рассматривалась задача бинарной классификации.

**Извлечение признаков.** Выделение признаков является важным шагом в процессе классификации сигналов ЭЭГ. Извлеченные признаки предназначены для получения наиболее полезной информации, содержащейся в сигнале. Для соответствующих каналов были извлечены такие признаки, как максимальная амплитуда и площадь под кривой. Первая характеристика сигнала это максимальное и максимальное абсолютное значения сигналов (по 150 мс, предшествующим моменту нажатия). По умолчанию были взяты амплитуды по следующим каналам: «Cz», «C3-Cz», «C3-C4», последние два из которых были получены как разность значений каналов на интервале всей эпохи. Вторая характеристика сигнала, содержащая важную информацию, заключалась в получении значений площади под кривой на интервале по 1500 мс от значения, где было произведено нажатие. Отрезок был поделен на 3 интервала длиной 500 мс, на каждом из которых было получено значение полученного признака.

**Применение моделей машинного обучения.** Модель случайного леса (англ. Random Forest, RF), метода опорных векторов (англ. Support Vector Machine, SVM) и логистическая регрессия были обучены на извлеченных признаках для каждого испытуемого. Модель на каждого испытуемого была своя. Система выполняла 5-кратную перекрестную проверку, с помощью которой были определены лучшие параметры. Точность, специфичность и полнота/чувствительность были основными метриками для оценки эффективности. Точность показывает долю эпох, которые были правильно классифицированы относительно всех эпох. Нужно отметить, что для получения достоверного значения сбалансированной точности, пропорции классов были взвешены. Чувствительность же показывает долю правильно распознанных позитивных эпох относительно всех позитивных эпох, а специфичность – долю правильно распознанных негативных эпох относительно всех негативных эпох. Метод опорных векторов показал наиболее высокие значения интересующих метрик. По всем испытуемым были получены усредненные значения оценок: точность, чувствительность и специфичность составили по 71 % каждая. Подавляющее большинство представленных моделей продемонстрировали многообещающие значения пол-

<sup>1</sup> WinEEG v. 2.4, В. А. Пономарев, Институт мозга, РАН. Официальный сайт: <https://mitsar-eeg.ru>

ноты, превышающие случайное гадание, причем почти половина превысила 80 %. Качество зависит от каждого отдельного испытуемого. Точность колеблется от 60 % до 85 %, чувствительность от 57 % до 86 %, а специфичность от 53 % до 91 %. По тем сигналам, где количество эпох небольшое (в пределах от 10 до 20) судить о качестве проблематично, поскольку встает вопрос, на какой части данных происходит обучение, а какая часть используется для проверки, так как при разных разбиениях можно получать разные оценки. Разброс значений метрик немалый, ввиду того, что модель на каждого испытуемого была своя, т.е. у разных испытуемых в разной степени проявлялись рассматриваемые биомаркеры. Нужно отметить, что биомаркеры совершения движения очень чувствительны к параметрам движения, а их характеристики зависят от многих факторов, таких как уровень мотивации, готовность к выполнению заданного движения [9].

**Заключение.** В рамках данного исследования была предоставлена база данных записей ЭЭГ и поставлена задача классификации вызванных потенциалов при самоиницированных нажатиях испытуемых. Была проведена предварительная обработка данных, в которую входили удаление артефактов и фильтрация сигналов. Записи ЭЭГ были разделены на эпохи, по которым было проведено извлечение признаков. Кроме этого был рассмотрен набор классификаторов на основе обучения с учителем. В данной работе следовало классифицировать сигналы ЭЭГ для определения совершения нажатия в рассматриваемой эпохе. Точность, чувствительность и специфичность в среднем составили 71 %. Результат классификации может подаваться на вход регулятору, который будет вырабатывать управление. Например, управление роботизированного инвалидного кресла.

*Работа проводилась при поддержке гранта СПбГУ ID 84912397.*

#### ЛИТЕРАТУРА

1. **Kropotov Yu.D.** (2008). Quantitative EEG, EventRelated Potentials and Neurotherapy. Elsevier, Berlin.
2. **Пронина М.В., Кротов Ю.Д., Мурашов П.В.** Возможность тренировки амплитуды независимых компонент вызванных потенциалов методом биообратной связи. *Физиология человека*, 2011, том 37, № 3, с. 13–18.
3. **Plotnikov S.A., Lipkovich M., Semenov D.M., Fradkov A.L.** Artificial intelligence based neurofeedback. *Cybernetics and Physics* 8 (4), 287–291.
4. **Кирой В.Н., Владимирский Б.М., Асланян Е.В., Бахтин О.М., Миняева Н.Р.** Электрографические корреляты реальных и мысленных движений: спектральный анализ. *Журнал высшей нервной деятельности им. И.П. Павлова*. 2010. Т. 60, No 5. С. 517–525.
5. **Мокненко О.А., Бобров П.Д., Черникова Л.А., Фролов А.А.** (2013). Основанный на воображении движения интерфейс мозг–компьютер в реабилитации пациентов с гемипарезом. *Бюллетень сибирской медицины*, 12(2).
6. **Aliakbarhosseinabadi S., Jiang N., Vuckovic A., Dremstrup K., Farina D., Mrachacz-Kersting N.** Detection of movement intention from single-trial movement related cortical potentials using random and nonrandom paradigms. *Brain-Computer Interfaces*, vol. 2, no. 1, pages 29–39, 1992.
7. **Гуляев С.А., Архипенко И.В.** Артефакты при электроэнцефалографическом исследовании: выявление и дифференциальный диагноз. 2012, с. 3–16.
8. **Blankertz Benjamin et al.** The BCI Competition 2003: progress and perspectives in detection and discrimination of EEG single trials. *IEEE transactions on bio-medical engineering*, vol. 51,6 (2004): 1044–51. doi:10.1109/TBME.2004.826692
9. **McFarland D., McCane L., David S., Wolpaw J.** Spatial filter selection for EEG-based communication. *Electroencephalography and Clinical Neurophysiology*, vol.103, no. 3, pages 386–394, 1997.
10. **Lang W.** (2003). Surface recordings of the Bereitschaftspotential in normals. In *The Bereitschaftspotential* (pp. 19–34). Springer, Boston, MA.

N.L.Shanarova, M.M.Lipkovich, A.I.Voloshina, A.A.Aleksandrov, V.M.Knyazeva (Saint Petersburg State University, St. Petersburg)

#### **Classification of human electroencephalogram signals to determine the intention to move**

This paper is devoted to the results of a study on the classification of human electroencephalogram signals to determine the intention to make a movement. Signals were subjected to artifact removal and filtering, and then biomarkers responsible for self-initiated movements were extracted from them. Signal classification was performed using machine learning methods. The quality of the different models was compared, the best of which was demonstrated by a support vector machine. The classification results can be used to develop control algorithms based on neurofeedback.