

ОЦЕНКА РАЗДЕЛИМОСТИ ЭЭГ ДАННЫХ НА ПРЕДМЕТ ЗОНАЛЬНОЙ ПРИНАДЛЕЖНОСТИ ВОЛН ГОЛОВНОГО МОЗГА ПО ОТВЕДЕНИЯМ

Вольф Д.А., Исхакова А.О.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия
runsolar@mail.ru

Аннотация. Приведены результаты оценки репрезентативности биоэлектрических сигналов, полученных электроэнцефалографическим путем (ЭЭГ). Формируются устойчиво зрительно вызванные потенциалы у группы людей с последующим созданием прикладной базы данных. Описывается подход для извлечения репрезентативных признаков из ЭЭГ сигнала. С помощью технологии глубокого машинного обучения проводится оценка на репрезентативность исследуемых данных.

Ключевые слова: управление роботом, биоэлектрические сигналы, интерфейс «мозг-компьютер», человеко-машинное взаимодействие, ЭЭГ, отведения.

Введение

Разработки систем управления и взаимодействия между человеком и внешними устройствами посредством сигналов головного мозга – то есть разработки интерфейса «мозг-компьютер» (англ. - brain-computer interface, BCI) – особенно актуальны последние 15 лет. Можно выделить ряд наиболее известных и исследованных видов нейроинтерфейсов: окулографический интерфейс, использующий движение глаз оператора для считывания сигнала; миографический – считывающий биоэлектрические сигналы, возникающие в мышцах человека; дыхательный – основанный на считывании показателей дыхательной системы оператора, - и другие.

На данный момент существует ряд исследований, посвященных данной теме. Одно из исследований в 2020 году провели сотрудники Пусанского национального университета в Южной Корее. Целью их работы стало создание собственного нейрокомпьютерного интерфейса. Исследователи предложили упрощенную синхронизированную гибридную систему для множественного командного управления сигналами электроэнцефалографа в моторной коре головного мозга. Предлагаемая система может выдавать 38 команд управления, для которых пользователю требуется только сосредоточиться на стимуле и моргнуть глазами [1].

Ещё одно исследование провели сотрудники Национального технологического университета Цзинь-И на Тайване. В своей научной работе они обращают внимание на значение BCI для людей, страдающих заболеванием двигательных нейронов (MND), которые не способны самостоятельно передвигаться. В статье [2] в основном предлагался интерфейс «мозг-компьютер» на основе беспроводной электроэнцефалограммы и схема привода для двигателей постоянного тока для управления электрическими инвалидными колясками через интерфейс Bluetooth для парализованных пациентов.

Авторы работы [3] поставили целью своей работы обнаружение сигналов моргания глаз из сигналов ЭЭГ. Исследователи собрали данные, описали методы, используемые для предварительной обработки сигналов ЭЭГ, а также для классификации сигналов моргания глаз с использованием вероятностной нейронной сети в качестве двоичного классификатора. Конечной их целью стало применение полученной базы данных в приложении нейрореабилитации для пациентов с двигательными нарушениями.

Одним из амбициозных проектов по данному направлению является также проект Илона Маска Neuralink, результатом которого должна стать нейротехнология, которая способна соединить мозг человека с компьютером. На сегодняшний день Neuralink представляет собой миниатюрный чип диаметром порядка 23 мм и высотой 8 мм. Чип может иметь до 1024-х соединений с мозгом, гибкие нити для инвазивного подключения чипов к мозгу и эффективные алгоритмы обработки. [4].

Представленные примеры показывают только малую часть исследований и достижений в области разработки средств межмашинного взаимодействия, в частности нейроинтерфейсов. Достигнутые результаты значительны – разработано множество моделей и прототипов интерфейсов взаимодействия с применением органов чувств и биоэлектрических сигналов. При этом говорить о том, что человеческий мозг может быть действительно заменен, или смоделирован, или алгоритмизирован, пока слишком рано – процессы мышления в разрезе управления сторонними устройствами на сегодняшний день превосходят по многообразию и производительности существующие разработки. С этим связано большое число исследований, актуальность и популярность разработок и исследований, позволяющих человеку напрямую взаимодействовать с техникой, исключая какую-либо физическую

составляющую. В вышеперечисленных работах в слабой мере освещена тематика получения и подготовки статистической информации, а также их теоретическая оценка. При этом можно констатировать, что привлечение гибридных технологий, включая методы машинного обучения, для получения научных и инженерных результатов на сегодняшний день является актуальной мировой практикой.

Основная гипотеза данного исследования заключается в том, что в ходе последовательных циклов формирования устойчиво зрительно вызванных потенциалов (УЗВП) головной мозг воспроизводит уникальные волны, заключающиеся в изменении часто-временных характеристик регистрируемых сигналов, характерных для каждой зоны головы (отведения). Другими словами, с некой долей вероятности можно идентифицировать к какому отведению головного мозга принадлежит тот или иной ЭЭГ сигнал.

Таким образом, данное исследование направлено на получение информативных признаков из ЭЭГ сигналов с последующей их машинной классификацией [5]. Необходимо провести исследование на предмет подтверждения гипотезы о том, что волны, регистрируемые сенсорами электроэнцефалографа с головных отведений, подлежат группировке и могут быть применимы в задачах машинного обучения, и последующей машинной классификации в различных научных и инженерных задачах. И, как следствие, результаты данного исследования позволят продвинуться в исследованиях нового типа биометрической идентификации человека.

1. Сбор экспериментальных данных и получение репрезентативных признаков

Для исследования была создана база данных с ЭЭГ УЗВП, полученная в результате сеансов УЗВП от 30 испытуемых обоих полов в возрасте от 17 до 23 лет (12 девушек и 18 юношей), не имеющих неврологических и психиатрических патологий. Перед экспериментом участники не принимали психотропные препараты и имели нормальное или скорректированное до нормального зрение. Данные электроэнцефалограммы фиксировались прибором «Нейрон-спектр-4ВП» (ООО «Нейрософт», Россия) на отведениях $O1$, $O2$, Oz , $P3$, $P4$ и Pz с частотой дискретизации 5 000 Гц, включенным режекторным фильтром и отключенным фильтром высоких и низких частот. Фотостимуляция осуществлялась с частотами 1, 8 и 14 Гц. Длительность каждого сеанса УЗВП составляла 15 с.

На основе имеющегося входного набора данных определена динамика частотно-временных характеристик УЗВП. Когда сетчатка глаза возбуждается вспышками частотой от 3,5 до 75 Гц, мозг генерирует электрическую активность с частотой мигания вспышки [6–10].

После накопления данных, произведена фильтрация электроэнцефалограмм полосным фильтром Баттерворта 6-го порядка (order) с пропусканием 2 (lowcut) – 35 (highcut) Гц.

Далее, сигналы были сгруппированы по частотам фотостимуляции (1, 8 и 14 Гц) и группам отведений « $O1$ », « $O2$ », « Oz », « $P3$ », « $P4$ », « Pz » для каждого испытуемого. С учетом частоты дискретизации после группировки были получены три матрицы с данными: $N = 30 \times M = 75000 \times V = 6$ элементов (N — порядковый номер испытуемого; M — количество семплов в сигнале; V — количество сигналов в группе по каждому испытуемому (также пусть данная величина обозначает множество, состоящее из {« $O1$ », « $O2$ », « Oz », « $P3$ », « $P4$ », « Pz »}).

Если отобрать только первые и последние 25000 признаков, можно получить две матрицы, содержащие информацию о сигналах для первых и последних 5-и секунд.

Однако, при таком подходе подготовки данных, как для машинного обучения, так и для машинной классификации получается очень большой вектор информативных признаков – M , и очень маленький вектор с образцами по каждому сигналу (примерами) – N .

Как минимум, высокая размерность признаков сопряжена с очень высокими вычислительными затратами, при этом большое число обучаемых параметров может привести к получению сложной модели классификации, которая будет обладать высокой дисперсией, и не позволит качественно выявить искомые признаки.

Несложно заметить, что имеются достаточно большие наборы по M для множества V . Для снижения размерности V произведено ресемплирование каждого сигнала в группах до $M = 25\ 000$ с сохранением структуры данных.

Аугментация данных осуществлена за счет «разбивки» признака M на окна по 1260 отсчетов с шагом 625 отсчетов, что в сумме для каждого отведения дало по 1140 образца.

В результате выше проведенных работ были получены прикладные данные, которые представляют собой структурированные записи электрической активности головного мозга человека в результате проведенного эксперимента с УЗВП (рис. 1).

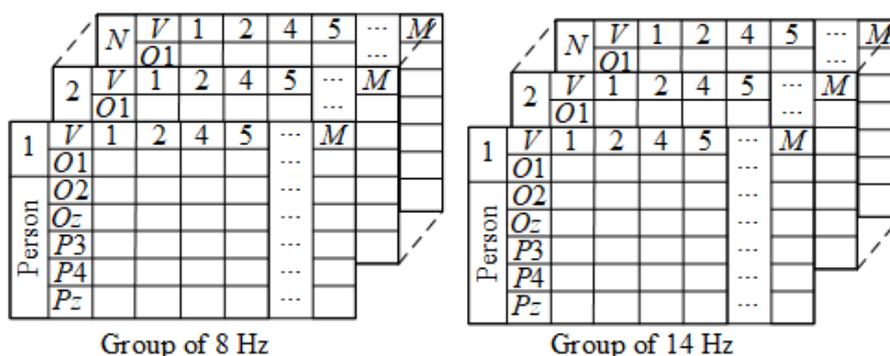


Рис. 1. Структура входных данных ЭЭГ с УЗВП по каждому испытуемому в частотных группах 8 и 14 Гц. Аналогично и для 1 Гц

В ряде работ [11-14] отмечаются индивидуальные психофизические и психоэмоциональные особенности каждого испытуемого. Это может свидетельствовать о том, что существует вероятность того, что признаки однозначно не сепарабельны по времени для всей группы испытуемых. Чтобы решить данную проблему, было применено глубокое машинное обучение для дальнейшей машинной классификации на основе классических методов [15].

Для интеграции элементов искусственной нейронной сети (ЭИНС) была разработана специализированная программы для ЭВМ [16]. С учетом полученной структуры данных был разработан специальный автокодировщик (АК) для кодирования ЭЭГ.

Автокодировщик (АК) электрической активности сигналов головного мозга человека – это разновидность искусственной нейронной сети, целью которой является восстановление входной информации (данных) на выходе. АК выполняет всего две задачи:

- сжатие входных данных в представление скрытого пространства (или латентного вектора), также известное как информационное узкое место;
- восстановление выходных данных на основе полученного представления. Сам по себе процесс автокодирования — это неконтролируемый алгоритм машинного обучения, так как алгоритм извлечения признаков определяется в результате глубокого машинного обучения.

Применение АК активно популяризируется в задачах реконструкции изображений и их базовой раскраски, сжатия данных, преобразования изображений в оттенках серого в цветные изображения, создания изображений с более высоким разрешением и т. д. Однако проблема заключается в том, что различные модели АК работают только с данными, которые аналогичны тем, на которых они были обучены – прикладные данные.

Итоговая реализация модели, полученного АК – «кодер-декодер» представляет собой симметричный многослойный мульти-адаптивный нейрон прямого распространения [17–19]. Кодировщик позволяет отобразить признаки размерностью – 1260 элементов в признаки размерностью 24 элемента. Однако данная размерность была получена не сразу. Релевантность полученных признаков также оценивалась с помощью глубокой нейронной сети в части декодера, который позволяет реконструировать исходный сигнал. Итоговая сеть АК состоит из 9-ти слоев, из которых 7 слоев с персептронами скрытые (hidden1 – hidden7). Слои сокращаются к 4-му скрытому слою (5-й слой для всей сети) и также увеличиваются в направлении выходного слоя, образуя симметричную архитектуру нейронной сети. Обучение АК воспроизводилось до тех пор, пока АК не получался неполным. По результатам каждого цикла глубокого обучения оценивалось представление скрытого пространства изучением информативных признаков в сторону уменьшения размеров 5-го выходного слоя.

2. Оценка разделимости ЭЭГ данных

Проверка разделимости данных электроэнцефалограммы производилась путем попытки классифицировать полученный массив данных и дальнейшего анализа полученного разделения. Для машинной классификации был применён алгоритм k -ближайших соседей. Для тестов использовалось 873 образца, не участвующих в процессе обучения (кросс-валидация – 20% от обучающей выборки). Результаты машинной классификации в виде показателей эффективности произведенных расчетов для тестовой выборки приведены в табл. 1.

Таблица 1. Результаты машинной классификации кодированных ЭЭГ с УЗВП методом *k*-средних соседей

Отведения	precision	recall	f1-score	support
Частота стимуляции — 8 Гц (accuracy 88%)				
O1	0.88	0.97	0.92	873
O2	0.90	0.57	0.70	873
Oz	0.92	0.84	0.88	873
P3	0.75	0.94	0.83	873
P4	0.98	0.99	0.99	873
Pz	0.91	0.97	0.94	873
Частота стимуляции — 14 Гц (accuracy 80%)				
O1	0.82	0.85	0.84	873
O2	0.72	0.68	0.70	873
Oz	0.82	0.82	0.82	873
P3	0.80	0.86	0.83	873
P4	0.97	0.92	0.94	873
Pz	0.68	0.67	0.67	873

В табл. 1 содержатся оценки способности классификатора отличать кодированные сигналы ЭЭГ друг от друга (отличать зональные отведения). Количественно на это указывает оценка – precision. Оценка recall демонстрирует качество алгоритма классификации обнаруживать серии соответствующих кодированных ЭЭГ с УЗВП. Характеристика f1-score подтверждает необходимый среднегармонический баланс между оценками precision и recall, Параметр support указывает на количество тестовых образцов.

На рис. 2 показаны границы и кластеры внутри них, которые соответствуют шести отведениям: O1, O2, Oz, P3, P4 и Pz. Также можно заметить, что скрытое пространство содержит «пробелы» — это эквивалентно отсутствию данных в задаче обучения с учителем, поскольку АК не был обучен этим особенностям скрытого пространства. Другой проблемой является разделимость пробелов, некоторые отведения хорошо разделены, но есть также области, где имеются «вкрапления» одних признаков в другие, что затрудняет разделение уникальных особенностей данных отведений. Тем не менее, можно сделать вывод, что полученные признаки обладают достаточно хорошей разделимостью, а, следовательно, могут быть применены в дальнейшем машинном обучении для задач классификации ЭЭГ сигналов.

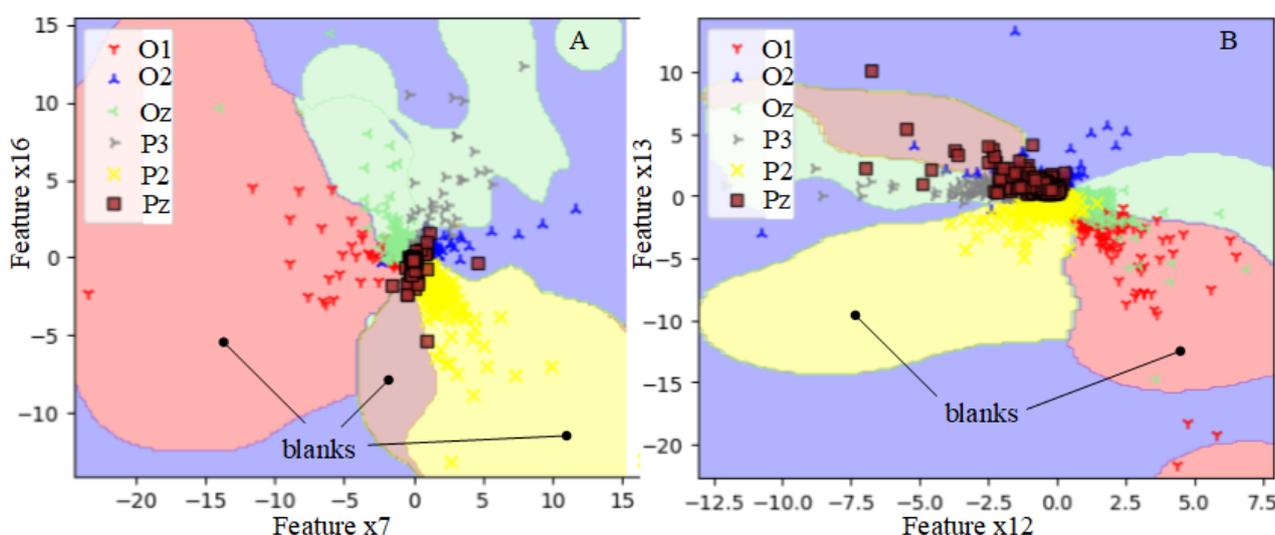


Рис. 2. Границы решений по отведениям O1, O2, Oz, P3, P4 и Pz, полученные на основе исследуемых признаков: А) для значимых признаков x7 и x16 (стимуляция 8 Hz); В) для значимых признаков x12 и x13 (стимуляция 14 Hz)

Опираясь на результаты проведенной работы, можно заключить, что каждое отведение головного мозга воспроизводит уникальные волны, характерные для каждой зоны головы. Результаты экспериментального исследования показывают, что имеет место быть некоторая обобщенность

сигналов по их отведениям в части выборок из генеральной совокупности статистических данных от испытуемых.

3. Заключение

Для подтверждения основной гипотезы осуществлен сбор статистической информации. Получение статистических данных достигалось путем создания технических условий и организационных мероприятий для проведения научного эксперимента с группой из 30 испытуемых обоих полов. Эксперимент обеспечен специализированным измерительным оборудованием медицинского назначения типа электроэнцефалограф высокого разрешения.

Достижимость поставленной задачи получение предполагаемых результатов с точностью 85%, основывалось на предварительной оценке релевантности и репрезентативности полученных данных в результате эксперимента по сбору биоэлектрической активности мозга. Где в качестве наборов первичных признаков взята частотно-временная характеристика. Таким образом, перед тем как приступить к глубокому машинному обучению и задаче машинной классификации, проведена оценка на репрезентативность экспериментальных данных.

Предлагаемая в статье модель симметричного многослойного мульти-адаптивного нейрона прямого распространения, обеспечивающего функции кодера и декодера, может найти свое применение при решении задач связанных с обработкой ЭЭГ сигналов.

Исходя из результатов данного исследования, авторами, данные о биоэлектрической активности головного мозга, записанные электроэнцефалографическим способом (ЭЭГ) можно представить в виде многомерной случайной величины, где положение центра также является математическим ожиданием ее проекций на оси главных компонент.

Литература

1. *Yang D., Nguyen T.H., Chung W.Y.* A Bipolar-Channel Hybrid Brain-Computer Interface System for Home Automation Control Utilizing Steady-State Visually Evoked Potential and Eye-Blink Signals // *Sensors* (Basel). 2020. N 20(19). – 5474.
2. *Lin J.-S., Yang W.-C.* Wireless brain-computer interface for electric wheelchairs with EEG and eye-blinking signals // *Int J Innov Comput Inf Control*. 2012. N 8. – 6011-6024.
3. *Rihana S., Damien P., Moujaess T.* EEG-Eye Blink Detection System for Brain Computer Interface // *Pons, J., Torricelli, D., Pajaro, M.* (eds) *Converging Clinical and Engineering Research on Neurorehabilitation*. Biosystems & Biorobotics, vol 1. – Springer, Berlin, Heidelberg, 2013.
4. *Musk E.* An integrated brain-machine interface platform with thousands of channels // *BioRxiv preprint* [Электронный ресурс]. – URL: <https://www.biorxiv.org/content/10.1101/703801v4> (дата обращения 31.05.2023).
5. *Turovsky Y., Wolf D., Meshcheryakov R., Iskhakova A.* Dynamics of Frequency Characteristics of Visually Evoked Potentials of Electroencephalography During the Work with Brain-Computer Interfaces // *Prasanna, S.R.M., Karpov, A., Samudravijaya, K., Agrawal, S.S.* (eds) *Speech and Computer*. SPECOM 2022. *Lecture Notes in Computer Science*, vol 13721. – Springer, Cham, 2022.
6. *Tao T., Yi X., Xiaorong G., Shangkai G.* Chirp-modulated visual evoked potential as a generalization of steady state visual evoked potential // *Journal of neural engineering*. 2011. N 9(1). – 016008.
7. *Kwak N.-S., Müller K.-R., Lee S.-W.* Toward exoskeleton control based on steady state visual evoked potentials // *2014 International Winter Workshop on Brain-Computer Interface, BCI 2014*. – Gangwon, Korea, 2014. – P. 1-2.
8. *Balnytė R., Uloziene I., Rastenytė D., Vaitkus A., Malcienė L., Laučkaitė K.* Diagnostic Value of Conventional Visual Evoked Potentials Applied to Patients With Multiple Sclerosis // *Medicina*. 2011. N 47(5). – P. 263-269.
9. *Markand O.* *Visual Evoked Potentials*. – Springer Cham (2020). – 242 p.
10. *Chaudhary U., Birbaumer N., Curado M.R.* Brain-Machine Interface (BMI) in paralysis // *Annals of Physical and Rehabilitation Medicine*. 2015. N 58(1). – P. 9-13.
11. *Aminoff M., Goodin D.* *Visual Evoked Potentials* // *Journal of clinical neurophysiology : official publication of the American Electroencephalographic Society*. 1994. N 11. – P. 493-499.
12. *Taylor M., McCulloch D.* *Visual Evoked Potentials in Infants and Children* // *Journal of clinical neurophysiology: official publication of the American Electroencephalographic Society*. – 1992. N 9. – P. 357-72.
13. *Liasis A.* *Visual evoked potentials* // *Acta Ophthalmologica*. – 2016. N 94.
14. *Carter J.* *Visual Evoked Potentials* // *Clinical Neurophysiology*. – Oxford University Press, 2011. – P. 311-322.
15. *Kwak N.-S., Müller K.-R., Lee S.-W.* A convolutional neural network for steady state visual evoked potential classification under ambulatory environment // *PLoS ONE*. 2017. N 12(2). – P. 1-20.
16. *Вольф Д.А., Туровский Я.А., Мецерыков Р.В., Исхаков А.Ю., Исхакова А.О.* Автокодировщик ЭЭГ-сигнала // Государственная регистрация программы для ЭВМ. Номер регистрации (свидетельства): 2023611934. Дата регистрации: 26.01.2023. [Электронный ресурс]. – URL: https://new.fips.ru/registers-doc-view/fips_servlet?DB=EVM&DocNumber=2023611934&TypeFile=html (дата обращения 31.05.2023).

17. *Nguyen H., Bottone S., Kim K., Chiang M., Poor H.V.* Adversarial Neural Networks for Error Correcting Codes (preprint). [Электронный ресурс]. – URL: https://www.researchgate.net/publication/357267696_Adversarial_Neural_Networks_for_Error_Correcting_Codes (дата обращения 31.05.2023).
18. *Köse U., Deperlioglu O., Alzubi J., Patrut B.* Diagnosing Parkinson by Using Deep Autoencoder Neural Network // Deep Learning for Medical Decision Support Systems. 2021. – P. 73-93.
19. *Mirjalili V., Raschka S., Nambodiri A., Ross A.* Semi-adversarial Networks: Convolutional Autoencoders for Imparting Privacy to Face Images // Conference: 2018 International Conference on Biometrics (ICB). – IEEE, Gold Coast, QLD, Australia, 2018. – P. 82-89.