

*П. Ю. Нарвойш**

студент

*А. И. Парамонов**

кандидат технических наук, доцент

*Белорусский государственный университет информатики и радиоэлектроники, Минск, Республика Беларусь

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ПРИ ИССЛЕДОВАНИИ ДЕЯТЕЛЬНОСТИ ГОЛОВНОГО МОЗГА МЕТОДОМ ЭЭГ

Рассматриваются возможные подходы к анализу ЭЭГ-данных с использованием алгоритмов машинного обучения. Приведено описание исходных данных. Представлены архитектуры моделей для анализа сигналов ЭЭГ и спектrogramм. Изучена возможность применения трансферного обучения для оптимизации ресурсов, а также описан комплексный подход к анализу ЭЭГ данных на основе ансамблирования моделей.

Ключевые слова: диагностика, электроэнцефалография, машинное обучение, спектrogramма, трансферное обучение.

*P. Yu. Narvoish**

Student

*A. I. Paramonov**

PhD, Tech., Associate Professor

*Belarusian State University of Informatics and Radioelectronics, Minsk, Republic of Belarus

APPLICATION OF MACHINE LEARNING METHODS IN THE BRAIN ACTIVITY STUDY BY USING EEG

The paper describes possible approaches to EEG data analysis using Machine Learning algorithms. Description of the initial data is provided. Model architectures for analyzing EEG signals and spectrograms are presented. The possibility of using transfer learning to optimize resources is considered, and a comprehensive approach to EEG data analysis based on model ensemble is described.

Keywords: diagnostics, electroencephalography, machine learning, spectrogram, transfer learning.

Введение

ЭЭГ (электроэнцефалография) – неинвазивный метод исследования функционального состояния головного мозга путем регистрации его биоэлектрической активности. ЭЭГ отражает биологический процесс, который обусловлен деятельностью множества электрических генераторов – нейронов. Создаваемое этими генераторами поле неоднородно по пространству головного мозга и изменчиво в каждый момент времени. Поэтому между двумя точками, расположенными в пределах мозга, между точками головного мозга и удаленной от него тканью организма появляются переменные разности потенциалов, которые можно зарегистрировать. Регистрация возникающих в головном мозге биологических потенциалов и является основной задачей ЭЭГ [1]. Для ранней диагностики различных заболеваний важно не только получать и регистрировать сигналы мозга, но и извлекать информацию, содержащуюся в ЭЭГ. Один из этапов компьютерной обработки сигнала – классификация, т. е. отнесение его к определенной группе на основе анализа его характеристик. Анализировать сигналы ЭЭГ можно как математическими методами, так и с использованием нейронных сетей и машинного обучения.

Применение методов машинного обучения при исследовании деятельности головного мозга методом ЭЭГ предполагает выполнение нескольких этапов: определение и четкая формулировка решаемой проблемы, подготовка наборов данных для обучения, при необходимости предобработка данных, выбор и обучение модели, проверка качества моделей путем анализа полученных показателей. В большинстве случаев задачей модели машинного обучения на основе ЭЭГ-данных является классификация, т. е. отнесение объекта к одной из категорий на основании его признаков. Данные для обучения должны соответствовать решаемой проблеме. В открытом доступе находится множество наборов данных (датасетов) для обучения моделей, направленных на распознавание движений, эмоций, реакций на внешние события, функциональных расстройств мозга и другие наборы описания деятельности головного мозга.

Применение методов машинного обучения в подходах к анализу ЭЭГ-данных

В качестве эксперимента рассматривались датасеты с заранее размеченными группой экспертов ЭЭГ-данными [2], которые содержат паттерны опасной мозговой активности: судороги (SZ), генерализованные периодические разряды (GPD), латерализованные периодические разряды (LPD), латерализованная ритмическая

дельта-активность (LRDA), генерализованная ритмическая дельта-активность (GRDA) и «иное». В работе исследуются возможности применения трех самых распространенных на сегодня подходов для анализа ЭЭГ данных с использованием методов машинного обучения.

Первый подход основан на преобразовании сигналов ЭЭГ в изображения спектрограмм и последующем обучении модели классификации паттернов на наборе изображений при помощи сверточных нейронных сетей. Спектральный состав позволяет количественно оценить соотношение активности различных диапазонов частот. Одной из причин широкого применения спектрального метода анализа является то, что спектральные характеристики ЭЭГ поддаются математической и статистической обработке и потенциально могут дать эффективные методы анализа ЭЭГ, которые невозможно получить при традиционных методиках. Пример спектрограммы ЭЭГ и изображения ее сигнала представлены на рис. 1.

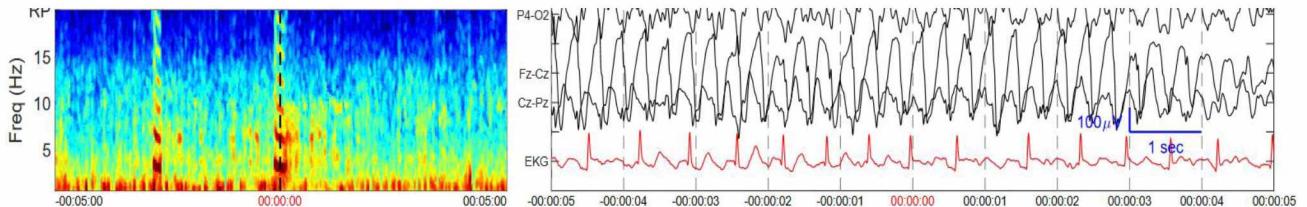


Рис. 1. Спектрограмма ЭЭГ (слева) и электроэнцефалограмма (справа)

В основе анализа изображений спектрограмм лежат 2D-сверточные нейронные сети [3]. Обучение сверточной нейронной сети для классификации изображений с нуля требует больших вычислительных мощностей. Поэтому принято решение выполнить трансферное обучение – метод, позволяющий сократить большую часть вычислений, используя часть модели, которая уже была обучена для выполнения связанной задачи, и повторно применяя ее в новой модели. Для этого можно зафиксировать те веса, которые получены в результате обучения модели на большом наборе разнообразных изображений, что позволит модели сохранить все результаты обучения. Далее, опционально, удаляются последние слои модели, так как в большинстве случаев они отвечают за решение конкретных прикладных задач. Затем в модель внедряются новые слои, которые помогут модели адаптироваться к специализированному характеру новой задачи. Пример архитектуры сети с использованием трансферного обучения представлен на рис. 2. Трансферное обучение дает возможность использовать меньший объем исходных данных, так как предварительно обученная модель сохраняет основные знания о задачах, особенностях, весах и функциях, что позволяет ей лучше и быстрее адаптироваться к новым задачам. Кроме того, такой подход позволяет задействовать гораздо меньше ресурсов, вычислительных мощностей и времени.

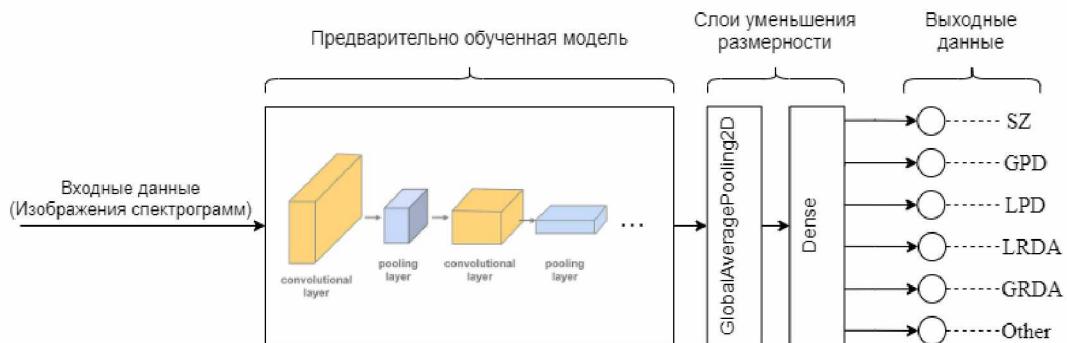


Рис. 2. Сверточная нейронная сеть с предварительно обученной моделью

Наряду с обучением моделей на основе изображений спектрограмм, широко применяется подход на основе анализа сигналов ЭЭГ, которые представляют собой временные данные. Для подобных задач применимы 1D-сверточные нейронные сети [3]. В исходном датасете одна запись сигнала ЭЭГ описывает промежуток времени, на протяжении которого собирались значения с 20 каналов (19 каналов – электроды, расположенные по международной системе «10-20», 1 канал – ЭКГ). Для построения 1D-сверточной нейронной сети можно использовать архитектуру по типу ResNet (Residual Neural Network) [4]. В ResNet сети благодаря соединениям быстрого доступа данные передаются не только последовательно из слоя в слой, но и с пропуском некоторого количества слоев, что и позволяет увеличивать количество слоев в сети. Пример фрагмента такой 1D-сверточной нейронной сети представлен на рис. 3 [5].

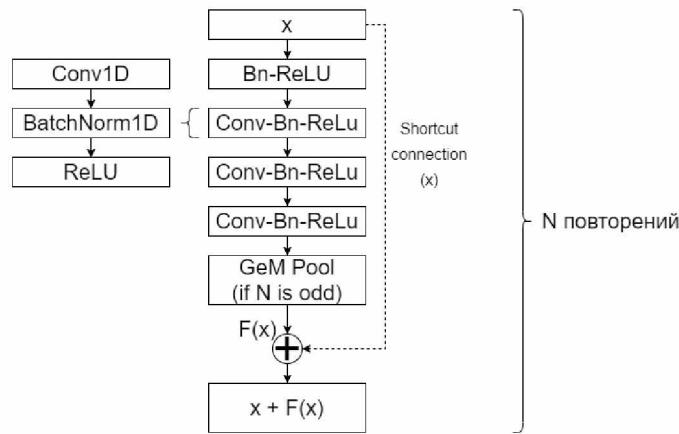


Рис. 3. Фрагмент 1D-сверточной нейронной сети

В последнее время все большую популярность при создании моделей получают комплексные подходы, которые объединяют нескольких успешных моделей в одну большую – ансамблирование моделей. Основная идея заключается в том, что несколько моделей обучаются отдельно, а далее их предсказания усредняются с помощью арбитра. В нашем случае 2D-сверточные нейронные сети обучаются на спектрограммах ЭЭГ, 1D-сверточные нейронные сети – на сигналах ЭЭГ. Ансамбль из них позволит создать модель, которая будет учитывать различные типы исходных данных. Арбитры, итоговым решением которых будет среднее арифметическое решений всех моделей ансамбля, показывают не лучшие результаты. Такой ансамбль придает одинаковое значение всем моделям, что не всегда эффективно, поэтому более подходящим методом является взвешенное принятие решений. Каждому алгоритму назначается свой вес, с которым его ответ будет входить в итоговую сумму, при этом сами веса нормируются на единицу.

Заключение

Компьютерные эксперименты позволяют предположить, что развитие методов обработки и анализа сигналов ЭЭГ с использованием искусственного интеллекта и машинного обучения открывает новые возможности для автоматизированной диагностики и прогнозирования состояния мозга. Подобные методы позволяют ускорить процесс анализа и снизить нагрузку на специалистов в данной сфере. Кроме того, применение автоматизированного анализа уменьшает вероятность человеческой ошибки. Таким образом, использование методов машинного обучения для анализа ЭЭГ данных представляет собой перспективное направление, которое позволит улучшить качество диагностики различных состояний головного мозга.

Библиографический список

1. Регистрация ЭЭГ// CMI.to. URL: <https://cmi.to/регистрация-ээг/> (дата обращения: 19.08.2024).
2. HMS – Harmful Brain Activity Classification / Jin Jing, Zhen Lin, Chaoqi Yang [et al.]. Kaggle. 2024. URL: <https://kaggle.com/competitions/hms-harmful-brain-activity-classification> (дата обращения: 19.08.2024).
3. Understanding 1D, 2D and 3D Convolution Network // Kaggle. URL: <https://www.kaggle.com/code/mersico/understanding-1d-2d-and-3d-convolution-network> (дата обращения: 19.08.2024).
4. Deep Residual Learning for Image Recognition / K. He, X. Zhang, S. Ren, J. Sun. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA, 2016. P. 770–778.
5. GWNET: Detecting Gravitational Waves using Hierarchical and Residual Learning based 1D CNNs / N. Dhankhar, T. Singh, A. Buragohain, R. Tiwari. 2022.