

# Моделирование когнитивных процессов распознавания эмоций

А.Е. Телепнев

Новосибирский государственный технический университет  
Новосибирск, Россия  
telepnev@corp.nstu.ru

Т.В. Авдеевко

Новосибирский государственный технический университет  
Новосибирск, Россия  
tavdeenko@mail.ru

**Аннотация**—В данной работе предложен подход к проектированию и разработке модели восприятия человека методами машинного обучения. Для создания модели используется набор данных электроэнцефалографии (ЭЭГ) SEED-V. Рассматриваются методы предобработки сигналов ЭЭГ, способы извлечения признаков, генеративные сети Вассерштейна и рекуррентные нейронные сети.

**Ключевые слова**—нейронные сети, генеративные сети Вассерштейна, ЭЭГ, рекуррентные сети, SEED-V, классификация эмоций.

## 1. ВВЕДЕНИЕ

Основная цель применения методов машинного обучения состоит в том, чтобы позволить компьютерам учиться без вмешательства человека, корректируя свои действия для достижения достоверного результата при решении задач. Известны ограничения при их применении: малая точность/скорость работы, узкоспециализируемость, нехватка данных для обучения. Основные области применения методов сводятся к быстрой обработке потока данных, классификации, кластеризации и прогнозированию. При этом, ощущается недостаток в исследовании функций мозга [1].

Эмоциональное состояние человека влияет на аспекты его жизнедеятельности: работу внутренних органов и двигательную активность, процессы мышления, памяти и восприятия. Применение машинного обучения в области распознавания эмоций позволяет моделировать когнитивные процессы, составлять модели обучения, разрабатывать интерфейсы мозг-компьютер, изучать мозговую активность и ассоциативную память. В данной работе предложен подход к разработке модели восприятия человека методами машинного обучения.

## 2. ИНСТРУМЕНТЫ И МЕТОДЫ

Существует множество методов распознавания эмоций человека [2]. Все методы базируются на модели классификации. Согласно этой модели, всего существует 66 эмоций, которые, в свою очередь, разбиваются на две группы: десять базовых эмоций (ожидание, недоверие, гнев, страх, радость, счастье, любовь, доверие, печаль, удивление) и 56 вторичных эмоций. Так как трудно различить такое огромное число эмоциональных состояний, большинство исследователей фокусируются на классификации базовых эмоций, валентности (активация—отрицательная / положительная) и возбуждения (высокая / низкая). Задачу автоматического разделения на классы решают при помощи анализа параметров человеческого тела, электрических импульсов и их изменения. Такими параметрами могут быть сопротивление кожи, кровяное давление, частота сердечных сокращений, активность глаз и, используемые в данной работе, данные ЭЭГ. Электроэнцефалограмма определяет электрическую активность в мозге с

помощью электродов, прикрепленных к коже головы. ЭЭГ представляет собой график, на котором отображены усиленные электрические сигналы мозга.

Используемый набор данных SEED-V [4] представляет собой данные ЭЭГ с пятью категориями эмоций: радость, грусть, страх, отвращение и нейтральность. Данные были собраны с 20 субъектов – 10 женщин и 10 мужчин, эмоции которых стимулировались видеофрагментами. После стимулирования эмоций, испытуемые проводили самооценку.

Зачастую, собранных данных для качественного обучения классификаторов недостаточно. Для решения данной проблемы, в работе рассматривается применение генеративной сети Вассерштейна. Идея генеративных сетей [5] заключается в использовании двух основных распределений вероятностей – распределение вероятностей генератора, которое относится к распределению на выходе модели генератора и распределение вероятностей по реальным изображениям. Цель генеративных сетей состоит в том, чтобы гарантировать, что оба этих распределения вероятностей близки друг к другу, чтобы генерируемый результат был очень реалистичным и высококачественным. Для вычисления расстояния между этими распределениями вероятностей математическая статистика в машинном обучении предлагает три основных метода, а именно дивергенцию Кульбака–Лейблера, дивергенцию Джессена–Шеннона и расстояние Вассерштейна [7]. Генеративная состязательная сеть Вассерштейна улучшает стабильность при обучении модели и обеспечивает функцию потерь, которая коррелирует с качеством генерируемых данных.

## 3. ПОСТРОЕНИЕ МОДЕЛИ

Для реализации цели научного исследования потребуется решить следующие задачи:

1. Определение формата входных и выходных данных.
2. Определение способа чтения и предобработки.
3. Исследование для изучения наилучшей архитектуры нейронной сети для генерации данных.
4. Исследование для изучения наилучшей архитектуры нейронной сети для классификации эмоций.
5. Реализация механизма оценки.
6. Проектирование и реализация структуры хранения нейронной сети.

Опираясь на поставленные задачи, данная система должна содержать следующие компоненты:

1. Модуль чтения данных.
2. Модуль предобработки.
3. Модуль генерации новых данных.
4. Модуль классификации эмоций.

На Рис. 1 представлена схема выгрузки и предобработки ЭЭГ сигналов. Данные ЭЭГ имеют

формат cnt [8] и работа с этим форматом осуществлялась при помощи Python библиотеки Mne [9]. Из сигнала ЭЭГ сигнала были исключены каналы с неинформативными данными, частота дискретизации была понижена до 200 Гц. Применяется фильтр низких и высоких частот. Физические движения при снятии ЭЭГ сигнала образуют артефакты, для исключения которых был применен метод preprocessing [10] библиотеки Mne. Поврежденные данные ЭЭГ необходимо реконструировать, то есть провести интерполяцию данных – заполнить недостающие данные на основе доступных данных. Есть множество способов интерполировать данные, но наиболее распространенным является применение сплайнов. Сплайн – это функция, график которой разбиваем на конечное число отрезков в соответствии с алгебраическим уравнением некоторой функции. Так как стимуляция происходит в определенных временных диапазонах, мы можем отбросить не интересующие нас данные до стимулов. Производится сегментация по определенным временным диапазонам. Далее производится извлечение признаков. В случае работы с ЭЭГ сигналом, существует множество способов извлечения признаков, наиболее используемые: квантили; стандартное отклонение; частотные характеристики; быстрое преобразование Фурье; оконное преобразование Фурье; вейвлеты; метод шейплетов; разделение по ритмам и их отдельный анализ.



Рис. 1. Выгрузка и предобработка сигнала ЭЭГ

Генерацию новых данных можно представить в виде схемы на Рис. 2. Процесс генерации новых данных происходит за счет попытки обмана критика сгенерированными данными. Критик предсказывает, с какой вероятностью данные, поданные на вход критика, являются реальными, а не сгенерированными. Если нас удовлетворяет качество сгенерированных данных, мы сохраняем их для дальнейшего использования.



Рис. 2. Выгрузка и предобработка сигнала ЭЭГ

В отличие от нейронных сетей с прямой связью, рекуррентные нейронные сети используют свою внутреннюю память состояний для обработки последовательностей. Такое динамическое поведение рекуррентных нейронных сетей делает их очень полезными и применимыми к анализу звука,

распознаванию рукописного текста и распознаванию эмоций по данным ЭЭГ [11]. Процесс классификации эмоций можно представить в виде схемы на Рис. 3.

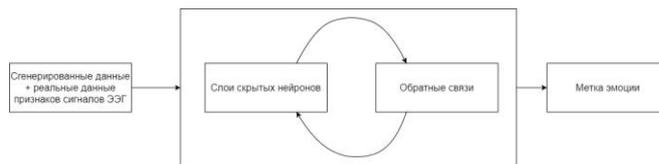


Рис. 3. Выгрузка и предобработка сигнала ЭЭГ

## ЗАКЛЮЧЕНИЕ

В рамках данной работы были проанализированы исследования, посвященные методам классификации и обработки сигналов ЭЭГ. Предложен оригинальный метод алгоритмической обработки и генерации физиологических данных для реализации модели восприятия.

## БЛАГОДАРНОСТИ

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации (проект № FSUN-2020-0009).

## ЛИТЕРАТУРА

- [1] Huimin, L. Brain Intelligence: Go beyond Artificial Intelligence / L. Huimin., L. Yujie, C. Min, K. Hyoungseop, S. Seiichi // Mobile Networks and Application. – 2018. – Vol. 23. – P. 368-375.
- [2] Dzedzickis, A. Human Emotion Recognition: Review of Sensors and Methods / A. Dzedzickis, A. Kaklauskas, V. Bucinskas // Sensors (Basel). – 2020. – Vol. 20(3). – P. 592.
- [3] Ting-Mei, L. Emotion classification based on brain wave: a survey / L. Ting-Mei, C. Han-Chieh, Z. Jianming // Human-centric Computing and Information. – 2019. – Vol. 9. – P. 42.
- [4] Wei, L. Comparing Recognition Performance and Robustness of Multimodal Deep Learning Models for Multimodal Emotion Recognition / L. Wei, Q. Jie-Lin, Z. Wei-Long, L. Bao-Liang // IEEE Transactions on Cognitive and Developmental Systems. – 2021. – Vol. 14(2). – P. 715-721.
- [5] Goodfellow, I. Generative adversarial nets / I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio // Advances in neural information processing systems. – 2014. – Vol. 27.
- [6] Arjovsky, M. Wasserstein generative adversarial networks / M. Arjovsky, S. Chintala, L. Bottou / ICML'17: Proceedings of the 34th International Conference on Machine Learning. – 2021. – Vol. 70. – P. 214-223.
- [7] Deshpande, I. Generative Modeling using the Sliced Wasserstein Distance / I. Deshpande, Z. Zhang, A. Schwing // CVPR 2018. – 2018.
- [8] mne.io.read\_raw\_cnt [Electronic resource]. – Access mode: [https://mne.tools/1.1/generated/mne.io.read\\_raw\\_cnt.html](https://mne.tools/1.1/generated/mne.io.read_raw_cnt.html) (25.09.2022).
- [9] MNE MEG+EEG analysis&visualization [Electronic resource]. – Access mode: <https://mne.tools/1.1/index.html> (23.09.2022).
- [10] Preprocessing [Electronic resource]. – Access mode: <https://mne.tools/dev/preprocessing.html> (27.09.2022).
- [11] Sherstinsky, A. Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network / A. Sherstinsky // Physica D: Nonlinear Phenomena. – 2020. – Vol. 404.