

ИСПОЛЬЗОВАНИЕ МАТРИЦ GRAMIAN ANGULAR FIELD ДЛЯ ПРЕОБРАЗОВАНИЯ ЭЛЕКТРОЭНЦЕФАЛОГРАММ В ЗАДАЧАХ КЛАССИФИКАЦИИ МОТОРНЫХ ОБРАЗОВ

Гоморов А.Л.

Томский политехнический университет, ИШИТР, аспирант, e-mail: alg5@tpu.ru

Введение

В настоящее время задачи классификации моторных образов являются актуальным направлением исследований благодаря их повсеместному использованию в интерфейсах мозг-компьютер.

Последние исследования в данной области проявляют большой интерес к методам преобразования электроэнцефалограмм в графические данные, что может способствовать увеличению точности их распознавания.

Целью данной работы является разработка модели классификации моторных образов на основе инструментов глубокого обучения и графического преобразования Gramian Angular Field.

Описание преобразования Gramian Angular Field

Впервые использование преобразования Gramian Angular Field (GAF) для последующего использования в задачах классификации было предложено в работе [1]. При использовании данного преобразования временные ряды представляются в полярной системе координат, после чего создаётся матрица Грамиана, каждый элемент которой является косинусом суммы углов векторов. Полученная матрица в результате преобразуется в двумерное изображение.

Первоначально значения временного ряда $X = \{x_1, x_2, \dots, x_n\}$ нормализуются в интервале $[-1; 1]$, используя следующую формулу:

$$\hat{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

Затем нормализованные значения ряда преобразуются в полярную систему координат по следующим формулам:

$$\begin{cases} \varphi_i = \arccos(\hat{x}_i) \\ r_i = \frac{t_i}{N} \end{cases} \quad (2)$$

где t_i – это индекс текущего элемента ряда, а N – коэффициент для регуляризации диапазона полярной системы координат.

Теперь мы можем построить GAF матрицы, тригонометрическую сумму (разницу) между каждой точкой для определения временной корреляции в различных временных интервалах. Полученные матрицы можно интерпретировать как двоичное изображение в градациях серого.

$$GASF = \begin{bmatrix} \cos(\varphi_1 + \varphi_1) & \dots & \cos(\varphi_1 + \varphi_n) \\ \cos(\varphi_2 + \varphi_1) & \dots & \cos(\varphi_2 + \varphi_n) \\ \vdots & \ddots & \vdots \\ \cos(\varphi_n + \varphi_1) & \dots & \cos(\varphi_n + \varphi_n) \end{bmatrix} \quad GADF = \begin{bmatrix} \sin(\varphi_1 - \varphi_1) & \dots & \sin(\varphi_1 - \varphi_n) \\ \sin(\varphi_2 - \varphi_1) & \dots & \sin(\varphi_2 - \varphi_n) \\ \vdots & \ddots & \vdots \\ \sin(\varphi_n - \varphi_1) & \dots & \sin(\varphi_n - \varphi_n) \end{bmatrix} \quad (3)$$

Описание датасета

В данной работе использовалась база данных MI-EEG Physionet, которая была записана разработчиками системы BCI2000 [2]. Данные MI-EEG Physionet получены с 64-х электродов в соответствии с международной системой разметки электродов 10-10 (исключая электроды NZ, F9, F10, FT9, FT10, A1, A2, TP9, TP10, P9 и P10). MI-EEG Physionet содержит более 1500 одноминутных и двухминутных записей ЭЭГ от 109 различных субъектов с частотой дискретизации 160 Гц.

Каждый испытуемый выполнял четыре задания MI: сжатие и разжатие левого кулака, правого кулака, обеих кулаков и ступней. Для каждого задания MI было выполнено 21 испытание. Время начала испытания $t = -2$ с, испытуемый расслабляется в течение 2 с. При $t = 0$ с на экране появляется цель соответствующего моторного образа. Испытуемому давали команду на выполнение соответствующей задачи MI в течение 4 с. При $t = 4$ с цель исчезала, и испытание заканчивалось. Временная разметка испытаний изображена на рисунке 1.



Рис. 1. Временная разметка испытания

Формирование данных для обучения

В данной работе для задач классификации мы использовали следующие моторные образы: сжатие-разжатие левой ладони и сжатие-разжатие правой ладони (для 2-классовой классификации). Для 3-классовой классификации вместе со сжатием-разжатием ладоней добавилось состояние покоя, во время которого испытуемый не воображает никакие МИ (при этом на результирующей ЭЭГ могут присутствовать шумы от различных источников). Были исключены данные 4 пациентов: 88-го, 92-го, 100-го, 104-го, так как данные их испытаний являются повреждёнными и содержат неполную информацию о испытаниях. Для сокращения размерности данных были использованы 19 электродов. Данный набор электродов соответствует системе разметки электродов 10-20, включающей в себя 21 электрод. При этом электроды A1 и A2, располагающиеся на ушах пользователя, исключены из дальнейших экспериментов.




Рис. 2. Пример получившихся GAF матриц разного разрешения

Для дальнейших экспериментов данные первых 90 испытуемых были взяты для формирования обучающей и валидационной выборок в отношении 80% к 20% соответственно. Для формирования тестовой выборки были взяты данные оставшихся 15 испытуемых. Работа с датасетом была выполнена с помощью библиотеки MNE [3] для Python.

Разработанная архитектура

В данной работе в задачах классификации моторных образов использовались 4 различных архитектуры глубоких нейронных сетей, 3 из которых являются стандартными моделями, широко используемыми в задачах классификации изображений: VGG19, AlexNet, ResNet50, а также предложенная архитектура, прошедшая оптимизацию гиперпараметров для нашей задачи. Реализация, обучение и тестирование моделей были созданы с помощью фреймворка Tensorflow Keras [4] для Python.

Предложенная нами архитектура была получена с помощью библиотеки Keras Tuner [5]. Архитектура основана на VGG19 (так как она стандартно показывала наибольшую точность), при этом было оптимизировано количество свёрточных слоёв, а также размерность полносвязных слоёв. Кроме того, после слоёв свёртки был добавлен рекуррентный слой LSTM с функцией активации сигмоида, который ещё больше помогает лучше захватить временные закономерности матриц GAF. Вместо функции активации ReLU в свёрточных слоях была установлена функция LeakyReLU, показав прирост точности классификации во время обучения.

В качестве оптимизатора использовался Adam с коэффициентом обучения 0,00001. Обучение длилось на протяжении 30 эпох, с размером пакета обучающих данных – 30.

Проведение экспериментов

Предложенная в данной работе модель показывает наибольшую точность в задаче классификации МО по сравнению с другими рассмотренными в работе архитектурами при следующих подобранных оптимальных параметрах входных данных: размер временного окна 3 секунды, и размер матрицы GADF 128x128.

В таблице 1 приведено сравнение точности классификации предложенной в работе модели с базовой моделью CNN, предложенной в [6], на датасете Physionet MI для 2-х и 3-х классов классификации.

Таблица 1

Точность классификации МО на датасете Physionet EEG MI

Модель	Количество учитываемых электродов	Максимальная точность
CNN (Dose et al. [6])	58	80,38 % 69,82 %
CNN-LSTM (Эта работа)	19	84,18 % 69,05 %

Заключение

В ходе проделанной работы была разработана модель классификации моторных образов на основе инструментов глубокого обучения и преобразования Gramian Angular Field. Предложенная в данной работе модель, используя намного меньше электродов (19 против 58), на 3,8% обошла модель CNN из [6] в задаче 2-х классов классификации и показала схожий результат в задаче 3-х классов классификации (разница менее 1%).

Список использованных источников

1. Wang Z., Oates T. Imaging time-series to improve classification and imputation // Twenty-Fourth International Joint Conference on Artificial Intelligence. – 2015.
2. Schalk G. A general-purpose brain-computer interface (BCI) system // IEEE Transactions on biomedical engineering. – 2004. – Т. 51. – № 6. – P. 1034–1043.
3. Gramfort A. et al. MEG and EEG data analysis with MNE-Python // Frontiers in neuroscience. – 2013. – P. 267.
4. Chollet F. et al. Keras: The python deep learning library. URL: <https://github.com/fchollet/keras>.
5. O'Malley T. et al. Keras Tuner. URL: github.com/keras-team/kerastuner.
6. Dose H. et al. An end-to-end deep learning approach to MI-EEG signal classification for BCIs // Expert Systems with Applications. – 2018. – V. 114. – P. 532–542.