

# КЛАССИФИКАЦИЯ МОТОРНЫХ ОБРАЗОВ С ПОМОЩЬЮ ГЛУБОКОГО ОБУЧЕНИЯ И ГРАФИЧЕСКОГО ПРЕДСТАВЛЕНИЯ ЭЛЕКТРОЭНЦЕФАЛОГРАММ

*А.Д. Брагин, ассистент ОИТ.,  
А.Л. Гоморов, студент гр. 8ВМ03.  
Томский политехнический университет  
E-mail: alg5@tpu.ru*

## **Введение**

Классификация моторных образов имеет множество трудностей: недостаток данных для обучения моделей, отсутствие общепринятых норм для входных параметров моделей (размер временного окна, количество электродов и т.д.), а также необходимость баланса между производительностью и точностью в случае практического применения моделей в ВСИ-системах.

Целью нашей работы являлось нахождение оптимального размера временного окна сигналов ЭЭГ, содержащих моторные образы (МО), для выбранного датасета, а также исследование влияния учёта соседних временных окон на точность классификации МО с помощью сверточных нейронных сетей и с применением метода Gramian Angular Field.

## **Описание алгоритма**

Для достижения поставленной цели была проделана следующая работа:

1. Мы загрузили данные датасета 10 испытуемых, взяв те испытания, где выполнялись моторные образы следующих действий: сжатие и разжатие левой ладони, сжатие и разжатие правой ладони, а также состояние покоя (для 3-классовой классификации).
2. Мы сформировали по 3 набора данных для обучающей и тестирующей выборок с различным размером временного окна для задач 2-х классовой классификации и 3-х классовой классификации.
3. В сформированных наборах данных мы разделили каждое испытание на 11 пересекающихся временных окон.
4. По сформированным наборам данных были созданы обучающие и тестирующие выборки с помощью применения преобразования Gramian Angular Field к полученным ранее временным последовательностям.
5. Мы обучили несколько моделей сверточных нейронных сетей с различной архитектурой для каждого рассматриваемого размера временного окна, чтобы найти его оптимальное значение.
6. После этого на модели сети, показавшей наилучшие результаты, было протестировано влияние учёта соседних временных окон на точность классификации, для чего различное количество пересекающихся временных окон испытания последовательно подавалось на вход модели нейронной сети, и решение о принадлежности класса испытания определялось усреднением решений сети.

## **Описание датасета**

В данной работе использовалась база данных MI-EEG Physionet, которая была записана разработчиками системы BCII2000 [1]. Данные MI-EEG Physionet получены с 64-х электродов в соответствии с международной системой 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.

В данной работе для сокращения размерности данных были использованы 12 электродов (FC1-FC6 и CP1-CP6). В работе [2] показали, что сокращение с 64-х до 12 рассматриваемых электродов не способствует уменьшению точности классификации МО данного датасета.

### Gramian Angular Field

С помощью преобразования Gramian Angular Field (GAF) мы представляем временные ряды в полярной системе координат, после чего создается матрица Грамиана, каждый элемент которой является косинусом суммы углов векторов. Полученная матрица в результате преобразуется в двумерное изображение [3].

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 (результат преобразования представлен на рисунке 2):

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

$$GADF = \begin{bmatrix} \sin(\varphi_1 - \varphi_1) & \cdots & \sin(\varphi_1 - \varphi_n) \\ \sin(\varphi_2 - \varphi_1) & \cdots & \sin(\varphi_2 - \varphi_n) \\ \vdots & \ddots & \vdots \\ \sin(\varphi_n - \varphi_1) & \cdots & \sin(\varphi_n - \varphi_n) \end{bmatrix} \quad (4)$$




Рис. 2. Матрицы GADF (слева) и GASF (справа) ЭЭГ МО.

### Поиск оптимального размера временного окна

Поиск оптимального размера временного окна выбирался из следующих значений: 4 с., 3 с., 2 с. При этом учитываемое время испытания для каждого размера временного окна составляло соответственно [-1;4], [-1;3], [-1;2]. При этом каждое испытание делилось на 11 пересекающихся временных окон соответствующего размера, расстояние между которыми – 0.1 с. Полученные временные ряды преобразовывались в матрицы GADF и формировали обучающую и тестирующую выборки. Матрицы GASF показали меньшую точность классификации (на 10-15%), поэтому все дальнейшие результаты приведены для GADF.

Для каждого рассматриваемого размера временного окна мы обучили 3 модели свёрточной нейронной сети различной архитектуры: VGG16, VGG19, AlexNet. На вход сетей подаётся 12 двумерных изображений GADF матрицы размером 64x64, выход сетей – значение вероятности принадлежности к определённому классу МО входных данных. Все расчёты были сделаны с помощью фреймворка TensorFlow Keras.

Таблица 1. Точность классификации МО с разным размером временного окна

Размер временного окна	VGG19		VGG16		AlexNet	
	2 класса	3 класса	2 класса	3 класса	2 класса	3 класса
4 с., [-1;4]	0.7613	0.5675	0.7318	0.5279	0.7112	0.5106
3 с., [-1;3]	0.7924	0.5909	0.7754	0.5642	0.7355	0.5413
2 с., [-1;2]	0.7241	0.5301	0.7012	0.5076	0.6933	0.4947

### Учёт соседних временных окон

Для тестирования влияния учёта соседних временных окон на точность классификации различное количество (3, 5, 7, 11) подряд идущих пересекающихся временных окон испытания последовательно подавалось на вход модели нейронной сети, и решение о принадлежности класса испытания определялось усреднением решений сети. Тестирование проводилось на модели, получившей наилучший результат на прошлом этапе (VGG19 с размером временного окна 3с.).

Таблица 2. Точность классификации МО при учёте соседних временных окон

Количество учитываемых пересекающихся временных окон	VGG19 (3с., [-1;3])	
	2 класса	3 класса
3	0.8333	0.6333
5	0.8500	0.6445
7	0.8500	0.6333
11	0.8112	0.6112

### Заключение

В результате выполненной работы можно сделать вывод, что рассмотрение соседних временных окон способно повысить точность классификации МО более чем на 5%. Оптимальное количество учитываемых пересекающихся временных окон при расстоянии между ними 0.1 с. – 5 первых окон.

### Список использованных источников

1. Schalk G. A general-purpose brain-computer interface (BCI) system //IEEE Transactions on biomedical engineering. – 2004. – Т. 51. – №. 6. – С. 1034-1043.
2. Lun X. et al. A simplified CNN classification method for MI-EEG via the electrode pairs signals //Frontiers in Human Neuroscience. – 2020. – С. 338.
3. Wang Z., Oates T. Imaging time-series to improve classification and imputation //Twenty-Fourth International Joint Conference on Artificial Intelligence. – 2015.