

# Применение графовых нейронных сетей к многомерным временным рядам для обнаружения новых функциональных паттернов в нейрофизиологии

Л.С. Сидоров

Московский государственный университет имени М.В.

Ломоносова

Москва, Россия

leon.sidorov@gmail.com

А.И. Майсурадзе

Московский государственный университет имени М.В.

Ломоносова

Москва, Россия

maysuradze@cs.msu.ru

**Аннотация**—В работе предложена методика, помогающая исследователям по серии экспериментов автоматически выявить функциональный паттерн в многомерных временных рядах. При этом было достаточно формализовать исходную задачу в терминах машинного обучения и не требовалось углубляться в предметную область. Работоспособность методики продемонстрирована в области нейрофизиологии для данных, где уже известен ожидаемый паттерн. Предложенная нейросетевая архитектура использует информацию об устройстве, с помощью которого были собраны данные. Исходное положение записывающих электродов было закодировано в виде графа и передано в соответствующую архитектуру. Для дальнейшего развития данной идеи представляет интерес применение предложенной методики в других предметных областях, например, показателям с датчиков на промышленных конвейерах или банковским транзакциям. Для подобных задач рассмотренный подход может быть доработан и расширен.

**Ключевые слова**—P300, временные ряды, функциональные паттерны, графовые нейронные сети, интерпретация

## 1. ВВЕДЕНИЕ

Во многих предметных областях исследуемые данные имеют вид многомерных временных рядов. Это могут быть показания датчиков на производственных линиях, акции на фондовом рынке или истории денежных транзакций. Иногда такие временные ряды возникают как результат дополнительной обработки, например, видео может преобразовываться в пучок траекторий специфических точек.

В наши дни исследователи ждут от моделей машинного обучения (МО) не просто решения прикладных задач, но и интерпретируемости результатов. Модели должны явно демонстрировать пользователям закономерности, которые они нашли. При этом анализ многомерных временных рядов во многих случаях сводится к выявлению так называемых *функциональных паттернов* [2], то есть особенностей поведения временного ряда, соответствующих некоторым интересующим исследователей состояниям системы. На протяжении многих лет эксперты из различных предметных областей уже выявили некоторое количество функциональных паттернов. Задачей данной работы является предложить методику автоматического поиска подобных паттернов в многомерных временных рядах без обладания какими-либо априорными знаниями о предметной области. Идея

исследования состоит в том, чтобы предложить модель, которая как частный случай найдет уже известные паттерны. Развивая подобный подход, в будущем исследователи смогут использовать модели машинного обучения, чтобы быстрее находить новые виды паттернов и закономерностей в исходных данных многомерных временных рядов.

Кроме того, наш подход использует дополнительную информацию о структуре измерительного устройства. Её можно представить в виде графа, содержащего информацию об отношении порядка компонентов многомерного временного ряда. Подобный подход должен улучшить обобщающую способность изучаемой модели.

## 2. ПРЕДМЕТНАЯ ОБЛАСТЬ

В данной работе в качестве предметной области взята нейрофизиология. Соответственно, работа методики будет продемонстрирована на выявлении одного из самых известных функциональных паттернов в электроэнцефалограммах (ЭЭГ), а именно *волны P300*.

Нетрудно видеть, что традиционные паттерны, такие как волна P300, удобно выявлять с помощью скользящих фильтров или операции свёртки [1]. Подобные операции уже реализованы в традиционных нейросетевых моделях МО.

Для экспериментов мы использовали данные, описанные в [2]. Набор данных «Матрица» был записан с помощью матрицы символов, наблюдая за которой человек может писать слова, концентрируя своё внимание на отдельных символах. Во время эксперимента строки и столбцы матрицы подсвечиваются в случайном порядке, реакция на эти неожиданные для респондента подсвечивания и позволяет понять, какой символ загадал человек.

Согласно исследованиям нейрофизиологов ожидается, но не гарантируется, что подсвечивание целевого символа вызывает на ЭЭГ волну P300. Хотя из обучающей разметки мы знаем, когда загорался целевой символ, эксперимент по постановке не гарантирует, что во время воздействия возникнет волна P300, однако шанс этого события крайне велик. Соответственно, модель МО не получает информацию о наличии волны P300 напрямую. Основная задача данной работы заключается в проверке гипотезы, что модель МО всё-таки сможет сама найти функциональный паттерн, который нейрофизиологам уже известен.

Стоит отметить, что медицинские данные как правило имеют достаточно подробные спецификации. Часто вместе с данными находится файл с координатами каждого электрода. Именно эту пространственную информацию мы и хотим включить в нейросетевую модель, чтобы повысить её обобщающую способность. Подчеркнём, что граф строится по трёхмерному объекту, принимая во внимание форм-фактор нейроинтерфейса, по двухмерному многообразию.

Помимо улучшения качества работы рассматриваемой модели, использование архитектуры на основе графов позволило нам получить более интерпретируемые результаты. Как сказано в [3], наиболее информативными электродами в записывающем устройстве являются Fz, Cz, P3, P4, Po7, Po8, Pz и Oz. На Рис. 1 мы можем заметить, что базовая архитектура в нашем подходе сфокусировала своё внимание лишь на трёх электродах Pz, Po7 и Po8. В то время как графовая нейронная сеть на Рис. 2 смогла распознать все вышеперечисленные электроды, кроме Fz и Cz.

Сам граф для построения подобной модели был получен с помощью триангуляции Делоне. Использование случайного графа соседства ухудшило итоговый результат, а также затруднило его интерпретацию. Таким образом, мы можем быть уверены в том, что именно добавление графа соседства улучшило начальный подход.

### 3. ЗАКЛЮЧЕНИЕ

Предложенная архитектура нейронной сети поочередно применяет фильтры к каналам и временным промежуткам на исходных данных, выявляя тем самым важность тех или иных электродов на голове человека или моментов времени во время записи.

Добавив дополнительный графовый фильтр в исходную архитектуру, мы смогли улучшить обобщающую способность модели, что также подтвердилось на значениях весов в пространственных фильтрах сети.

Модель самостоятельно выявила важнейшие электроды в записи ЭЭГ, а также сфокусировала своё внимание на её ключевых участках. Таким образом, модель самостоятельно научилась выявлять волну P300.

Качество решения задач бинарной классификации и классификации символов сразу же оказалось на уровне лучших решений из [2].

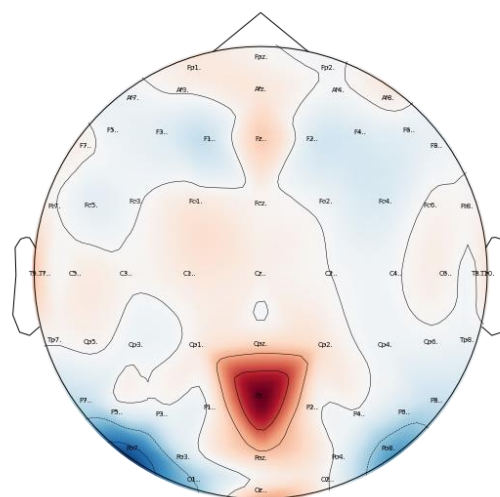


Рис. 1. Веса входного слоя нейронной сети в базовом подходе




Рис. 2. Веса входного слоя нейронной сети после применения графовой свёртки

### БЛАГОДАРНОСТИ

Работа выполнена при поддержке НОШ МГУ «Мозг, когнитивные системы, искусственный интеллект», НИР МГУ 5.1.21, гранта РФФИ No. 20-01-00664.

### ЛИТЕРАТУРА

- [1] Cecotti, H. Convolutional neural networks for p300 detection with application to brain-computer interfaces / H. Cecotti, A. Graser // Piscataway: IEEE. – 2010. – P. 433–445.
- [2] Blankertz, B. The BCI competition III: Validating alternative approaches to actual BCI problems / B. Blankertz, K.R. Muller, D.J. Krusienski, G. Schalk, J.R. Wolpaw, A. Schlogl, G. Pfurtscheller, J.R. Millan, M. Schroder, N. Birbaumer // Piscataway: IEEE. – 2006. – P. 153–159.
- [3] Sharbrough, G. American Electroencephalographic Society Guidelines for Standard Electrode Position Nomenclature / G. Sharbrough, R. Chatrian, H. Lesser, M. Luders, T. Nuwer, T. Picton – Philadelphia: Lippincott Williams & Wilkins, 1991. – 200 p.