

Тензорное непрерывное представление сигнала при построении нейроинтерфейса BCI

В рамках курса "Моя первая научная статья"

Соболевский Федор Б05-111

Московский физико-технический институт

2 апреля 2024

ФПМИ

Задача обработки сигналов головного мозга

Основной объект исследования — электроэнцефалограммы (ЭЭГ) представляют собой многомерные временные ряды. Постановка задачи для классификации:

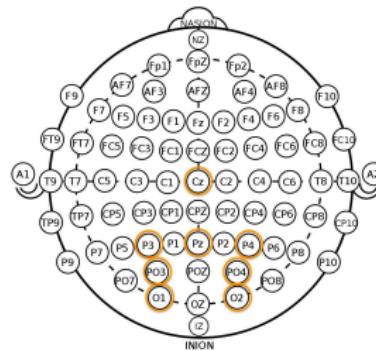
$$X = \{X_i\}_{i=1}^M,$$

$$X_i = \{x_t\}_{t \in T}, x_t \in \mathbb{R}^E,$$

$$T = \{t_i\}_{i=1}^N, t_i \in \mathbb{R},$$

$$Y = \{y_i\}_{i=1}^M, y_i \in \{0, 1\},$$

где E — количество электродов, N — количество наблюдений в одном отрезке ЭЭГ, M — количество отрезков ЭЭГ.



Карта электродов для выборки P300, используемой в работе (электроды, с которых считывается сигнал, выделены цветом)

Мотивация для использования непрерывного представления

- Сигналы головного мозга, как и многие исследуемые типы сигналов, по природе своей являются **непрерывными**.
- Большинство методов обработки сигналов (RNN, LSTM и т. п.) в качестве скрытого слоя используют **дискретное** представление.
- Непрерывное представление позволяет решить проблемы, связанные с нерегулярностью и/или пробелами в данных.

Современные методы, использующие дискретное представление

- **ERPCov TS LR** — алгоритм, основанный на римановой геометрии. Основная идея: матрицы ковариации принадлежат риманову многообразию симметричных положительно определенных матриц, поэтому их можно отобразить в касательное пространство и дальше обрабатывать стандартными методами (например, с помощью алгоритма логистической регрессии). Алгоритм реализован в библиотеке `pyriemann` в Python.

```
clf = make_pipeline(  
    XdawnCovariances(n_components),  
    TangentSpace(metric="riemann"),  
    LogisticRegression(),  
)
```

Пайплайн алгоритма ERPCov TS LR — построение ковариационных матриц, проецирование, лог. регрессия.

Современные методы, использующие дискретное представление

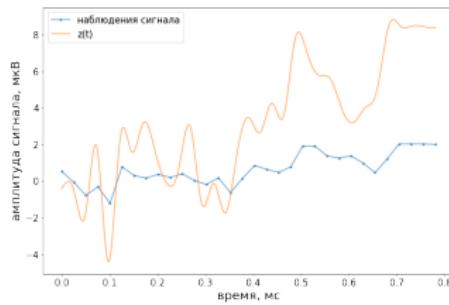
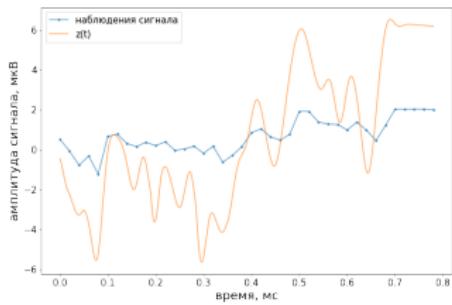
- **EEGNET** — свёрточная нейросеть, настроенная под задачу обработки ЭЭГ.

Блок	Слой	Количество фильтров	Размер фильтров	Размер данных на выходе
1	Input	F_1	$(1, \frac{1}{2}\text{rate})$	(E, N)
	Reshape			$(1, E, N)$
	Conv2D			$(F_1 \cdot E, N)$
	BatchNorm			$(F_1 \cdot E, N)$
	ReLU			$(F_1 \cdot E, N)$
	DepthwiseConv2D		$(E, 1)$	$(D * F_1, 1, N)$
	BatchNorm			$(D * F_1, 1, N)$
	ReLU			$(D * F_1, 1, N)$
	AveragePool2D		$(1, p_1)$	$(D * F_1, 1, \frac{N}{p_1})$
	Dropout*			$(D * F_1, 1, \frac{N}{p_1})$
2	SeparableConv2D	F_2	$(1, \frac{1}{4}\text{rate})$	$(F_2, 1, \frac{N}{p_1})$
	BatchNorm			$(F_2, 1, \frac{N}{p_1})$
	ReLU		$(1, p_2)$	$(F_2, 1, \frac{N}{p_1})$
	AveragePool2D			$(F_2, 1, \frac{N}{p_1 * p_2})$
	Dropout*			$(F_2, 1, \frac{N}{p_1 * p_2})$
	Flatten			$(F_2 * \frac{N}{p_1 * p_2})$
	Dense		$C * \frac{F_2 * N}{p_1 * p_2}$	C
класс				

Структура EEGNET

Методы, использующие непрерывное представление

- **Neural CDE** — нейронные управляемые дифференциальные уравнения. Модель NeuralCDE состоит из нескольких шагов: аппроксимация входных данных кубическим сплайном, решение дифференциального уравнения относительно скрытого состояния модели и классификация по информации о скрытых состояниях. Ниже визуализировано скрытое состояние для выборки P300 на регулярных и нерегулярных данных.



Методы использующие непрерывное представление

- **ODE LSTM** — модель, использующая в стандартной архитектуре сети LSTM непрерывное представление сигнала в скрытом слое, построенное с помощью нейронных обыкновенных дифференциальных уравнений.
- **LMU LSTM** — то же самое, но в качестве скрытого состояния используется разложение сигнала по полиномам Лежандра.

Задача работы номер 1: провести сравнительный анализ различных современных моделей, использующих дискретное и непрерывное представление сигнала, в приложении к задачам классификации и регрессии сигналов.

Результаты экспериментов с задачей классификации на выборке P300 при внесении нерегулярности в данные:

Модель	Точность на обучении	Точность на тесте	F1-score на обучении	F1-score на тесте
CDE	0.82	0.81	0.80	0.72
ODE-LSTM	0.74	0.72	0.71	0.67
LMU	0.76	0.74	0.71	0.69
EEGNet	0.67	0.59	0.63	0.58
PyRiemann	0.61	0.48	0.59	0.46

Тензорное представление сигнала

Основной целью работы (и источником её новизны) является построение и исследование моделей обработки сигналов ЭЭГ, использующих **тензорное представление сигнала**.

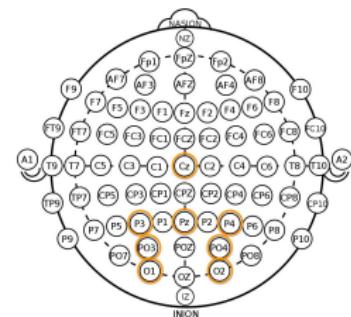
Мотивация: В задаче обработки сигнала может быть полезна информация о его природе: источниках, пространственном расположении, частотном устройстве.

Подобная идея используется, например, в сверточных нейросетях: увеличение размерности позволяет лучше учитывать внутреннюю пространственную структуру объектов и при этом может даже ускорять сходимость.

Варианты тензоризации сигнала

Вариант 1: тензоризация по пространству. Идея: учитывать пространственное расположение электродов при снятии ЭЭГ и для каждого электрода хранить информацию о соседних (по аналогии со сверточными нейросетями).

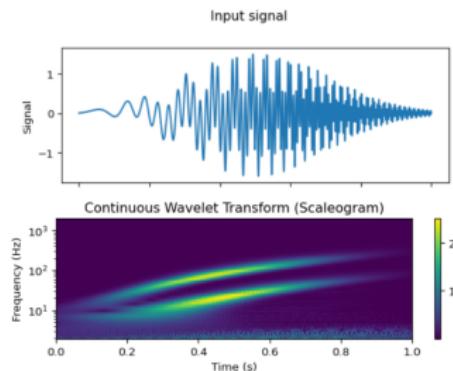
Проблема: электроды располагаются на голове довольно нетривиальным образом, вследствие чего затруднительно использовать скользящее окно для вычисления сверток. Использование же графовых моделей сильно усложнит работу, так что эта идея остается для будущих исследований.



Варианты тензоризации сигнала

Вариант 2: тензоризация по частоте. **Идея:** учитывать частотную структуру сигнала, непрерывно меняющуюся во времени, с целью улучшения информации о сигнале.

Для преобразования сигнала можно использовать *continuous wavelet transform*, реализованный в пакете PyWavelets (на рисунке приведен пример работы алгоритма из документации).



Дальнейший план работы

- Проанализировать еще несколько современных методов обработки сигналов в поисках лучшего для сравнения с предлагаемым в работе
- Рассмотреть еще одну или две выборки для задачи обработки сигнала
- Реализовать модель, основанную на тензоризации сигнала по частотам, и проанализировать её в сравнении с моделями, не использующими тензорное представление.
- Исследовать свойства, связанные с непрерывным тензорным представлением сигнала.