

Deep Learning in Computational Physics

СОЗДАНИЕ ДИНАМИЧЕСКОГО КОГНОВИЗОРА – РАСПОЗНАВАНИЕ КОГНИТИВНЫХ СОСТОЯНИЙ С ПОМОЩЬЮ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ

Макаров Александр Сергеевич ⁽¹⁾

Гаджиев Исмаил Маратович ⁽²⁾

Зав лаб., к.ф.-м.н. Доленко Сергей Анатольевич ⁽²⁾

(1) Московский государственный университет имени М. В. Ломоносова (МГУ)


(2) Научно-исследовательский институт ядерной физики имени Д. В. Скобельцина МГУ

Введение

Динамический Когновизор – инструмент, который на основе анализа данных о мозговой активности распознает и визуализирует когнитивные состояния и переходы между ними.

- Мозговая активность фиксируется с помощью функциональной магнитно-резонансной томография (фМРТ);
- Когнитивное состояние – состояние, в котором задействуются один или несколько типов мышления.

Данные фМРТ



- **31** испытуемый;
- Время одного сеанса: **30 мин**;
- Размерность изображения мозга:
91x109x91.
- Объем памяти для записи сеанса
одного испытуемого: **26 Гб**.

Задания для испытуемых

a

b

c

d

e

Lantern	Brush
Elephant	Hanky

f

Interest	Guilt
Success	Standard

- Задания 6 типов;
- Каждое задание соответствует своему КОГНИТИВНОМУ СОСТОЯНИЮ.

Цели работы

- С помощью методов глубокого обучения научиться по данным фМРТ различать состояние покоя и активности;
- Сравнить полученные результаты с результатами, полученными с помощью методов машинного обучения и анализа главных компонент.

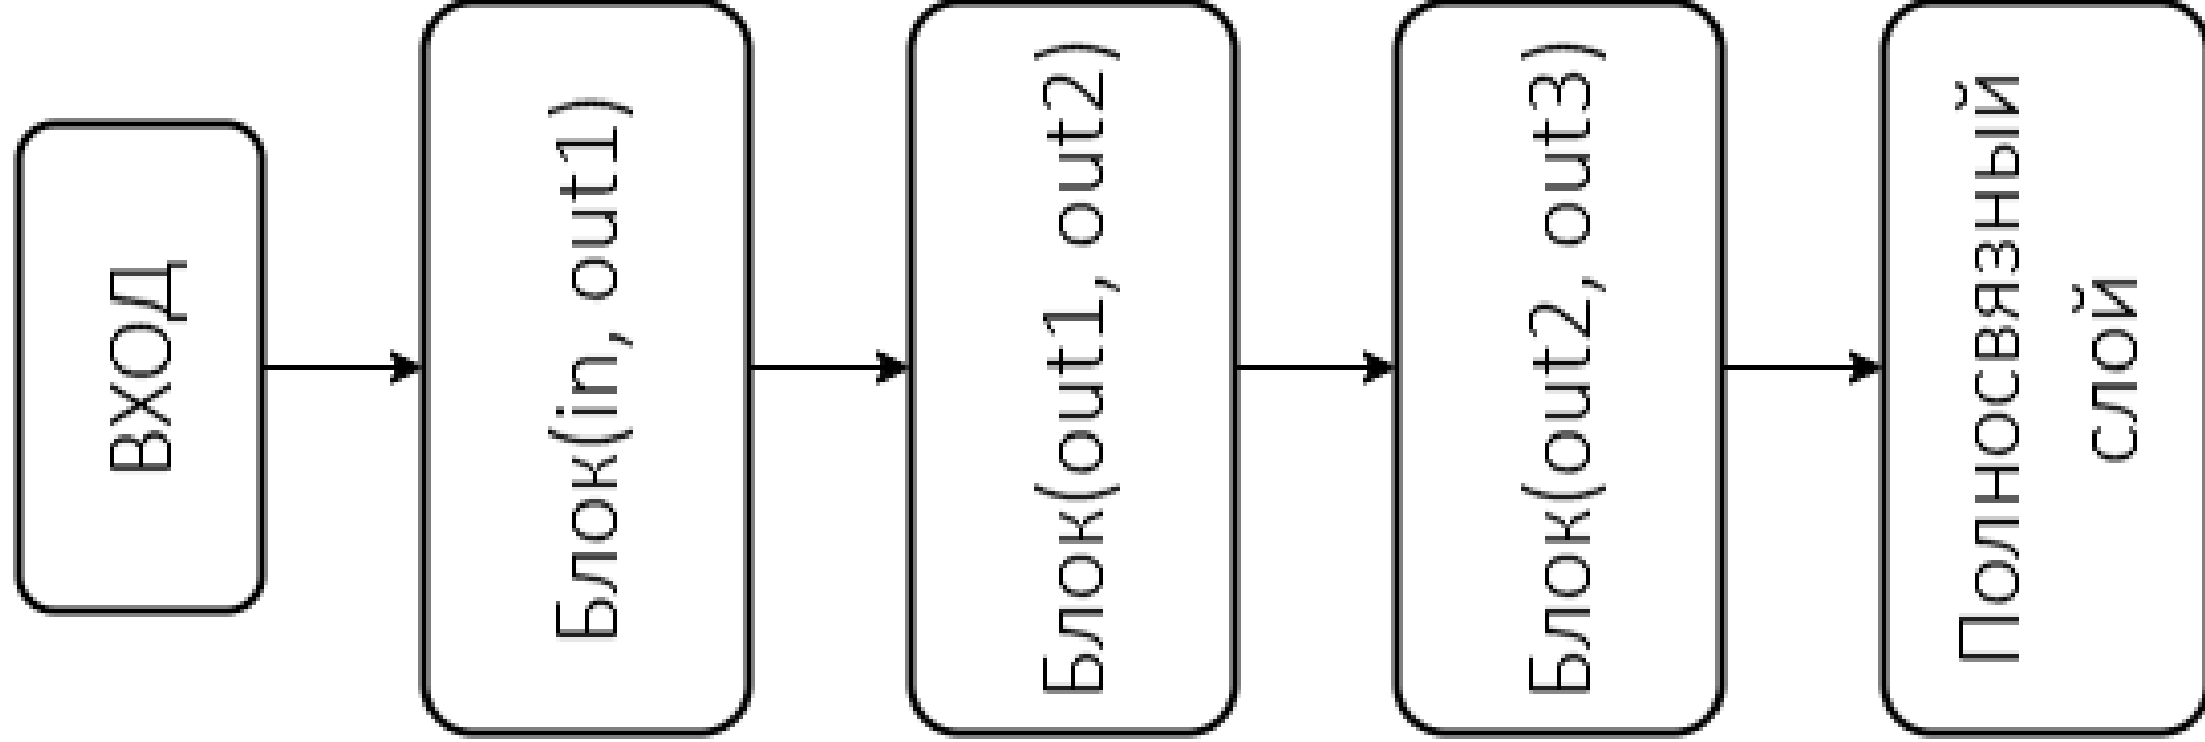
Предобработка данных

- Смещение центра координат;
- Расчет и коррекция артефактов движения;
- Коррекция неоднородности магнитного поля в области сканирования;
- Коррекция временного сдвига сигнала в срезах;
- Удаление вокселей, не относящихся к мозгу;

Предобработка данных

- Приведение индивидуальных изображений в атласное пространство MNI;
- Нормализация средней интенсивности;
- Понижение уровня шума в сигнале;
- Разбиение на тренировочную и тестовую выборки,
23 человека (83453 изображений) и 8 человек (29100 изображения),
соответственно.

Архитектура свёрточной нейронной сети



Блок свёрточной нейронной сети

Conv(3x3, in, out)

BatchNorm

ReLu

Conv(1x1, out, out)

BatchNorm


ReLu

MaxPool, 2

- Conv(NxN) – Свертка с фильтром NxN;
- in – число входных каналов
- out – число выходных каналов;
- MaxPool, 2 – макс. пулинг
с размером окна 2


Модели свертки

Slice – Модель свертки, которая принимает на вход несколько срезов 3D изображения и интерпретирует их, как 2D изображения, после чего к каждому из них применяется 2D Свертка.




Модели сверток

Sep – разделяемая 3D свертка.




Модели сверток

3D-Conv – полная 3D свертка.



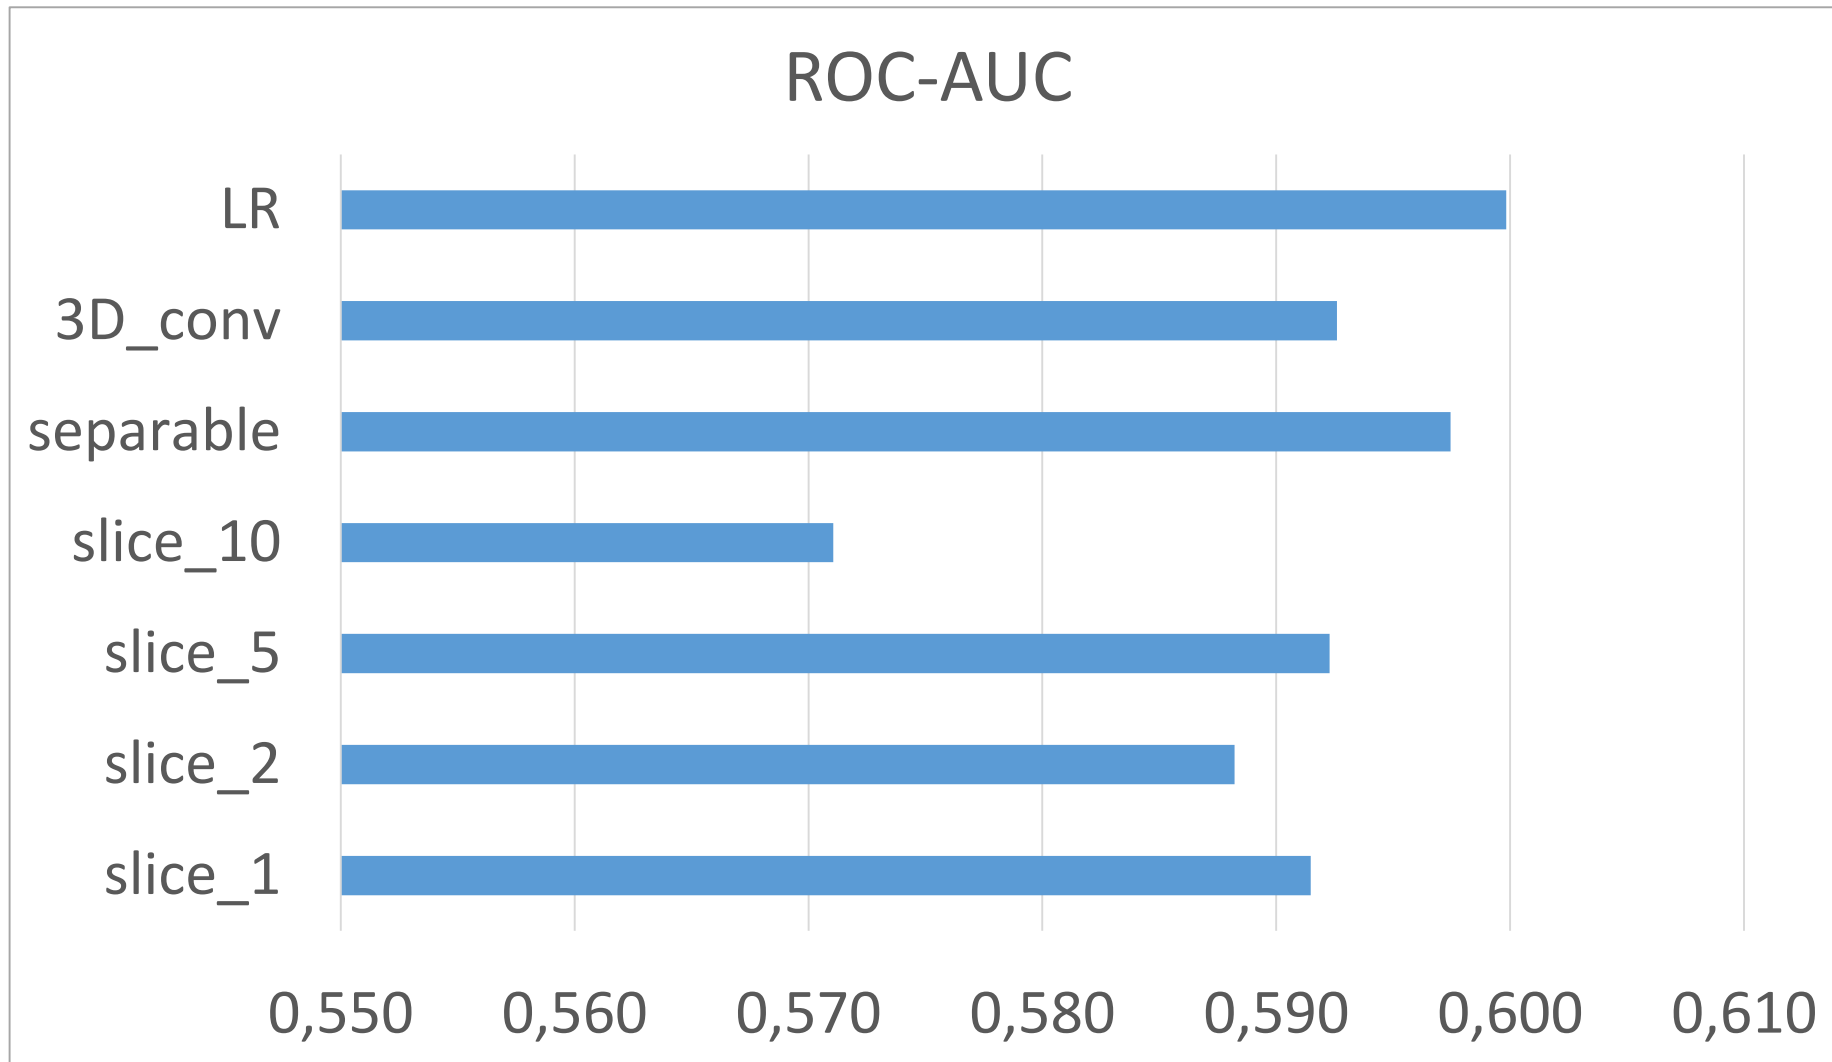
3D-Conv($N \times N \times N$)
→



Параметры моделей

Модель	Out1	Out2	Out3	Скрытый слой
Slice	128	256	256	256
Sep	32	64	64	128
3D-Conv	32	64	64	128

Результаты классификации



Выводы

- Лучшие результаты показала модель с разделяемыми 3D свертками;
- Все модели глубокого обучения показали результаты,
не превосходящие полученные нами ранее
с помощью машинного обучения и анализа главных компонент.

Выводы

- Вероятно, модель, построенная на основе машинного обучения и анализа главных компонент, уже использует почти всю информацию из обработанных фМРТ изображений;
- Для улучшения результатов, возможно, стоит использовать новый способ предобработки;
- Как показало прошлое исследование, необходимо также учитывать предысторию фМРТ изображений.

Спасибо за внимание!