



## Сравнение ансамблевых и корреляционных графов в задаче классификации состояний мозга на основе фМРТ-данных

Д. В. Власенко<sup>1</sup>✉, В. Г. Ушаков<sup>1</sup>, А. А. Заикин<sup>1,2</sup>, Д. Г. Захаров<sup>1</sup>

<sup>1</sup>Национальный исследовательский университет «Высшая школа экономики», Москва, Россия

<sup>2</sup>Университетский колледж Лондона, Великобритания

E-mail: ✉dvlasenko@hse.ru, uwadim@gmail.com, alexey.zaikin@ucl.ac.uk, dzakh76@gmail.com

Поступила в редакцию 12.10.2024, принята к публикации 25.01.2025,

опубликована онлайн 3.02.2025, опубликована 31.07.2025

**Аннотация.** Изучение функциональных сетей мозга, которые поддерживают когнитивные процессы, является одной из центральных задач современной нейронауки. Функциональная магнитно-резонансная томография (фМРТ) широко используется для получения данных об активности мозга. Однако высокая размерность и динамическая природа фМРТ-данных делает их обработку сложной задачей. Сетевые методы представления данных предлагают перспективный подход, позволяющий описывать мозг в виде сети, где узлы соответствуют областям мозга, а рёбра — функциональным связям между ними. Это позволяет глубже исследовать топологию мозговых сетей и их роль в когнитивных состояниях. Цель данной работы — сравнить ансамблевые и корреляционные графы в задаче классификации состояний мозга на основе данных функциональной магнитно-резонансной томографии. **Методы.** В данной работе представлен новый метод представления фМРТ-данных в графовой форме, основанный на ансамблевом обучении. Для демонстрации эффективности метода представления данных мы сравнили его с корреляционными графами, применяя затем для классификации состояний мозга графовую нейронную сеть. **Результаты и Заключение.** Наши результаты показали, что ансамблевые графы приводят к существенно более точной и стабильной классификации. Лучшая эффективность классификации позволяет предположить, что с использованием этого метода мы более эффективно определяем функциональные связи между регионами мозга при выполнении когнитивных задач.

**Ключевые слова:** когнитивные процессы, функциональная магнитно-резонансная томография, ансамблевые графы, классификация, машинное обучение.

**Благодарности.** Исследование выполнено при поддержке Российского научного фонда (грант номер 24-68-00030) и частично за счет суперкомпьютерного комплекса Национального исследовательского университета «Высшая школа экономики».

**Для цитирования:** Власенко Д. В., Ушаков В. Г., Заикин А. А., Захаров Д. Г. Сравнение ансамблевых и корреляционных графов в задаче классификации состояний мозга на основе фМРТ-данных // Известия вузов. ПНД. 2025. Т. 33, № 4. С. 557–566. DOI: 10.18500/0869-6632-003164. EDN: PPZDBV

Статья опубликована на условиях Creative Commons Attribution License (CC-BY 4.0).

## Comparison of ensemble and correlation graphs in the task of classifying brain states based on fMRI data

D. V. Vlasenko<sup>1</sup>✉, V. G. Ushakov<sup>1</sup>, A. A. Zaikin<sup>1,2</sup>, D. G. Zakharov<sup>1</sup>

<sup>1</sup>National Research University Higher School of Economics, Moscow, Russia

<sup>2</sup>University College London, UK

E-mail: ✉dvlasenko@hse.ru, uwadim@gmail.com, alexey.zaikin@ucl.ac.uk, dzakh76@gmail.com

Received 12.10.2024, accepted 25.01.2025, available online 3.02.2025, published 31.07.2025

**Abstract.** The study of functional brain networks that support cognitive processes is one of the central goals of modern neuroscience. Functional magnetic resonance imaging (fMRI) is widely used to obtain data on brain activity. However, the high dimensionality and dynamic nature of fMRI data makes their processing challenging. Network-based methods of data representation offer a promising approach to describe the brain as a network, where nodes correspond to brain regions and edges correspond to functional connections between them. This allows us to further explore the topology of brain networks and their role in cognitive states. The *purpose* of this paper is to compare ensemble and correlation graphs in a brain state classification task based on functional magnetic resonance imaging (fMRI) data. *Methods.* This paper presents a novel method for representing fMRI data in graph form based on ensemble learning. To demonstrate the effectiveness of the data representation method, we compared it with correlated graphs by applying a graph neural network to classify brain states. *Results and Conclusion.* Our results showed that ensemble graphs lead to significantly more accurate and stable classification. The better classification performance suggests that using this method we are more efficient in identifying functional connections between brain regions during cognitive tasks.

**Keywords:** cognitive processes, functional magnetic resonance imaging, ensemble graphs, classification, machine learning.

**Acknowledgements.** This research was supported by RSF (project No. 24-68-00030) and in part through computational resources of HPC facilities at HSE University.

**For citation:** Vlasenko DV, Ushakov VG, Zaikin AA, Zakharov DG. Comparison of ensemble and correlation graphs in the task of classifying brain states based on fMRI data. Izvestiya VUZ. Applied Nonlinear Dynamics. 2025;33(4):557–566. DOI: 10.18500/0869-6632-003164

*This is an open access article distributed under the terms of Creative Commons Attribution License (CC-BY 4.0).*

### Введение

Одной из центральных задач современной междисциплинарной науки является изучение фундаментальных принципов функционирования мозга человека. К сожалению, в настоящее время не существует общей теории, которая описывала бы эти принципы, и основным подходом является изучение активности мозга посредством различных физических методов (электроэнцефалографии, магнитоэнцефалографии, функциональной магнитно-резонансной томографии и др.) и выявление на основе этих данных функциональных сетей мозга, отвечающих тем или иным когнитивным процессам. Понимание того, как различные области мозга взаимодействуют и координируют свою деятельность во время выполнения различных когнитивных задач, и способность точно классифицировать состояния мозга может дать важные сведения о природе когнитивных процессов и способствовать разработке методов диагностики и лечения нейродегенеративных заболеваний. В этом контексте функциональная магнитно-резонансная томография (фМРТ) [1, 2] стала важным инструментом для получения данных об активности мозга [3–6].

Анализ фМРТ-данных представляет собой сложную задачу из-за их высокоразмерной и динамичной природы. В последние годы все больше внимания уделяется применению сетевых методов представления данных для описания функциональных связей между различными областями мозга [7–9]. Эти методы позволяют строить модель мозга в виде сети, где узлы представляют

собой регионы мозга, а рёбра — функциональные связи между ними. Такой подход позволяет глубже изучить природу когнитивных состояний, выявляя как локальные, так и глобальные связи в активности мозга. Использование сетевых методов анализа фМРТ-данных позволяет не только исследовать характеристики функциональных сетей мозга, но и их топологию с использованием методов машинного обучения [6, 10–12].

На данный момент в нейронауке существует несколько методов представления фМРТ-данных в сетевой форме. Самым простым и популярным методом является корреляционный граф [6, 10, 13]. В общем случае для вычисления функциональной связи между двумя регионами мозга вместо корреляции Пирсона может использоваться любая другая метрика, которая может быть инвариантна или не инвариантна относительно времени и пространственного расположения регионов мозга [14–16].

В этой работе мы предлагаем новый подход к построению графов связности, основанный на ансамблевом обучении [17–19], который ранее не использовался для презентации когнитивных данных. Он предназначен для задачи бинарной классификации состояний мозга и обладает рядом существенных преимуществ. Во-первых, ансамблевое обучение позволяет эффективно справляться с шумами, неизбежно присутствующими в данных и особенно свойственными данным нейровизуализации, а также с индивидуальной разницей в протекании когнитивных процессов у испытуемых. Во-вторых, предварительная обработка данных с использованием методов машинного обучения перед использованием сложной модели классификации приводит к повышению точности классификации. В-третьих, наш метод презентации фМРТ-данных позволяет использовать мультимодальные данные и отражать в графе полезную информацию, которую несут различные метрики связности и характеристики временных рядов регионов мозга. Другими словами, наш метод объединяет достоинства различных метрик, строя при этом один график. Это приводит к уменьшению расхода компьютерной памяти, необходимой для хранения данных, и вычислительного времени, которое тратится на последующий сетевой анализ данных. Такие графы могут быть названы ансамблевыми или «синолитическими» графиками от греческого слова «synolo», то есть ансамбль [20].

Для верификации выше описанных утверждений нами на основе данных NCP 1200 Subject Release [21, 22] были построены корреляционные графы (как относительно простой и наиболее популярный метод представления фМРТ-данных) и ансамблевые графы. Затем классификация состояний мозга проводилась с применением графовой нейронной сети (ГНС). Построенные корреляционные и ансамблевые графы, а также весь код доступны для ознакомления на Zotero и GitHub [23].

## 1. Метод

**1.1. Данные.** Для проверки предлагаемого метода были отобраны фМРТ-данные здоровых 100 человек из NCP 1200 Subject Release [21, 22]. Итоговая выборка состояла из 50 мужчин и 50 женщин возрастом от 22 до 35 лет. Мы использовали данные, которые были собраны при участии испытуемым в одном из шести различных экспериментов: рабочая память, азартные игры, движение конечностями, социальное восприятие, реляционное восприятие и эмоциональное восприятие [24]. Для задачи бинарной классификации в каждом эксперименте нами были выделены два состояния мозга (табл. 1). Каждому состоянию мозга соответствовала та или иная выполняемая испытуемым когнитивная задача. Таким образом, в каждом из семи экспериментов было по 200 размеченных данных.

Данные были собраны при 3 Тл с полем зрения  $208 \times 180$  мм, размером изотропного вокселя 2.0 мм, временем повторения (TR) 0.72 с, временем эха (TE) 33.1 мс и углом переворота 52 градуса. Предварительная обработка фМРТ была выполнена NCP, а именно была выполнена коррекция

Таблица 1. Два состояния мозга для каждой когнитивной задачи, между которыми производится классификация

Table 1. Two brain states for each cognitive task, between which classification is made

	состояние 1	состояние 2
Рабочая память	0-назад	2-назад
Азартные игры	победа	проигрыш
Движение конечностями	левая рука или нога	правая рука или нога
Социальное восприятие	случайное движение	ментальное взаимодействие
Реляционное восприятие	отношение	сходство
Эмоциональное восприятие	нейтрально	страх

движений головы, коррекция искажения от магнитного поля, пространственная нормализация и фильтрация пространственных и временных шумов. Более подробно с методами получения и обработки данных можно ознакомиться в [24, 25]. Дополнительно нами был удален линейный тренд из данных, временные ряды вокселей были нормализованы и парцеллированы на 379 регионов с помощью атласа [26]. Временные ряды внутри каждого региона были пространственно усреднены таким образом, чтобы каждому региону мозга соответствовал один временной ряд.

**1.2. Репрезентация фМРТ-данных в графовой форме.** Введем необходимые обозначения. Граф  $g = (V, E, H, W)$  состоит из множества вершин  $V = \{i | i \in 1, \dots, n\}$ , множества неориентированных ребер  $E = \{ij | i \in V; j \in V; i \neq j\}$ , множества значений вершин  $H = \{h_i | i \in V\}$  и множества значений ребер  $W = \{w_{ij} | ij \in E\}$ . Каждая вершина графа ассоциирована с регионом мозга, полученным путем парцелляции фМРТ-данных. Временной ряд региона мозга  $i$  будем обозначать с помощью  $x_i$ .

Для сравнения с ансамблевыми графами мы использовали знаменитые в области нейропривизуализации и простые в интерпретации корреляционные графы. В таких графах значение вершины  $i$  есть среднее значение региона  $h_i = \bar{x}_i$ , значение ребра  $ij$  есть корреляция Пирсона между временными рядами двух регионов  $w_{ij} = \rho(x_i, x_j)$ . При этом для каждого графа мы нормализовали вес его ребер.

В общем случае для ансамблевых графов значение ребра  $ij$  вычисляется как разница вероятностей двух состояний мозга при условии значений некоторого набора функций  $f_1, \dots, f_k$  от временных рядов регионов мозга  $i, j$ :

$$w_{ij} = P(2 | f_1(x_i, x_j), \dots, f_k(x_i, x_j)) - P(1 | f_1(x_i, x_j), \dots, f_k(x_i, x_j)). \quad (1)$$

В качестве функций  $f_1, \dots, f_k$  мы выбрали те же метрики, что были использованы и для корреляционных графов: среднее значение регионов  $i$  и  $j$  и корреляцию Пирсона между ними. Таким образом, для вычисления весов ребер для каждого ребра требовалось обучить индивидуальный классификатор. В частности, мы использовали метод опорных векторов [27] с радиально-базисным ядром и параметром регуляризации, равным единице. Из уравнения (1) следует, что вес ребра может принимать значения от  $-1$  до  $1$ . Соответственно, если вес ребра  $w_{ij}$  отрицательный, то ребро  $ij$  несет информацию о том, что состояние мозга 1 является наиболее вероятным состоянием. Если вес ребра  $w_{ij}$  положительный, то ребро  $ij$  несет информацию о том, что уже состояние мозга 2 является наиболее вероятным состоянием. Чем больше абсолютное значение веса ребра  $|w_{ij}|$ , тем больше информации для классификации несет ребро  $ij$ . Так как информация о средних значениях временных рядов регионов уже учтена в весах ребер, а для ГНС необходимы значения вершин, то значение каждой вершины  $i$  есть единица ( $h_i = 1$ ). Весь процесс построения ансамблевых графов и классификации отображен на рис. 1.

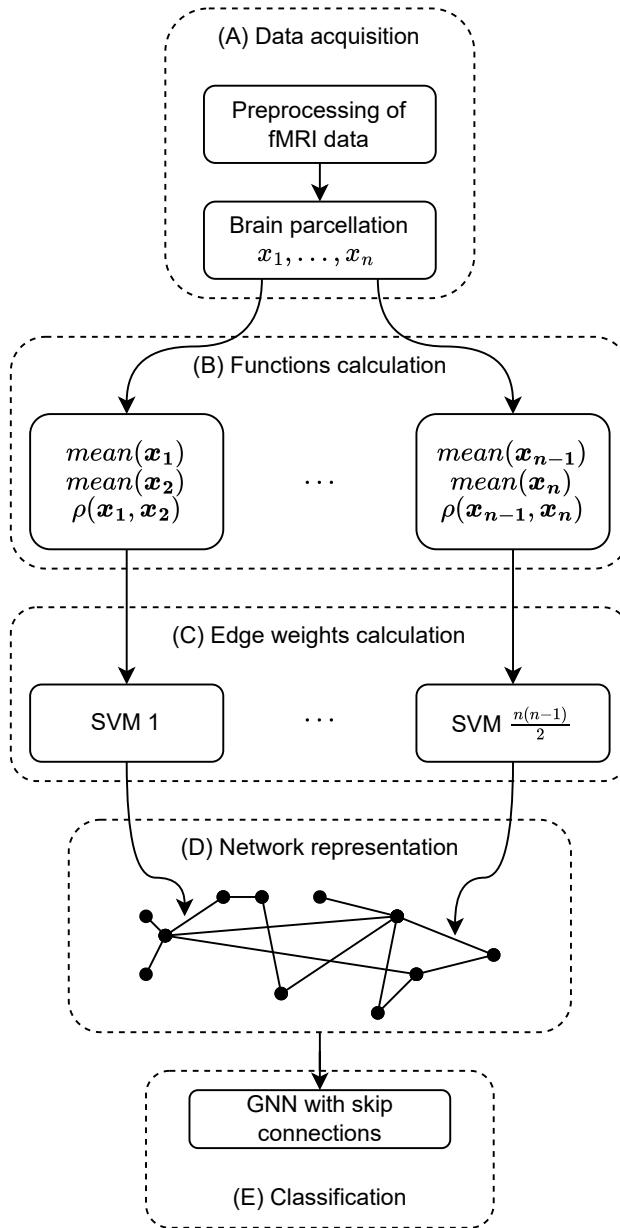


Рис. 1. Схема представления фМРТ-данных в форме ансамблевых графов для классификации состояний мозга. Сначала данные подвергаются необходимой предварительной обработке, из них извлекаются временные ряды (А). Затем на временных рядах вычисляются функции (В), значения которых подаются в классификаторы для вычисления весов ребер графа (С). После этого данные представляются в графовой форме (Д) и подаются в метаклассификатор, например, графовую нейронную сеть, для окончательной классификации (Е)

Fig. 1. An overview of representing fMRI, EEG/MEG data in graph form for classification of brain states. Initially, the data is preprocessed in the required way and time series are extracted from the data (A). Then, functions are calculated on the time series (B), the values of which are then fed to classifiers to calculate the edge weights of the graph (C). After that, the data is presented in graph form (D) and fed to a meta-classifier, e.g. a graph neural network, for the final classification (E)

**1.3. Графовая нейронная сеть.** Для классификации графов, полученных на предыдущем этапе, использовалась простая графовая нейронная сеть со следующей архитектурой. Классифицируемый граф подавался на сверточный графовый слой [28], после чего применялась ReLU [29]. После нелинейности использовались слои Batch Normalization [30] и DropOut [31]

для предотвращения переобучения нейронной сети. Далее использовались так называемые «skip connections» [32], когда выход сверточного слоя после нелинейности соединяется с данными на входе слоя. Аналогично применялись еще два сверточных слоя. В результате получались эмбеддинги вершин, учитывающие влияние соседних вершин графа. Для перехода от эмбеддингов вершин к эмбеддингу всего графа использовался Global max Pooling [33]. Далее, после еще одного слоя Batch Normalization, данные подавались на полносвязный слой, после которого вычислялись оценки принадлежности объекта к классу с помощью сигмоиды. В качестве функции потерь использовалась кросс-энтропия.

**1.4. Схема обучения и валидации.** Для процедуры построения графов каждый датасет разбивался на обучающую и тестовую выборки по количеству испытуемых: 70 человек в обучающей выборке (140 наборов данных), 30 — в тестовой (60 наборов данных). На обучающей выборке происходила тренировка моделей для построения графов, которые затем применялись для построения графов на тестовой выборке.

Классификация графов проводилась с помощью ГНС с таким же разделением на обучающую и тестовую выборку, что и для задачи построения графов. Тестовая выборка дополнитель но разбивалась на валидационную выборку из 20 испытуемых (40 размеченных графов), на которой производился поиск оптимальных гиперпараметров ГНС и, собственно, тестовую выборку из 10 испытуемых (20 наборов графов), на которой оценивались метрики классификации. После подбора гиперпараметров ГНС на валидационной выборке ГНС обучалась и тестиировалась 50 раз с различными random seed, что позволило оценить среднее и стандартное отклонение метрик.

## Результаты и заключение

Результаты сравнения корреляционного и ансамблевого методов репрезентации на основе фМРТ-данных НСР представлены в табл. 2. В ней представлены средняя точность классификации и F1-метрика и их стандартные отклонения. Ансамблевый метод (в среднем) для каждого типа эксперимента приводит к более точной и стабильной классификации.

Мы предполагаем, что нашему методу удается превзойти корреляционный метод из-за того, что корреляционные графы содержат в себе шум, порождаемый следующими причинами:

Таблица 2. Сравнение корреляционного и ансамблевого методов репрезентации на основе фМРТ-данных НСР. Представлена точность классификации и F1-метрика в формате среднее (стандартное отклонение)

Table 2. Comparison of correlation-based and ensemble-based representation methods on fMRI data of HCP. Classification accuracy and F1 metric in mean (standard deviation) format are presented

		Корреляционные графы	Ансамблевые графы
Рабочая память	Accuracy (%) F1 (%)	71.7 (7.11) 72.78 (7.86)	79.4 (3.56) 74.37 (5.23)
Азартные игры	Accuracy (%) F1 (%)	65.3 (6.12) 70.7 (5.82)	98.9 (2.07) 98.95 (1.97)
Движение конечностями	Accuracy (%) F1 (%)	62.3 (6.34) 42.66 (12.36)	68.0 (4.36) 67.75 (4.55)
Социальное восприятие	Accuracy (%) F1 (%)	80.6 (5.71) 82.57 (4.5)	98.2 (2.4) 98.11 (2.53)
Реляционное восприятие	Accuracy (%) F1 (%)	85.3 (5.69) 85.46 (5.8)	95.0 (0.0) 95.24 (0.0)
Эмоциональное восприятие	Accuracy (%) F1 (%)	54.2 (5.23) 55.64 (6.34)	73.8 (6.37) 73.7 (5.18)

неустойчивостью корреляционных коэффициентов из-за коротких временных рядов. При расчете коэффициентов корреляции на основе коротких временных рядов, свойственных фМРТ-данным, возникает стандартная ошибка, что приводит к недостоверным оценкам корреляции. Чем короче временные ряды, тем выше ошибка и, следовательно, выше уровень шума. При этом стоит учитывать, что временные ряды из соседних областей могут влиять друг на друга из-за физической близости изменений в кровотоке. Это приводит к искажению измеряемых корреляций. Также глобальные изменения сигнала, например, из-за общего изменения уровня активности, могут накладываться на локальные сигналы, создавая ложные корреляции. Ввиду перечисленных выше проблем корреляционные графы, построенные на фМРТ-данных, нужно дополнительного обрабатывать для фильтрации шума. В свою очередь, ансамблевый метод, в силу природы его вычисления, как раз помечает незначимые для классификации ребра весом, близким по абсолютному значению к нулю. Это приводит к уменьшению влияния неважной для классификации информации в данных.

В качестве примера визуализации топологии графов, которые строятся с помощью ансамблевого метода, мы приводим усредненную по тестовой выборке матрицу весов ребер в эксперименте на рабочую память (рис. 2). Можно видеть, как некоторые ребра ярко подсвечены цветом, что свидетельствует об их значимости в классификации между двумя состояниями.

Обратим внимание, что в том формате, в котором мы строили ансамблевые графы, их можно также интерпретировать как преобразование над корреляционными графами с применением методов машинного обучения.

В заключение отметим, что в данной работе представлен метод репрезентации данных, основанный на ансамблевом обучении, который показал во всех задачах более высокие результаты по сравнению с наиболее распространенным методом, что позволяет его рекомендовать для проведения анализа фМРТ-данных. Лучшая эффективность классификации позволяет предположить, что с использованием этого метода мы более эффективно определяем функциональные связи между регионами мозга при выполнении когнитивных задач. Мы надеемся, что в будущем, при дальнейшем накоплении таких экспериментальных данных, наш метод даст возможность дальше продвинуться в понимании процессов, протекающих в мозге.

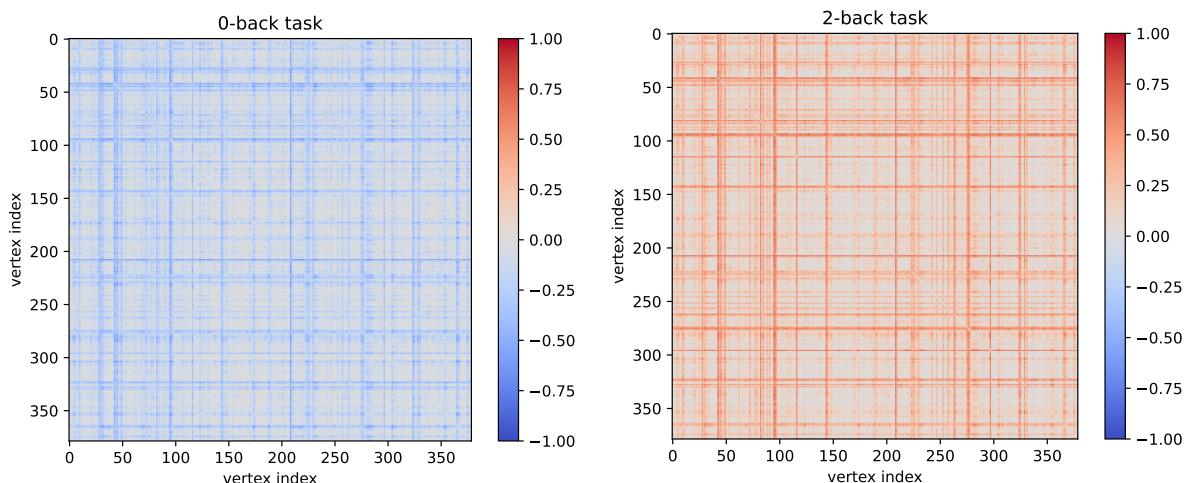


Рис. 2. Усредненные по тестовой выборке матрицы весов ребер для ансамблевых графов в эксперименте на рабочую память. По вертикали и горизонтали расположены индексы вершины, цвет отражает вес ребра (цвет онлайн)

Fig. 2. Test sample averaged matrices of edge weights for ensemble graphs in the working memory experiment. Vertically and horizontally there are vertex indices, the color reflects the edge weight (color online)

## References

1. Heeger DJ, Ress D. What does fMRI tell us about neuronal activity? *Nat. Rev. Neurosci.* 2002;3(2):142–151. DOI: 10.1038/nrn730.
2. Logothetis NK. What we can do, and what we cannot do with fMRI. *Nature.* 2008;453(7197):869–878. DOI: 10.1038/nature06976.
3. Ramzan F, Khan MUG, Rehmat A, Iqbal S, Saba T, Rehman A, Mehmood Z. A deep learning approach for automated diagnosis and multiclass classification of Alzheimer’s disease stages using resting state fMRI and residual neural networks. *J. Med. Syst.* 2019;44(2):37. DOI: 10.1007/s10916-019-1475-2.
4. Arribas JI, Calhoun VD, Adali T. Automatic Bayesian classification of healthy controls, bipolar disorder, and schizophrenia using intrinsic connectivity maps from fMRI data. *IEEE Transactions on Biomedical Engineering.* 2010;57(12):2850–2860. DOI: 10.1109/TBME.2010.2080679.
5. Luo Y, Alvarez TL, Halperin JM, Li X. Multimodal neuroimaging based prediction of adult outcomes in childhood-onset ADHD using ensemble learning techniques. *Neuroimage: Clin.* 2020;26:102238. DOI: 10.1016/j.nicl.2020.102238.
6. Li X, Zhou Y, Dvornek N, Zhang M, Gao S, Zhuang J, Scheinost D, Staib LH, Ventola P, and Duncan JS. BrainGNN: Interpretable brain graph neural network for fMRI analysis. *Med. Image Anal.* 2021;74:102233. DOI: 10.1016/j.media.2021.102233.
7. Wang J, Zuo X, He Y. Graph-based network analysis of resting-state functional MRI. *Front. Syst. Neurosci.* 2010;4:16. DOI: 10.3389/fnsys.2010.00016.
8. Richiardi J, Eryilmaz H, Schwartz S, Vuilleumier P, Van De Ville D. Decoding brain states from fMRI connectivity graphs. *Neuroimage.* 2011;56(2):616–626. DOI: 10.1016/j.neuroimage.2010.05.081.
9. Takerkart S, Auzias G, Thirion B, Ralaivola L. Graph-based inter-subject pattern analysis of fMRI data. *PLoS ONE.* 2014;9(8):e104586. DOI: 10.1371/journal.pone.0104586.
10. Saeidi M, Karwowski W, Farahani FV, Fiok K, Hancock PA, Sawyer BD, Christov-Moore L, Douglas PK. Decoding task-based fMRI data with graph neural networks, considering individual differences. *Brain Sci.* 2022;12(8):1094. DOI: 10.3390/brainsci12081094.
11. Li X, Dvornek NC, Zhou Y, Zhuang J, Ventola P, Duncan JS. Graph neural network for interpreting task-fMRI biomarkers. In: Shen D, Liu T, Peters TM, Staib LH, Essert C, Zhou S, Yap P-T, Khan A, editors. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019. MICCAI 2019. Lecture Notes in Computer Science.* Vol. 11768. Cham: Springer; 2019. P. 485–493. DOI: 10.1007/978-3-030-32254-0\_54.
12. Bessadok A, Mahjoub MA, Rekik I. Graph neural networks in network neuroscience. *IEEE Trans. Pattern Anal. Mach. Intell.* 2023;45(5):5833–5848. DOI: 10.1109/TPAMI.2022.3209686.
13. Gorban AN, Tyukina TA, Pokidysheva LI, Smirnova EV. Dynamic and thermodynamic models of adaptation. *Phys. Life Rev.* 2021;37:17–64. DOI: 10.1016/j.plrev.2021.03.001.
14. Ursino M, Ricci G, Magosso E. Transfer entropy as a measure of brain connectivity: A critical analysis with the help of neural mass models. *Front. Comput. Neurosci.* 2020;14:45. DOI: 10.3389/fncom.2020.00045.
15. Hlinka J, Paluš M, Vejmelka M, Mantini D, Corbetta M. Functional connectivity in resting-state fMRI: Is linear correlation sufficient? *Neuroimage.* 2011;54(3):2218–2225. DOI: 10.1016/j.neuroimage.2010.08.042.
16. Roebroeck A, Formisano E, Goebel R. Mapping directed influence over the brain using Granger causality and fMRI. *Neuroimage.* 2005;25(1):230–242. DOI: 10.1016/j.neuroimage.2004.11.017.
17. Ganaie MA, Hu M, Malik AK, Tanveer M, Suganthan PN. Ensemble deep learning: A review. *Engineering Applications of Artificial Intelligence.* 2022;115:105151. DOI: 10.1016/j.engappai.2022.105151.

18. Mohammed A, Kora R. A comprehensive review on ensemble deep learning: Opportunities and challenges. *Journal of King Saud University Computer and Information Sciences*. 2023;35(2): 757–774. DOI: 10.1016/j.jksuci.2023.01.014.
19. Galar M, Fernandez A, Barrenechea E, Bustince H, Herrera F. A review on ensembles for the class imbalance problem: Bagging-, boosting-, and hybrid-based approaches. *IEEE Trans. Syst., Man, Cybern. C*. 2012;42(4):463–484. DOI: 10.1109/TSMCC.2011.2161285.
20. Nazarenko T, Whitwell HJ, Blyuss O, Zaikin A. Parenclitic and synolytic networks revisited. *Front. Genet.* 2021;12:733783. DOI: 10.3389/fgene.2021.733783.
21. Elam JS, Glasser MF, Harms MP, Sotiroopoulos SN, Andersson JL, Burgess GC, Curtiss SW, Oostenveld R, Larson-Prior LJ, Schoffelen JM, Hodge MR, Cler EA, Marcus DM, Barch DM, Yacoub E, Smith SM, Ugurbil K, Van Essen DC. The Human Connectome Project: A retrospective. *Neuroimage*. 2021;244:118543. DOI: 10.1016/j.neuroimage.2021.118543.
22. Van Essen DC, Smith SM, Barch DM, Behrens TEJ, Yacoub E, Ugurbil K; WU-Minn HCP Consortium. The WU-Minn Human Connectome Project: An overview. *Neuroimage*. 2013;80: 62–79. DOI: 10.1016/j.neuroimage.2013.05.041.
23. Vlasenko D, Zaikin A, Zakharov D. *Ensemble\_graphs\_fmri\_2024* [Data set]. Zenodo. 2024. DOI: 10.5281/zenodo.13764278.
24. Barch DM, Burgess GC, Harms MP, Petersen SE, Schlaggar BL, Corbetta M, Glasser MF, Curtiss S, Dixit S, Feldt C, Nolan D, Bryant E, Hartley T, Footer O, Bjork JM, Poldrack R, Smith S, Johansen-Berg H, Snyder AZ, Van Essen DC; WU-Minn HCP Consortium. Function in the human connectome: Task-fMRI and individual differences in behavior. *Neuroimage*. 2013;80:169–189. DOI: 10.1016/j.neuroimage.2013.05.033.
25. Glasser MF, Sotiroopoulos SN, Wilson JA, Coalson TS, Fischl B, Andersson JL, Xu J, Jbabdi S, Webster M, Polimeni JR, Van Essen DC, Jenkinson M; WU-Minn HCP Consortium. The minimal preprocessing pipelines for the Human Connectome Project. *Neuroimage*. 2013;80:105–124. DOI: 10.1016/j.neuroimage.2013.04.127.
26. Glasser MF, Coalson TS, Robinson EC, Hacker CD, Harwell J, Yacoub E, Ugurbil K, Andersson J, Beckmann CF, Jenkinson M, Smith SM, Van Essen DC. A multi-modal parcellation of human cerebral cortex. *Nature*. 2016;536(7615):171–178. DOI: 10.1038/nature18933.
27. Platt JC. Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods. *Advances in Large Margin Classifiers*. 1999;10(3):61–74.
28. Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks. *arXiv*: 1609.02907. arXiv Preprint; 2016. DOI: 10.48550/arXiv.1609.02907
29. Fukushima K. Visual feature extraction by a multilayered network of analog threshold elements. *IEEE Transactions on Systems Science and Cybernetics*. 1969;5(4):322–333. DOI: 10.1109/TSSC.1969.300225.
30. Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv:1502.03167*. arXiv Preprint; 2015. DOI: 10.48550/arXiv.1502.03167.
31. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*. 2014;15(56): 1929–1958.
32. Xu K, Zhang M, Jegelka S, Kawaguchi K. Optimization of graph neural networks: Implicit acceleration by skip connections and more depth. *arXiv:2105.04550*. arXiv Preprint; 2021. DOI: 10.48550/arXiv.2105.04550.
33. Grattarola D, Zambon D, Bianchi FM, Alippi C. Understanding pooling in graph neural networks. *IEEE Trans. Neural Netw. Learn. Syst.* 2024;35(2):2708–2718. DOI: 10.1109/TNNLS.2022.3190922.



*Власенко Даниил Владимирович* — родился в Краснодаре (2001). Окончил бакалавриат математико-механического факультета Санкт-Петербургского государственного университета (2023) по направлению «Прикладная математика и информатика» и магистратуру Института когнитивных нейронаук ВШЭ (2025). Работает в группе теоретической нейронауки Института когнитивных нейронаук НИУ ВШЭ в должности научного сотрудника. Научные интересы — анализ данных, статистика, наука о сетях, математическое моделирование, нейронауки.

Россия, 101000 Москва, ул. Мясницкая, 20  
Институт когнитивных нейронаук НИУ «Высшая школа экономики»  
E-mail: dvlasenko@hse.ru  
ORCID: 0009-0002-4867-2896  
AuthorID (eLibrary.Ru): 1262749



*Ушаков Вадим Геннадьевич* — родился в Анапе (1977). С отличием окончил физический факультет Московского государственного университета им. М. В. Ломоносова (2001). Работал научным сотрудником в ЦАГИ им. Н. Е. Жуковского и в Центре анализа сложных систем Сеченовского университета. Научные интересы — анализ данных, графовые нейронные сети, статистика, математическое моделирование, стохастические процессы.

Россия, 101000 Москва, ул. Мясницкая, 20  
Институт когнитивных нейронаук НИУ «Высшая школа экономики»  
E-mail: uvadim@mail.ru  
ORCID: 0009-0004-1388-560X  
AuthorID (eLibrary.Ru): 36629



*Заикин Алексей Анатольевич* — родился в Москве (1973). С отличием окончил физический факультет Московского государственного университета им. М. В. Ломоносова (1995). В 1998 году защитил диссертацию на соискание ученой степени кандидата физико-математических наук по направлениям «Радиофизика» и «Акустика». В настоящее время является профессором системной медицины и прикладной математики Института женского здоровья и математического факультета Университетского колледжа Лондона, Великобритания. Область научных интересов: вычислительная и системная медицина, системная биология, теоретическая биофизика, прикладная математика, статистическая физика, нелинейная динамика и стохастическое моделирование в биологии. Является автором более 160 научных публикаций.

Gower Street London, WC1E 6BT, UK  
Institute for Women's Health and Dep. of Mathematics University College London  
E-mail: alexey.zaikin@ucl.ac.uk  
ORCID: 0000-0001-7540-1130  
AuthorID (eLibrary.Ru): 29322



*Захаров Денис Геннадьевич* — родился в Нижнем Новгороде (1976), окончил радиофизический факультет Нижегородского государственного университета им. Н. И. Лобачевского (1999). Защитил диссертацию на соискание ученой степени кандидата физико-математических наук по направлению «Радиофизика» (2005). Более 20 лет работал в Институте прикладной физики РАН. В настоящее время является ведущим научным сотрудником Института когнитивных нейронаук Национального исследовательского университета «Высшая школа экономики». Область научных интересов — теория нелинейных колебаний и волн, нелинейная динамика, моделирование активности спайковых нейронных сетей и когнитивных процессов. Является автором более 100 научных публикаций.

Россия, 101000 Москва, ул. Мясницкая, 20  
Институт когнитивных нейронаук НИУ «Высшая школа экономики»  
E-mail: dgzakharov@hse.ru  
ORCID: 0000-0003-4367-8965  
AuthorID (eLibrary.Ru): 42103