



Известия высших учебных заведений. Прикладная нелинейная динамика. 2023. Т. 31, № 5
Izvestiya Vysshikh Uchebnykh Zavedeniy. Applied Nonlinear Dynamics. 2023;31(5)

Научная статья
УДК 530.182

DOI: 10.18500/0869-6632-003062
EDN: RUEQPM

Классификация мозговой активности при помощи синоптических сетей

Д. В. Власенко¹✉, А. А. Заикин^{2,3}, Д. Г. Захаров¹

¹Национальный исследовательский университет «Высшая школа экономики», Москва, Россия

²Университетский колледж Лондона, Великобритания

³Первый Московский государственный медицинский университет имени И. М. Сеченова, Россия

E-mail: ✉ vlasenko.daniil.vl@gmail.com, alexey.zaikin@ucl.ac.uk, dzakh76@gmail.com

Поступила в редакцию 17.05.2023, принята к публикации 10.07.2023,

опубликована онлайн 21.09.2023, опубликована 29.09.2023

Аннотация. Поскольку мозг — это чрезвычайно сложная гиперсеть взаимодействующих между собой макроскопических подсетей, проведение полномасштабного анализа его активности представляется труднейшей задачей. Тем не менее эту задачу можно существенно упростить, анализируя соответствие различных паттернов макроскопической активности мозга, например, на снимках функциональной магнитно-резонансной томографии (фМРТ), выполнению тех или иных когнитивных задач или патологическим состояниям. *Цель* данной работы — предложить и протестировать метод представления данных фМРТ в виде графов, которые отражают в себе полезную для последующей классификации информацию о взаимосвязях активности областей мозга. *Методы.* В данной работе исследуется возможность применения синоптических сетей в анализе мозговой активности. В частности, был предложен метод построения графа, вершины которого отражают значения вокселей фМРТ, а ребра и веса ребер отражают взаимосвязи между вокселями фМРТ. *Результаты и Заключение.* На основе классификации фМРТ данных по характеристикам графов была показана эффективность метода на основе синоптических сетей в выявлении и передаче важной для классификации информации при построении графов.

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

Благодарности. Исследование осуществлено в рамках Программы фундаментальных исследований НИУ ВШЭ с использованием суперкомпьютерного комплекса НИУ ВШЭ.

Для цитирования: Власенко Д. В., Заикин А. А., Захаров Д. Г. Классификация мозговой активности при помощи синоптических сетей // Известия вузов. ПНД. 2023. Т. 31, № 5. С. 661–669. DOI: 10.18500/0869-6632-003062. EDN: RUEQPM

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

Classification of brain activity using synolitic networks

D. V. Vlasenko¹✉, A. A. Zaikin^{2,3}, D. G. Zakharov¹

¹National Research University Higher School of Economics, Moscow, Russia

²University College London, UK

³Sechenov First Moscow State Medical University, Russia

E-mail: ✉vlasenko.daniil.vl@gmail.com, alexey.zaikin@ucl.ac.uk, dzakh76@gmail.com

Received 17.05.2023, accepted 10.07.2023, available online 21.09.2023, published 29.09.2023

Abstract. Because the brain is an extremely complex hypernet of interacting macroscopic subnetworks, full-scale analysis of brain activity is a daunting task. Nevertheless, this task can be greatly simplified by analysing the correspondence between various patterns of macroscopic brain activity, for example, through functional magnetic resonance imaging (fMRI) scans, and the performance of particular cognitive tasks or pathological states. The *purpose* of this work is to present and validate a methodology of representing fMRI data in the form of graphs that effectively convey valuable insights into the interconnectedness of brain region activity for subsequent classification purposes. *Methods.* This paper explores the application of synolitic networks in the analysis of brain activity. We propose a method for constructing a graph, the vertices of which reflect fMRI voxels' values, and the edges and edge weights reflect the relationships between fMRI voxels. *Results and Conclusion.* Based on the classification of fMRI data by graph properties, the effectiveness of the method in conveying important information for classification in the construction of graphs was shown.

Keywords: cognitive processes, functional magnetic resonance imaging, synolitic networks, graphs, classification, machine learning.

Acknowledgements. This article is an output of a research project implemented as part of the Basic Research Program at the National Research University HSE using the supercomputer complex of the National Research University HSE.

For citation: Vlasenko DV, Zaikin AA, Zakharov DG. Classification of brain activity using synolitic networks. *Izvestiya VUZ. Applied Nonlinear Dynamics.* 2023;31(5):661–669. DOI: 10.18500/0869-6632-003062

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

Введение

Функциональная магнитно-резонансная томография или фМРТ — разновидность магнитно-резонансной томографии, которая проводится с целью измерения изменений в токе крови, вызванных нейронной активностью головного мозга [1]. В основе этого метода лежит предположение, что мозговой кровоток и активность нейронов связаны между собой: при увеличении активности нейронов приток крови к содержащей их области увеличивается, при падении — уменьшается. Таким образом, фМРТ позволяет определить активацию макроскопических областей головного мозга (с примерным линейным размером в несколько миллиметров) во время его функционирования под влиянием различных факторов и при различных патологических состояниях. На сегодняшний день это один из самых используемых инструментов исследования когнитивных процессов в мозге и активно развивающихся и общепринятых методов нейровизуализации (см., например, [2]). Так, при нейровизуализации изображение строится в виде сетки точек (вокселей) в объеме, которое затем преобразуется в свернутое двумерное многообразие в трехмерном пространстве [3], что позволяет отразить активность различных отделов головного мозга.

Поскольку мозг — это чрезвычайно сложная гиперсеть взаимодействующих между собой макроскопических подсетей, проведение полномасштабного анализа его активности представляется труднейшей задачей. Тем не менее эту задачу можно существенно упростить, анализируя соответствие различных паттернов макроскопической активности мозга, например, на снимках фМРТ,

выполнению тех или иных когнитивных задач или патологическим состояниям. В частности, один из действенных методов исследования функциональной роли областей мозга основывается на построении модели классификации между двумя разными режимами мозговой активности и оценки того, как сильно изменяется точность классификации при использовании доступных или недоступных данных об активности конкретной области мозга для модели [4]. При решении подобных задач наиболее эффективными оказываются графовые нейронные сети [4, 5]. Для построения графов таких сетей в вершинах отражают отобранные признаки данных, а веса ребер показывают взаимосвязи между признаками. К настоящему моменту в задачах классификации мозговой активности уже используются методы представления фМРТ данных в виде графов (см., например, работы [4, 6, 7]). Но для отражения взаимосвязей между областями мозга в таких графах используют довольно простые классические методы, например, линейную корреляцию Пирсона или частную корреляцию [4, 7]. Несмотря на то, что эти методы выявляют скоррелированность признаков, такая корреляция, сама по себе, не несет полезной информации для классификации. В этой статье мы предлагаем устранить этот недостаток и доработать методы репрезентации данных. Таким образом, цель нашей работы — предложить и протестировать метод представления фМРТ данных в виде графов, которые отражали бы значимую для последующей классификации информацию о взаимосвязях между областями мозга. Этот метод мы назвали синолитическим, так как он был вдохновлен синолитическими сетями, позволяющими применять методы анализа графов к многомерным сложным данным [8]. Здесь мы рассматриваем простейший случай, при котором будем различать только два режима мозга, или другими словами, когда стоит задача бинарной классификации. Такая классификация может проводиться как на основе характеристик [6] графов, так и на основе их топологии [4]. В этой работе мы концентрируемся на классификации на основе характеристик графов.

1. Методы

1.1. Векторизация фМРТ данных. Результатом сканирования мозга испытуемого, после предварительной обработки данных, является состоящее из вокселей объемное трехмерное изображение, изменяющееся во времени. Воксель — элемент объемного растрового изображения, аналог пикселя в двухмерном изображении. Значение вокселя фМРТ в конкретный момент времени отражает объем крови (уровень оксигенации) в данной области мозга.

Множество данных фМРТ будем обозначать Ω , а множество режимов мозговой активности — $\Sigma = \{I, II\}$. Пусть $(\Omega, \tilde{\Sigma}) = \{(\omega_n, \sigma_n)\}_n$ — конечная выборка из (Ω, Σ) , необходимая для построения и обучения метода. Представим снимок фМРТ $\omega \in \Omega$ в памяти компьютера как четырехмерный массив a действительных неотрицательных чисел, где первые три индекса x, y, z фиксируют положение вокселя фМРТ, а четвертый индекс t фиксирует время. Таким образом, через a_{xyzt} обозначается воксель с индексами x, y, z в момент времени t , а через a_{xyz} — все значения вокселя с индексами x, y, z . Далее, в случае необходимости индексации вокселей одним числом, полагаем, что все воксели в пространстве проиндексированы в порядке их представления в изображении.

1.2. Метод представления фМРТ данных в виде графа. Каждая вершина в графе отражает воксель в фМРТ данных, ребра между вершинами и веса ребер отражают взаимосвязи между вокселями. На основе массива a построим граф $g = (V, E, R, W)$, где $V = \{v_i\}_i$ — множество вершин, $E = \{e_{ij}\}_{ij}$ — множество неориентированных ребер, $R = \{r_i\}_i$ — множество значений вершин, $W = \{w_{ij}\}_{ij}$ — множество весов ребер, v_i — вершина, отражающая воксель i , e_{ij} — ребро, отражающее связь между вокселями i и j , r_i — значение вершины v_i , w_{ij} — вес ребра e_{ij} .

Как было сказано выше, вершина v_i соответствует вокселю i , и у нее есть значение r_i . Фактически, в нашем случае, воксель i — это временной ряд с множеством значений. Для вычисления r_i в методе используется статистика T , которая преобразовывает все значения вокселя в одно число. Таким образом, можно ввести новый трехмерный массив $a^T = T(a)$, то есть для $\forall x, y, z$ $a_{xyz}^T = T(a_{xyz})$. Значения массива a^T и используются в качестве значений вершин R . Сама статистика T выбирается исходя из результатов тестирования метода. Например, это может быть среднее значение временного ряда или разница квантилей разного уровня.

Поскольку веса ребер отражают взаимосвязи между вокселями при разных режимах работы мозга, одной из наиболее важных задач является метод вычисления значения весов ребер W . Определим w_{ij} как

$$w_{ij} = P(\sigma = II | r_i, r_j) - P(\sigma = I | r_i, r_j). \quad (1)$$

Другими словами, вес ребра w_{ij} равен разнице вероятностей режимов работы мозга при условии значений инцидентных ребру вершин. При этом веса ребер могут принимать значения только от -1 до 1 . Соответственно, если вес ребра — отрицательный ($w_{ij} < 0$), то ребро e_{ij} несет в себе информацию о том, что наиболее вероятным является режим мозга I. Если вес ребра — положительный ($w_{ij} > 0$), то данное ребро несет в себе информацию о том, что наиболее вероятным является режим II. Чем больше абсолютное значение веса ребра $|w_{ij}|$, тем больше информации для классификации несет в себе ребро e_{ij} . Соответственно, чем ближе к нулю абсолютное значение веса ребра $|w_{ij}|$, тем меньше информации оно несет.

На практике для вычисления таких вероятностей мы будем использовать вероятностные классификаторы $Cl_{ij} : \{\sigma | (r_i, r_j), \{(r_i^n, r_j^n)\}_n, \{\sigma_n\}_n\} \rightarrow [0, 1]$, которые обучаются на имеющейся выборке $(\tilde{\Omega}, \tilde{\Sigma})$. Перепишем формулу (1) так:

$$w_{ij} = Cl_{ij}(\sigma = II | (r_i, r_j), \{(r_i^n, r_j^n)\}_n, \{\sigma_n\}_n) - Cl_{ij}(\sigma = I | (r_i, r_j), \{(r_i^n, r_j^n)\}_n, \{\sigma_n\}_n). \quad (2)$$

Таким образом, для каждого ребра e_{ij} требуется обучить свой вероятностный классификатор Cl_{ij} для последующего вычисления весов ребер W . Выбор типа классификаторов $\{Cl_{ij}\}_{ij}$ мы обсуждаем в разделе 2.2.

1.2.1. Топология графа. Выбрав метод вычисления значений вершин R и значений весов ребер W , перейдем к описанию топологии графа. Как правило, при построении синоптических сетей строится полный граф, что позволяет учитывать взаимодействия между всеми элементами сети. В случае данных фМРТ вершин в графе оказывается слишком много. Это в свою очередь приводит к большому количеству ребер при построении полного графа, и метод требует огромной вычислительной мощности. Например, при разрешении фМРТ $100 \times 100 \times 100$ вокселей, в полном графе будет 1 000 000 вершин и 499 999 500 000 ребер. При этом для каждого ребра e_{ij} необходимо обучать свой классификатор Cl_{ij} .

Вместо полного графа мы предлагаем построить граф-сетку, то есть такой граф, в котором ребра связывают соседние воксели. Два вокселя считаются соседними, если у них есть общая сторона, ребро или угол. То есть внутренний воксель (xyz) связан с вокселями из множества $\{(\hat{x}\hat{y}\hat{z}) : \hat{x} \in \{x-1, x, x+1\}, \hat{y} \in \{y-1, y, y+1\}, \hat{z} \in \{z-1, z, z+1\}, (\hat{x}\hat{y}\hat{z}) \neq (xyz)\}$. При такой топологии графа ресурсные затраты сокращаются с $O(n^2)$ до $O(n)$, где n — число вокселей.

Поскольку в фМРТ изображается не только мозг, но и пространство вокруг головы испытуемого, следует удалить из графа ребра, которые инцидентны с вершинами, значения которых ниже порогового значения r . Такие ребра не несут полезной информации для классификации, так как связаны с вершинами, ассоциированными с вокселями, находящимися вне мозга. Также из

графа следует удалить ребра, абсолютное значение веса которых ниже порогового значения w . Ребра, в которых $|w| \approx 0$, могут появиться только в двух случаях. В первом случае они могут быть связаны с вершинами, ассоциированными с вокселями, которые неактивны ни в одном из двух режимов мозговой активности. Во втором — они могут быть связаны с вершинами, ассоциированными с вокселями, которые в равной степени принимают участие в работе мозга в обоих режимах, поэтому связывающие их ребра не несут полезной информации для классификации. Таким образом, из графа g удаляются ребра из множества $\{e_{ij} : r_i < r | r_j < r | |w_{ij}| < w\}_{ij}$. Параметр r выбирается исходя из того, какое значение аппарат фМРТ присваивает вокселям вне мозга. Как правило, это положительное близкое к нулю число. Параметр w влияет на значимость ребер, которые остаются в графе g . Чем больше w , тем больше ребер будет удалено.

В результате этих процедур у каждого внутреннего вокселя остается не более 26 соседей. Соответственно степени вершин в графе не больше 26.

1.3. Классификация на основе характеристик графа. После построения графа g вычисляются его характеристики $\{f_u\}_u = \{F_u(g)\}_u$. Таким образом, от графа остается последовательность чисел $\{f_u\}_u$. В качестве характеристик графа $\{F_u(g)\}_u$ могут выступать среднее весов ребер, дисперсия весов ребер, количество компонент связности и так далее. На основе характеристик $\{f_u\}_u$ происходит итоговая классификация фМРТ данных ω с помощью классификатора Cl , который был обучен на выборке $\{\{f_u^n\}_u\}_n$.

Характеристики $\{F_u(g)\}_u$ выбираются по результатам работы метода на тренировочной выборке. Выбор характеристик $\{F_u(g)\}_u$ и типа классификатора Cl мы обсудим в разделе 2.2.

2. Результаты

2.1. Данные. Метод был протестирован на данных исследования [9], при котором данные фМРТ регистрировались во время просмотра испытуемыми изображений объектов (эксперимент с наблюдением) или воображения объектов с закрытыми глазами (эксперимент с воображением). В эксперименте с наблюдением использовались 1200 изображений из 150 категорий объектов (по 8 изображений на каждую категорию). Каждое изображение демонстрировалось испытуемому один раз. Для каждого испытуемого было проведено 24 цикла фМРТ сканирования. Все изображения были взяты из ImageNet (<http://www.image-net.org>, выпуск осень 2011), крупномасштабной базы данных изображений. Во время эксперимента с наблюдением испытуемые выполняли задание на повторение изображения в обратном порядке (по 5 попыток в каждом цикле), демонстрировалось 55 изображений в цикле. В эксперименте с воображением испытуемые должны были визуально представлять последовательность из 25 объектов. Каждый объект принадлежал одной из 50 категорий. Для каждого испытуемого было проведено 20 циклов фМРТ сканирования.

Фактически, в рамках данного эксперимента можно выделить два режима, в которых функционирует мозг испытуемого. Первый режим наблюдается, когда испытуемому последовательно показывают 55 блоков, 50 из которых — это различные между собой изображения, 5 — повторяют предшествующую картинку. Если испытуемый видит повторную картинку, он должен нажать на кнопку. Во втором режиме мозг испытуемого находится, когда его просят последовательно представить 25 объектов. После представления каждого объекта испытуемого просят оценить по пятибалльной шкале степень ясности образа, который он представил, с помощью нажатия соответствующих кнопок. В рамках данной работы мы оцениваем эффективность нашего метода по классификации двух режимов мозга по фМРТ: при эксперименте с наблюдением и эксперименте с воображением.

Таблица 1. Выборка, разделение на тренировочную и тестовую части. Режим зрительного восприятия обозначен как «seen», режим представления — как «imagined»
 Table 1. Sample, division into training and test parts. The visual mode is marked as “seen”, the imagined mode is marked as “imagined”

	seen		imagined		
	training	test	training	test	
sub-01	17	7	14	6	44
sub-02	17	7	14	6	44
sub-03	17	7	14	6	44
sub-04	17	7	14	6	44
sub-05	16	8	14	6	44
	84	36	70	30	220
	120		100		

В сборе данных участвовало 5 испытуемых, у каждого было просканировано в разные дни 44 фМРТ в двух режимах, из которых 24 в режиме зрительного восприятия и 20 в режиме представления. Последовательности изображений и объектов у одного и того же испытуемого были различны между собой. Выборка была разделена таким образом, что 30% выборки каждого режима для каждого индивида попадает в тестовую часть и 70% в обучающую. В табл. 1 представлена информация о выборке фМРТ и о ее разделении на тестовую и обучающую части.

Особенностью данных является то, что они получены для 5 испытуемых, и для каждого из них они разбиты на тестовую и тренировочную части. Такой подход не позволяет утверждать, что эффективность метода была протестирована на независимых данных. Однако он позволяет проверить, возможно ли предсказать поведение человека, на котором метод обучался.

Оригинальный размер вокселя в фМРТ данных был $3 \times 3 \times 3 \text{ мм}^3$, для уменьшения затрат вычислительных ресурсов и сглаживания индивидуальных особенностей строения мозга качество фМРТ данных было понижено до $10 \times 10 \times 10 \text{ мм}^3$.

2.2. Выбор и настройка параметров. В качестве статистики T для вычисления a^T были протестированы следующие статистики: среднее значение временного ряда, медианное значение временного ряда, минимальное значение временного ряда, максимальное значение временного ряда, разница максимального и минимального значений временного ряда, квантиль временного ряда уровня 10%, квантиль временного ряда уровня 90%, разница квантилей временного ряда уровней 90% и 10%. Лучший результат Метода был получен, когда в качестве статистики T выбиралось медианное значение.

В качестве классификаторов $\{Cl_{ij}\}_{ij}$ для подсчета весов ребер W были использованы вероятностные классификаторы из библиотеки scikit-learn [10]. В их основе лежит метод опорных векторов с радиально-базисным ядром со стандартными для этого метода параметрами. Классификатор Cl для итоговой классификации на основе характеристик графов был также взят из библиотеки scikit-learn. Он построен на базе метода опорных векторов с радиально-базисным ядром со стандартными для этого метода параметрами.

В качестве характеристик графов $\{F_u(g)\}_u$ выбраны среднее значение весов ребер, квантиль весов ребер уровня 10%, квантиль весов ребер уровня 90% и стандартное отклонение весов ребер. Графики распределений этих характеристик для всей выборки, когда T — медианное значение вокселя, $r = 1$, $w = 0$, представлены на рис. 1. Как можно заметить, распределения характеристик при разных режимах мозговой активности отличаются друг от друга смещением, что должно привести к успешной классификации.

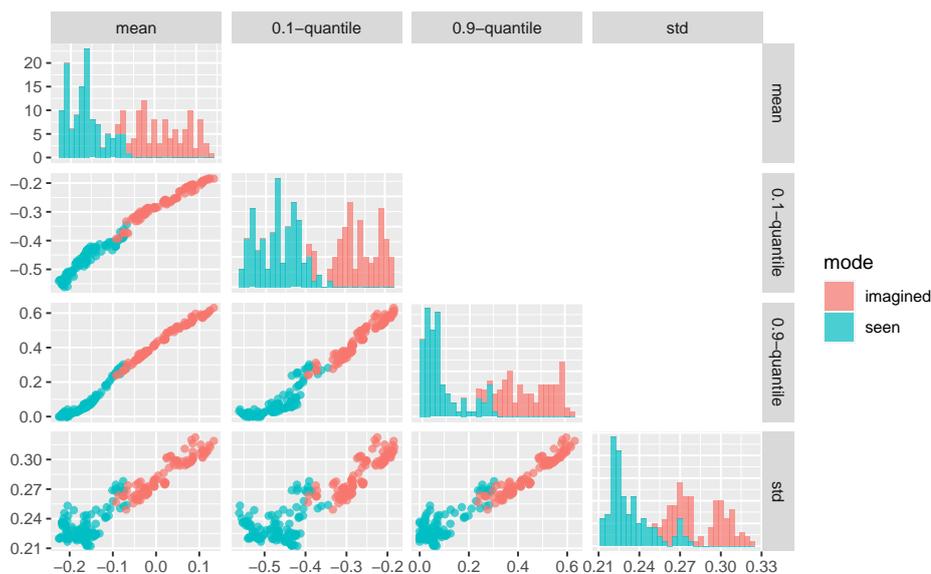


Рис. 1. Распределения характеристик графов для всей выборки фМРТ, когда в качестве статистики T было выбрано медианное значение вокселя ($r = 1$, $w = 0$). Режим зрительного восприятия обозначен как «seen», режим представления — как «imagined» (цвет онлайн)

Fig. 1. Distributions of the properties of graphs for the entire fMRI sample when T is the median value of voxel ($r = 1$, $w = 0$). The visual mode is marked as “seen”, the imagined mode is marked as “imagined” (color online)

2.3. Точность классификации. Точность метода при всех описанных выше различных способах вычисления a^T оказалась очень высокой: она не опускалась ниже 90%. Лучший результат классификации был получен, когда статистика T была выбрана как медианное значение временного ряда ($r = 1$, $w = 0.2$, матрица классификации представлена в табл. 2). В этом случае точность составила 98.5%. Это позволяет рекомендовать данную статистику для использования в последующих исследованиях.

Таблица 2. Матрица классификации для случая, когда в качестве статистики T было выбрано медианное значение вокселя ($r = 1$, $w = 0.2$). Режим зрительного восприятия обозначен как «seen», режим представления — как «imagined»

Table 2. The classification matrix for the case when the median voxel value was chosen as function T ($r = 1$, $w = 0.2$). The visual mode is marked as “seen”, the imagined mode is marked as “imagined”

	seen	imagined
seen	36	0
imagined	1	29

Заключение

В данной работе реализован и протестирован метод представления фМРТ данных в виде синолитических графов. Классификация на основе характеристик графа показала высокую точность, из чего можно сделать вывод об эффективности метода в передаче важной для классификации информации при построении графов. Также была продемонстрирована эффективность синолитических сетей в анализе данных о мозге, и предложен новый метод вычисления связности областей мозга, который, в отличие от классических методов подсчета корреляции, несет полезную для последующей классификации информацию. Фактически мы показали, что классификация может проводиться уже на основе одних только весов ребер. Наилучшие результаты были достигнуты при использовании статистики T в виде медианного значения временного ряда.

Дальнейшее развитие метода предполагает предшествующую классификации кластеризацию вокселей и связывание вершин не с вокселями, а с множествами соседних вокселей. Также есть возможность сохранять большее количество информации, которую несет в себе временной ряд a_{xyz} . Для этого в методе предполагается использовать не одну функцию T при вычислении значений вершин R , а множество функций $\{T_k\}_k$. Тогда вершина в графе будет содержать в себе несколько значений, что должно привести к улучшению получаемых результатов.

References

1. Ogawa S, Lee TM, Kay AR, Tank DW. Brain magnetic resonance imaging with contrast dependent on blood oxygenation. Proceedings of the National Academy of Sciences of the United States of America. 1990;87(24):9868–9872. DOI: 10.1073/pnas.87.24.9868.
2. Singleton MJ. Functional magnetic resonance imaging. Yale J. Biol. Med. 2009;82(4):233.
3. Gao JS, Huth AG, Lescroart MD, Gallant JL. Pycortex: an interactive surface visualizer for fMRI. Frontiers in Neuroinformatics. 2015;9:23. DOI: 10.3389/fninf.2015.00023.
4. 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 PT, Khan A, editors. Medical Image Computing and Computer Assisted Intervention – MICCAI 2019. MICCAI 2019. Vol. 11678 of Lecture Notes in Computer Science. Cham: Springer; 2019. P. 485–493. DOI: 10.1007/978-3-030-32254-0_54.
5. Saueressig C, Berkley A, Munbodh R, Singh R. A joint graph and image convolution network for automatic brain tumor segmentation. In: Crimi A, Bakas S, editors. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. BrainLes 2021. Vol. 12962 of Lecture Notes in Computer Science. Cham: Springer; 2022. P. 356–365. DOI: 10.1007/978-3-031-08999-2_30.
6. Anderson A, Cohen MS. Decreased small-world functional network connectivity and clustering across resting state networks in schizophrenia: an fMRI classification tutorial. Frontiers in Human Neuroscience. 2013;7:520. DOI: 10.3389/fnhum.2013.00520.
7. Kim BH, Ye JC. Understanding graph isomorphism network for rs-fMRI functional connectivity analysis. Frontiers in Neuroscience. 2020;14:630. DOI: 10.3389/fnins.2020.00630.
8. Nazarenko T, Whitwell HJ, Blyuss O, Zaikin A. Parenclitic and synolytic networks revisited. Frontiers in Genetics. 2021;12:733783. DOI: 10.3389/fgene.2021.733783.
9. Horikawa T, Kamitani Y. Generic Object Decoding (fMRI on ImageNet) [Electronic resource]. OpenNeuro. 2019. No. ds001246. DOI: 10.18112/openneuro.ds001246.v1.2.1.
10. Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Blondel M, Prettenhofer P, Weiss R, Dubourg V, Vanderplas J, Passos A, Cournapeau D, Brucher M, Perrot M, Duchesnay É. Scikit-learn: Machine learning in Python. Journal of Machine Learning Research. 2011;12(85): 2825–2830.



Власенко Даниил Владимирович — родился в Краснодаре (2001). Окончил математико-механический факультет Санкт-Петербургского государственного университета (2023) по направлению «Прикладная математика и информатика», кафедра статистического моделирования. Стажер-исследователь Центра биоэлектрических интерфейсов НИУ ВШЭ. Научные интересы — анализ данных, статистика, наука о сетях, математическое моделирование, нейронауки.

Россия, 101000 Москва, ул. Мясницкая, 20
Центр биоэлектрических интерфейсов НИУ «Высшая школа экономики»
E-mail: vlasenko.daniil.vl@gmail.com
ORCID: 0009-0002-4867-2896

Заикин Алексей Анатольевич — родился в Москве (1973). С отличием окончил физический факультет МГУ им. М. В. Ломоносова (1995). Защитил диссертацию на соискание ученой степени кандидата физико-математических наук по направлениям радиофизика и акустика (1998). Профессор системной медицины и прикладной математики Института женского здоровья и математического факультета Университетского колледжа Лондона (Великобритания), заместитель директора Центра анализа сложных систем Первого Московского государственного медицинского университета имени И. М. Сеченова. Область научных интересов: вычислительная и системная медицина, системная биология, теоретическая биофизика, прикладная математика, статистическая физика, нелинейная динамика и стохастическое моделирование в биологии. Имеет более 160 научных публикаций.



Gower Street London, WC1E 6BT, UK
Institute for Women's Health and Dep. of Mathematics University College London
Россия, 119991 Москва, ул. Трубецкая, д. 8, стр. 2
Центр анализа сложных систем, Первый Московский государственный
медицинский университет имени И. М. Сеченова
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 НИУ «Высшая школа экономики». Область научных интересов — теория нелинейных колебаний и волн, нелинейная динамика, моделирование активности спайковых нейронных сетей и когнитивных процессов. Имеет 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