

Перевод на английский язык <https://vavilov.elpub.ru/jour>

## Сверточные нейронные сети для классификации по данным ЭЭГ здоровых людей, практикующих или не практикующих медитацию

С. Фу<sup>1</sup>, С.С. Таможников<sup>2</sup>, А.Е. Сапрыгин<sup>2, 3</sup>, Н.А. Истомина<sup>1</sup>, Д.И. Клемешова<sup>3</sup>, А.Н. Савостьянов<sup>1, 2, 3</sup> 

<sup>1</sup> Новосибирский национальный исследовательский государственный университет, Новосибирск, Россия

<sup>2</sup> Научно-исследовательский институт нейронаук и медицины, Новосибирск, Россия

<sup>3</sup> Федеральный исследовательский центр Институт цитологии и генетики Сибирского отделения Российской академии наук, Новосибирск, Россия

 a-sav@mail.ru

**Аннотация.** В настоящее время разработка объективных методик для оценки уровня стресса является чрезвычайно актуальной задачей прикладной нейронауки. Анализ электроэнцефалограммы (ЭЭГ), записанной в условиях выполнения заданий на самоконтроль поведения, может служить основой для разработки тестовых методик, позволяющих классифицировать людей по уровню стресса. Хорошо известно, что одним из следствий медитационной практики является выработка у участников навыков произвольного контроля над собственным ментальным состоянием за счет повышенной концентрации внимания на самом себе. На фоне медитационной практики часто происходит снижение общего уровня тревожности и стресса. Целью нашего исследования было разработать, обучить и протестировать сверточную нейронную сеть, способную классифицировать людей на группы участвующих или не участвующих в медитационной практике на основе анализа вызванных потенциалов головного мозга, записанных при выполнении заданий парадигмы стоп-сигнал. Были разработаны четыре архитектуры неглубоких сверточных сетей, которые были обучены и протестированы на выборке из 100 человек (51 медитатор и 49 не-медитатор). В дальнейшем все структуры были дополнительно протестированы на независимой выборке в 25 человек. Установлено, что структура, использующая одномерный сверточный слой, который объединяет слой и двуслойную полностью подключенную сеть, показала наилучшие результаты работы в имитационных тестах. Однако эта модель была часто подвержена переобучению из-за ограничения размера отображения набора данных. Явление переобучения было смягчено при помощи изменения структуры и масштаба модели, параметров сети инициализации, регуляризации, случайной деактивации (dropout) и гиперпараметров скрининга перекрестной проверки. В итоге нами получена модель, которая показала 82 % точность в классификации людей на подгруппы. Можно ожидать, что использование таких моделей окажется эффективным методом для оценки уровня стресса и предрасположенности к тревожным и депрессивным расстройствам в других группах испытуемых.

Ключевые слова: сверточные нейронные сети; ЭЭГ; вызванные потенциалы мозга; медитация; парадигма стоп-сигнал.

**Для цитирования:** Фу С., Таможников С.С., Сапрыгин А.Е., Истомина Н.А., Клемешова Д.И., Савостьянов А.Н. Сверточные нейронные сети для классификации по данным ЭЭГ здоровых людей, практикующих или не практикующих медитацию. *Вавиловский журнал генетики и селекции*. 2023;27(7):851-858. DOI 10.18699/VJGB-23-98

## Convolutional neural networks for classifying healthy individuals practicing or not practicing meditation according to the EEG data

X. Fu<sup>1</sup>, S.S. Tamozhnikov<sup>2</sup>, A.E. Saprygin<sup>2, 3</sup>, N.A. Istomina<sup>1</sup>, D.I. Klemeshova<sup>3</sup>, A.N. Savostyanov<sup>1, 2, 3</sup> 

<sup>1</sup> Novosibirsk State University, Novosibirsk, Russia

<sup>2</sup> Scientific Research Institute of Neurosciences and Medicine, Novosibirsk, Russia

<sup>3</sup> Institute of Cytology and Genetics of the Siberian Branch of the Russian Academy of Sciences, Novosibirsk, Russia

 a-sav@mail.ru

**Abstract.** The development of objective methods for assessing stress levels is an important task of applied neuroscience. Analysis of EEG recorded as part of a behavioral self-control program can serve as the basis for the development of test methods that allow classifying people by stress level. It is well known that participation in meditation practices leads to the development of skills of voluntary self-control over the individual's mental state due to an increased concentration of attention to themselves. As a consequence of meditation practices, participants can reduce overall anxiety and stress levels. The aim of our study was to develop, train and test a convolutional neural network capable of classifying individuals into groups of practitioners and non-practitioners of meditation by analysis of event-related brain potentials recorded during stop-signal paradigm. Four non-deep convolutional network architectures were developed, trained and tested on samples of 100 people (51 meditators and 49 non-meditators). Subsequently,

all structures were additionally tested on an independent sample of 25 people. It was found that a structure using a one-dimensional convolutional layer combining the layer and a two-layer fully connected network showed the best performance in simulation tests. However, this model was often subject to overfitting due to the limitation of the display size of the data set. The phenomenon of overfitting was mitigated by changing the structure and scale of the model, initialization network parameters, regularization, random deactivation (dropout) and hyperparameters of cross-validation screening. The resulting model showed 82 % accuracy in classifying people into subgroups. The use of such models can be expected to be effective in assessing stress levels and inclination to anxiety and depression disorders in other groups of subjects.

Key words: convolutional neural networks; EEG; event-related brain potentials; meditation; stop-signal paradigm.

**For citation:** Fu X., Tamozhnikov S.S., Saprygin A.E., Istomina N.A., Klemeshova D.I., Savostyanov A.N. Convolutional neural networks for classifying healthy individuals practicing or not practicing meditation according to the EEG data. *Vavilovskii Zhurnal Genetiki i Seleksii = Vavilov Journal of Genetics and Breeding*. 2023;27(7):851-858. DOI 10.18699/VJGB-23-98

## Введение

Стресс – одна из наиболее распространенных проблем в современном обществе; поиск эффективных способов оценки уровня стресса важен для своевременной диагностики риска возникновения психических и психосоматических расстройств (Kuh et al., 2003; Кузнецова и др., 2016). Большинство психологических методов оценки уровня стресса основано на использовании опросников, при заполнении которых респондент отвечает на вопросы, касающиеся его субъективного самочувствия. Слабым звеном такого подхода считается высокая вероятность неверных самооценок, возникающая либо вследствие нежелания человека сообщать о своих проблемах, либо как результат низкой способности распознать изменения в собственном состоянии (Iwata, Higuchi, 2000; McCrae et al., 2000). Возможным решением этой проблемы является разработка объективных подходов к диагностике психических черт или состояний, основанных на анализе мозговых сигналов, таких как фМРТ или ЭЭГ.

Медитация – система особых ментальных практик, направленных на установление произвольного контроля над своими собственными психическими состояниями. Хотя медитация изначально возникает как элемент религиозных практик, особенно распространенных в восточных религиях, в настоящее время этот феномен вызывает большой интерес среди ученых. Медитация рассматривается как основа для создания неинвазивных, немедикаментозных техник, позволяющих снизить риск широкого ряда психических или психосоматических заболеваний. В ряде исследований показано, что медитация оказывает множество положительных эффектов на психическое здоровье, включая общее снижение стресса и уровня предрасположенности к депрессии (Chiesa et al., 2011; Saeed et al., 2019). При анализе ЭЭГ, регистрируемой в условиях распознавания эмоциональных стимулов, были выявлены достоверные эффекты медитации на состояние головного мозга человека (Aftanas, Golosheykin, 2005; Atchley et al., 2016; Savostyanov et al., 2020). Поэтому анализ ЭЭГ у людей, занимающихся либо не занимающихся медитационной практикой, может быть рассмотрен как подход, позволяющий разработать методики оценки уровня стресса.

Экспериментальным методом, позволяющим оценить способность человека произвольно управлять собственными движениями в условиях изменяющейся внешней среды, является стоп-сигнал парадигма (ССП) (Logan, Cowan, 1984; Vand et al., 2003). СПП позволяет оценить

баланс двух процессов – активации и торможения поведения в условиях дефицита времени для принятия решений. В некоторых исследованиях СПП рассматривается как эффективный метод для диагностики уровня личностной тревожности и предрасположенности к депрессии (Hsieh et al., 2021; Зеленских и др., 2022). Можно предположить, что динамика мозговой активности в условиях СПП будет служить маркером, отличающим друг от друга людей, участвующих либо не участвующих в медитационной практике.

Искусственная нейронная сеть – это развивающаяся технология, основанная на машинном обучении, которая широко используется в различных областях. По сравнению с другими традиционными методами машинной классификации, такими как линейный дискриминантный анализ и алгоритм *k*-ближайшего соседа, искусственные нейронные сети дают более точные результаты классификации людей в соответствии с их поведенческими и нейрофизиологическими характеристиками (Khosla et al., 2020). Кроме того, по сравнению с машиной опорных векторов искусственная нейронная сеть легче справляется с задачами множественной классификации, обеспечивая удобство для дальнейших исследований, а также более эффективную подгонку нелинейных сложных взаимосвязей.

Целью нашего исследования были разработка, обучение и тестирование искусственной нейронной сети, позволяющей на основе анализа вызванных потенциалов в парадигме стоп-сигнал классифицировать людей по критерию их участия в медитативных практиках. Мы предполагаем, что созданная таким образом нейронная сеть будет в дальнейшем способна оценить индивидуальный уровень стресса и склонности к тревожно-депрессивным расстройствам.

## Методы экспериментального исследования

**Испытуемые.** Группа людей, практикующих медитацию саматха (другое название «медитация осознанности»), была обследована в июле–августе 2018 г. на базе Байкальского медитационного центра ([www.geshe.ru/](http://www.geshe.ru/)). Экспериментальная группа включала 51 здорового праворукого участника от 25 до 66 лет (32 мужчины; средний возраст 41.0, SD = 8.3), практикующего медитацию в течение 5–15 лет. Контрольная группа была обследована в октябре–ноябре 2019 г. на базе медицинского колледжа пос. Хандыга, Томпонский район Республики Саха (Якутия), и включала 49 здоровых праворуких участников от 22

до 58 лет (22 мужчины; средний возраст 38.0, SD = 8.3), никогда не участвовавших в практиках медитации или йоги.

Протокол исследования одобрен локальным этическим комитетом НИИ нейронаук и медицины в соответствии с Хельсинкской декларацией биомедицинских обследований. Все испытуемые подписывали добровольное согласие на участие в обследованиях.

**Экспериментальная процедура.** Эксперимент был организован на основе парадигмы стоп-сигнал, предложенной в 1984 г. (Logan, Cowan, 1984) и модифицированной А.Н. Савостьяновым с коллегами (Savostyanov et al., 2009). Эксперимент проходил в форме компьютерной интерактивной игры «Охота». На экране компьютера появлялась одна из двух картинок: олень или танк. Испытуемый должен был нажимать левую кнопку после появления оленя или правую кнопку после появления танка. Время нажатия было ограничено 0.7 с. Если испытуемый нажимал на кнопку правильно и быстрее, чем 0.7 с, его игровой счет увеличивался. Если испытуемый нажимал кнопки неверно или время его ответа было дольше, чем 0.7 с, то игровой счет снижался.

Всего каждому испытуемому было предложено 135 заданий. В 35 случаях после появления целевого сигнала предъявлялся стоп-сигнал (красный квадрат с надписью “Stop”), что означало, что участник должен прервать уже начатое движение. Если участник не нажимал на кнопку после стоп-сигнала, его счет не менялся. Если участник нажимал на кнопку после стоп-сигнала, его счет снижался. Порядок активационных и тормозных заданий был рандомизирован. Также была рандомизирована последовательность заданий «олень» и «танк». Интервал между окончанием предыдущего задания и началом нового варьировал от 3 до 7 с. Общая продолжительность эксперимента составляла примерно 12 мин.

**Предобработка экспериментальных данных.** Очистка ЭЭГ от артефактов производилась методом ICA (Delorme, Makeig, 2004). Исходный ЭЭГ сигнал был эпохирован относительно метки появления целевого сигнала (олень или танк). Временной интервал от -1 до +3 с был выбран для эпохирования стимулов. Базовый уровень ЭЭГ был установлен в интервале от -1000 до -250 мс. Таким образом, получено от 80 до 90 фрагментов ЭЭГ для каждого участника, содержащих только активационное условие

и не содержащих моментов предъявления стоп-сигналов. После исключения артефактов связанные с событиями потенциалы (event-related potential, ERP) вычислялись отдельно для каждого канала ЭЭГ, усредненно по всем испытаниям и всем участникам.

Вычисление ERP проводилось в программе EEGLAB\_toolbox. Для каждого канала ЭЭГ были получены амплитудно-временные графики ERP. Затем выполнен визуальный просмотр графика ERP для отведения С3. В этом отведении максимально четко выделяются моторные пики ERP. В частности, по этому отведению были выбраны два пика – ранний премоторный, амплитуда которого предшествует нажатию на кнопку (так называемый readiness potential), и постмоторный пик, амплитуда которого достигает максимума при нажатии на кнопку. В результате визуального просмотра были установлены временные границы как раннего, так и позднего пика, после чего амплитуда в каждом из этих временных окон вычислялась отдельно для каждого человека и каждого ЭЭГ канала, но усредненно по всем испытаниям активационного задания парадигмы стоп-сигнал у каждого участника. Вычисление усредненной амплитуды выполнено при помощи программного пакета ERPLAB (<https://erplab.org/erplab>). Значения амплитуды были откорректированы к базовому уровню отдельно для каждого участника. Полученные значения использовались в качестве обучающих и тестовых данных для искусственных нейронных сетей.

**Описание входных данных.** Общая структура входных данных показана на рис. 1. У каждого испытуемого анализировалась ЭЭГ для 64 каналов, расположенных на разных участках поверхности головы. В соответствии с международной схемой 10–20 %, название электрода отражает его пространственное положение. Исходный ЭЭГ сигнал для каждого канала представлен в форме непрерывного ряда замеров разности потенциалов между активным и референтным электродами с временным разрешением 1000 замеров в секунду. Каждый участник обследования выполняет серию однотипных заданий (в нашем случае 100 активационных заданий стоп-сигнал парадигмы для каждого участника).

При вычислении амплитуды ERP исследователь выбирает несколько временных окон, в каждом из которых все значения амплитуды суммируются по всем временным

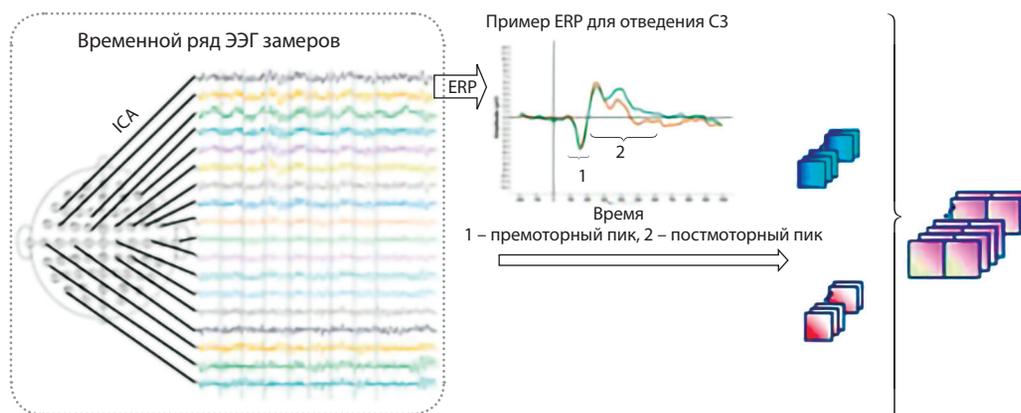


Рис. 1. Схема получения входных данных для нейронной сети.

точкам и усредняются по всем испытаниям. Амплитудные значения в разных окнах отражают временную динамику развития нейрофизиологического процесса. Мы выбрали два временных окна (250–350 и 550–900 мс после целевого сигнала), которые отражали соответственно физиологические процессы, ассоциированные с подготовкой и выполнением движения. У каждого участника было получено численное значение амплитуды ERP отдельно для каждого временного окна и для каждого ЭЭГ канала. В разных участках головы ERP может отклоняться от нулевого значения потенциала как вверх (положительный пик), так и вниз (отрицательный пик), поэтому численные значения амплитуды могут быть как положительными, так и отрицательными. Таким образом, наши данные учитывают как пространственную (название канала, его положение на голове), так и временную (первое или второе окно ERP) характеристику мозгового ответа на задание в парадигме стоп-сигнал, а также электрическую направленность реакции (положительные или отрицательные значения амплитуды пиков).

Для каждого обследованного человека размерность данных составила  $2 \times 64$  значения. Поскольку в каждой группе было примерно по 50 участников, размер данных для каждой из наших выборок составляет  $50 \times 2 \times 64$ , а общий размер набора данных –  $100 \times 2 \times 64$ .

## Проектировка структуры и фреймворка нейронной сети

Поскольку входной набор ERP данных невелик, была спроектирована неглубокая нейронная сеть для предсказания того, участвовал ли человек в долговременных медитациях или нет. Однако исходная ЭЭГ также имеет характеристики временных рядов, поэтому для ее анализа была дополнительно использована сверточная нейронная сеть в качестве глубокой нейронной сети для обучения и прогнозирования. Основные компоненты сверточной нейронной сети включают сверточные слои, объединяющие слои и полностью связанные слои.

В нашем случае на входной слой сверточной сети подаются данные ЭЭГ, преобразованные в виде двумерной матрицы с единичным размером выборки  $2 \times 64$ , где каждая строка представляет отдельный пик ERP, а каждый столбец представляет канал записи ЭЭГ. Скрытый уровень сверточной нейронной сети включает в себя три общие архитектуры: сверточный уровень, объединяющий слой и полностью подключенный слой. В качестве ядра свертки мы применили инструмент `Conv1d()` в PyTorch, что позволило предотвратить явление переобучения, вызванного использованием более сложных ядер свертки с большим количеством параметров (детальное описание инструмента см.: <https://pytorch.org/docs/stable/generated/torch.nn.Conv1d.html#torch.nn.Conv1d>, 21.02.2023).

Параметры сверточного слоя включают размер ядра свертки, размер шага и заполнение, которые совместно определяют размер выходной карты объектов сверточного слоя и являются гиперпараметрами сверточной нейронной сети. Из-за особенностей данных ЭЭГ существуют как пространственные, так и временные взаимосвязи, поэтому мы разработали две схемы. Первая схема заключается в использовании в общей сложности двух одномерных

сверток. Одна из них извлекает пространственные характеристики, которые представляют собой соединения пиков ERP в различных каналах электродов, а другая извлекает временные характеристики. В этой схеме функция-оболочка `PyTorch Conv1d()` была использована для завершения соответствующей функции. Второй слой заключается в применении только одной одномерной свертки, но эта свертка может извлекать как временные, так и пространственные объекты, для чего также выбрана функция-оболочка `PyTorch Conv1d()`.

Сверточные слои содержат функции активации, помогающие представлять сложные объекты. В нашем исследовании применялись три функции активации: `sigmoid()`, `relu()` и `softmax()` из PyTorch (<https://pytorch.org/docs/stable/generated/torch.nn.BCELoss.html>, 15.04.2023). После извлечения объектов в сверточном слое выходная карта объектов передавалась на объединяющий слой для выбора объектов и фильтрации информации. Слой объединения выбирает область объединения таким же образом, как и этап карты объектов сканирования ядра свертки, который управляется размером объединения, размером шага и заполнением. Уровень свертки и объединяющий слой в сверточной нейронной сети могут извлекать признаки входных данных. Роль полностью связанного слоя заключается в нелинейной комбинации извлеченных признаков для получения выходных данных. В нашем случае было создано два полностью связанных слоя, чтобы предотвратить переобучение из-за небольшого размера набора данных, для чего применялся инструмент `Linear()` в PyTorch. Перед выходным слоем в сверточной нейронной сети обычно находится полностью подключенный слой. Мы использовали различные функции потерь и активации при обучении на основе этих двух сценариев, чтобы повысить точность и производительность модели двух решений.

В соответствии с описанной выше схемой были спроектированы четыре сетевые структуры, которые использовались для классификации обследованных людей (рис. 2). Единственное различие между этими четырьмя архитектурами заключается в количестве сверточных слоев и количестве выходных нейронов в конце.

В *первой структуре* сверточный слой применяется для извлечения как временных, так и пространственных объектов. Затем берутся два полностью соединенных слоя и выводятся два значения после нормализации с помощью функции активации `softmax`. В качестве функции потерь используется перекрестная энтропия, в качестве алгоритма градиентного спуска – метод Adam.

*Вторая структура* применяет сверточный слой для извлечения как временных, так и пространственных объектов. Затем берутся два полностью соединенных слоя, а значение выводится после активации сигмовидной функции. В качестве функции потерь используется двоичная перекрестная энтропия, в качестве алгоритма градиентного спуска – Adam.

*Третья структура* основана на применении двух видов свертки для извлечения пространственных и временных характеристик данных соответственно. Затем берутся два полностью соединенных слоя и выводятся два значения после нормализации с помощью функции активации

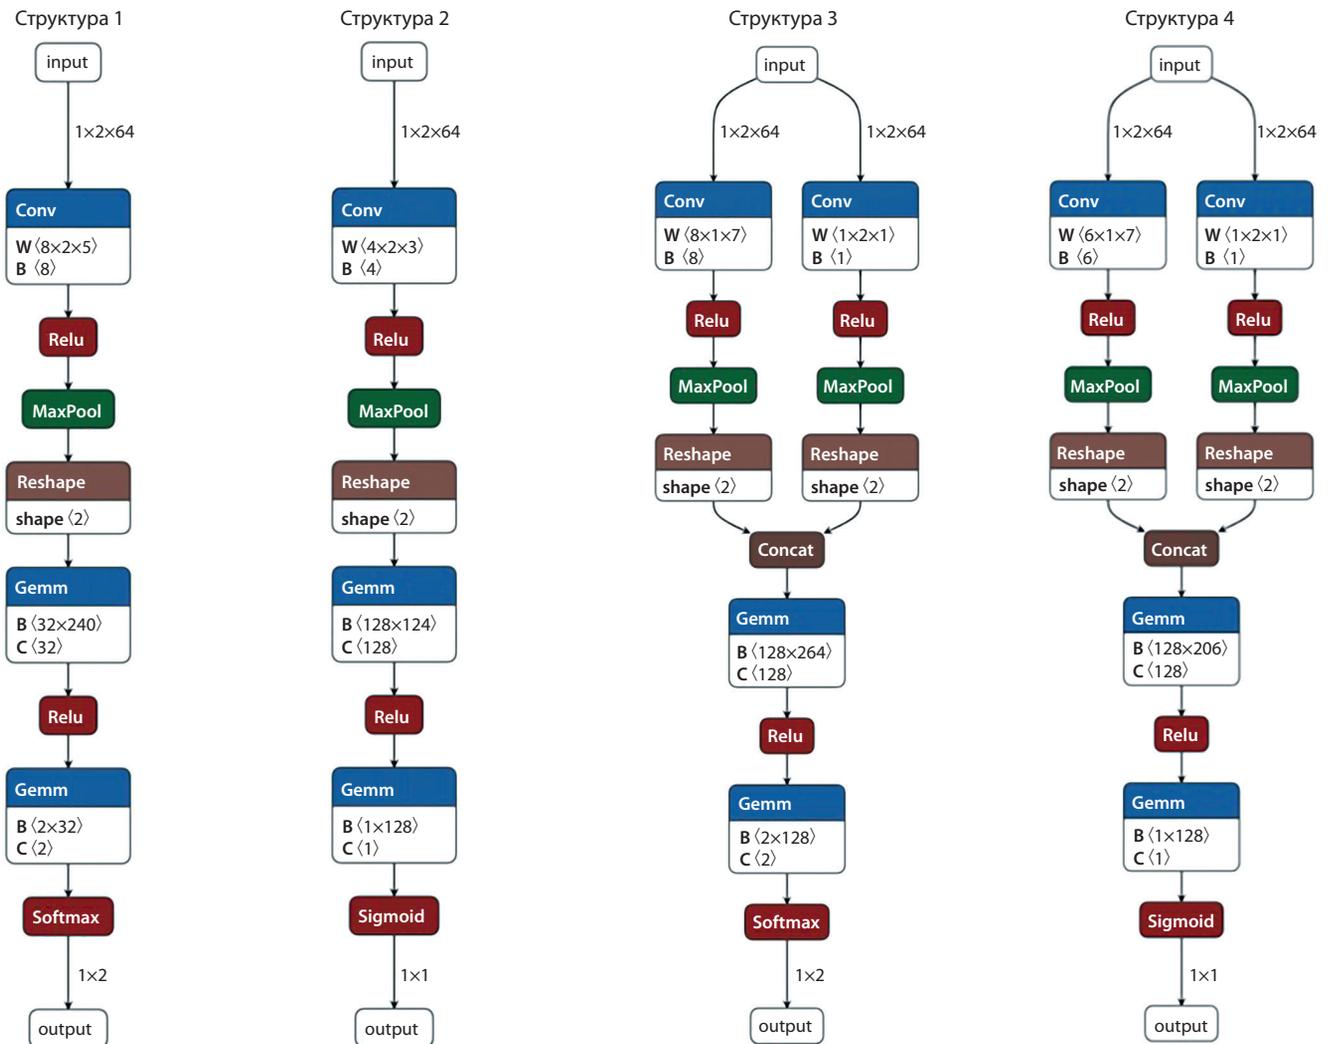


Рис. 2. Блок-схемы четырех моделей (структур) для архитектуры нейронной сети.

softmax. В качестве функции потерь используется перекрестная энтропия, в качестве алгоритма градиентного спуска – Adam.

И наконец, *четвертая структура* применяет два вида свертки для извлечения пространственных и временных характеристик данных соответственно. Затем берутся два полностью соединенных слоя. Значение выводится после активации сигмовидной функции. В качестве функции потерь используется двоичная перекрестная энтропия, в качестве алгоритма градиентного спуска – Adam.

Оптимальные гиперпараметры найдены для каждой структуры и описаны в разделе оценки модели.

### Обучение нейронной сети

Процесс обучения искусственной нейронной сети можно разделить на следующие четыре этапа: инициализация, прямое распространение, обратное распространение и обновление веса.

При инициализации мы присвоили случайное начальное значение каждому из параметров (весов и смещений) нейронной сети для нарушения симметрии, чтобы каждый нейрон имел разный градиент и, таким образом,

мог изучать различные функции. Позже, при поиске по гиперпараметрам, для каждой архитектуры была определена оптимальная функция инициализации. В процессе прямого распространения обучающие данные (входные и выходные) подавались в нейронную сеть, и значение активации каждого нейрона вычислялось по очереди от входного слоя к скрытому, а затем к выходному слою в соответствии со структурой нейронной сети. Значения активации брались из линейной комбинации входных данных и весов плюс смещение, за которым следовала нелинейная функция, такая как sigmoid или ReLU. Цель прямого распространения состояла в том, чтобы получить прогнозируемый результат нейронной сети и сравнить его с истинным результатом. Целью обратного распространения являлось получение градиента каждого параметра, который может быть применен для обновления параметров. В нашем случае для этого были использованы функция потерь кросс-энтропии и двоичная функция потерь кросс-энтропии (<https://pytorch.org/docs/stable/generated/torch.nn.CrossEntropyLoss.html>, 20.03.2023). Функция кросс-энтропии применялась нами для измерения расстояния между распределением вероятностей, предсказанным мо-

делью, и истинным распределением вероятностей. С ее помощью мы оценивали производительность модели и выбирали оптимальную модель и параметр путем сравнения значений потерь различных моделей или различных параметров.

В соответствии со своим градиентом каждый параметр обновляется с определенной скоростью обучения (размером шага), так что функция потерь уменьшается. Целью обновления веса является оптимизация параметров нейронной сети, чтобы нейронная сеть могла лучше соответствовать данным обучения. Для этой задачи нами был применен метод Adam. Метод Adam – это алгоритм оптимизации стохастического градиентного спуска с адаптивным импульсом, который был предложен на конференции ICLR в 2015 г. и стал одним из самых популярных и эффективных оптимизаторов в области глубокого обучения. Adam объединяет два классических алгоритма оптимизации: Adagrad и RMSProp, которые способны решать задачи с разреженными градиентами и нестационарными целевыми функциями, а также использовать идею импульса для ускорения сходимости. Adam эквивалентен наличию отдельной скорости обучения для каждого параметра, и эта скорость обучения адаптивно настраивается в соответствии с изменением градиента. В частности, когда градиент велик, оценка второго момента увеличивается, что снижает скорость обучения. Когда градиент мал или разрежен, оценка первого момента увеличивается, что увеличивает скорость обучения. Это позволило эффективно избежать колебаний, вызванных слишком большой скоростью обучения, или увеличения сложности конвергенции, вызванного слишком малой скоростью обучения, или даже попадания в ловушку локального минимума или седловой точки.

Чтобы уменьшить переобучение и лучше обучить модель, мы применили пакетную нормализацию. Batch normalization – это подход, который решает проблему исчезающего градиента за счет улучшения сглаживания потерь, ускоряет конвергенцию сети и повышает точность (Loffe, Szegedy, 2015). Метод нормализует данные в мини-пакете таким образом, чтобы среднее значение было равно 0, а стандартное отклонение – 1. В то же время вводятся два обучаемых параметра, масштаб и сдвиг, чтобы модель могла изучить свое соответствующее распределение при обратном распространении. Для реализации этой функции мы использовали инструмент BatchNorm1d() из PyTorch.

Переобучение – распространенная проблема в процессе обучения искусственной нейронной сети, при возникновении которой модель хорошо работает на обучающем наборе, но плохо – на тестовом наборе или на новых данных, что указывает на то, что она плохо обобщается. В нашем случае проблема заключалась в переобучении из-за небольшого набора исходных данных. Чтобы решить ее, мы применили инициализацию, регуляризацию L2 и случайную деактивацию (dropout), а также перекрестную проверку для оценки модели и выбора гиперпараметров, которые наилучшим образом обучают модель, в некоторой степени уменьшая переобучение. Мы использовали метод регуляризации L2 (уменьшение веса), который включает добавление штрафного члена к функции потерь, пропорциональной сумме квадратов параметров модели.

Регуляризация L2 может привести к тому, что параметры модели будут стремиться к меньшим значениям, тем самым снижая чувствительность модели к шуму или выбросам. Случайная деактивация (dropout) означает случайное обнуление определенных нейронов или слоев соединений с определенной вероятностью во время обучения. Это уменьшает количество параметров модели, что повышает надежность и способность к обобщению модели.

Перекрестная проверка – это повторное использование данных, разделение результирующей выборки данных, объединение в различные обучающие и тестовые наборы, обучающий набор для обучения модели и тестовый набор для оценки качества прогнозирования модели. Мы применили метод K-fold умножения в качестве метода перекрестной проверки, чтобы уменьшить переобучение.

### Оценка качества работы модели на обучающих данных

В соответствии с характеристиками выборки ЭЭГ данных и показателями эталонной модели классификации мы использовали метрики “F1-score”, “AUC” (area under curve) и «точность» в качестве показателей оценки модели ([https://keras.io/api/models/model\\_training\\_apis](https://keras.io/api/models/model_training_apis)). Чем выше эти показатели, тем выше производительность модели. F1-score и AUC являются комплексными оценочными показателями классификационных моделей, но они имеют разные погрешности. На AUC в меньшей степени влияет соотношение положительных и отрицательных проб в образце. Для целей этой разработки стало ясно, что прогнозирование человека с высоким уровнем стресса как человека с низким уровнем стресса привело бы к принципиально неверным результатам. Поэтому мы выбрали показатель F1-score в качестве наиболее приоритетного для оценки эффективности модели. Гиперпараметры модели оценивали, используя пятикратную перекрестную проверку, чтобы отобрать наиболее подходящие гиперпараметры для предотвращения переобучения и повышения производительности модели.

Результаты оценки модели на обучающей выборке представлены на рис. 3. Рассматривая каждый из выбранных нами показателей, можно увидеть, что наиболее эффективную классификацию показала модель 2. По всем выбранным показателям ее эффективность превысила 80%. Модели 1 и 4 тоже демонстрируют хорошие результаты классификации, тогда как модель 3 работает хуже всего. Следовательно, мы предполагаем, что выход одного нейрона превосходит использование двух нейронов в задаче

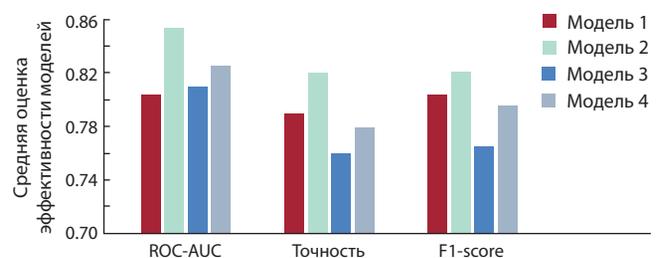


Рис. 3. Результаты тестирования четырех разных моделей нейронной сети на обучающей выборке.

бинарной классификации ЭЭГ. Двоичная перекрестная потеря, очевидно, больше подходит для нашей задачи классификации, основанной на имеющемся наборе данных. При оценке эффективности модели количество выборок составило 100, из них 51 человек занимался медитацией (низкий уровень стресса) и 49 не занимался медитацией. Количество выборок сбалансировано, поэтому это не существенно влияет на обучение и производительность модели. Более того, для данных только с двумя пиками ERP в 64 каналах электродов одна свертка, извлекающая как временные, так и пространственные характеристики, работала лучше, чем две свертки, извлекающие временные и пространственные характеристики по отдельности.

**Оценка качества модели на независимых данных.** Чтобы оценить качество работы модели на независимой выборке, мы подготовили ЭЭГ данные, записанные у 25 человек, которые не были включены в обучающую выборку. Из этих 25 человек 12 практиковали медитацию, а 13 не практиковали. Оборудование, дизайн эксперимента и предобработка ЭЭГ данных были такими же, как и в случае с обучающей выборкой. В этой части исследования все модели, обученные ранее, были протестированы на новых данных, не включенных в обучающую выборку. В качестве показателей оценки эффективности модели были использованы точность, надежность, отзывчивость, F1-score, ROC-AUC, специфичность, чувствительность. Несмотря на использование функции инициализации параметров, веса по-прежнему инициализировались случайным образом в пределах определенного диапазона, поэтому мы исправили начальное значение случайного числа, чтобы обеспечить стабильность работы модели.

Показатели эффективности для разных моделей на независимой тестовой выборке отражены на рис. 4. Наилучшие результаты по большинству выбранных параметров показала модель 4. Также достаточно хорошие результаты получены для модели 2. Эта структура показала наименьшую чувствительность к переобучению, что говорит о ее большей надежности в сравнении с моделью 4.

## Заключение

В нашем исследовании была успешно разработана нейронная сеть, которая классифицирует людей на группы участвующих или не участвующих в медитации на основе анализа их ЭЭГ данных с точностью примерно 80–85%. Мы использовали набор данных ЭЭГ, собранный и составленный в ходе наших собственных экспериментов, и выбрали амплитуду ERP пика перед нажатием на кнопку 250–350 мс и значение амплитуды пика после нажатия на кнопку 550–900 мс для 64 каналов записи. При этом размер выборки составил  $1 \times 2 \times 64$ .

Были разработаны четыре архитектуры неглубоких сверточных сетей, среди которых структуры 2 и 4 показали себя лучше всего в тестах на независимых выборках данных. Наиболее надежной была структура 2, которая использовала одномерный сверточный слой, объединяющий слой и двуслойную полностью подключенную сеть. Во время разработки этой модели отмечено, что она часто подвержена переобучению из-за ограничения размера отображения набора данных. Явление переобучения было смягчено за счет изменения структуры и масштаба моде-

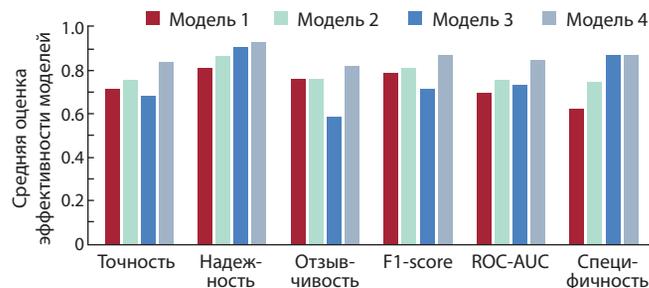


Рис. 4. Результаты тестирования четырех разных моделей нейронной сети на независимой выборке.

ли, конкретных параметров сети инициализации, регуляризации, случайной деактивации (dropout) и гиперпараметров скрининга перекрестной проверки.

В целом предложенный нами подход был апробирован на двух небольших выборках клинических испытуемых. Похожий метод на экспериментальных данных из парадигмы стоп-сигнал был ранее апробирован нами при классификации на выборках клинических пациентов с депрессивным расстройством и здоровых людей (Зеленских и др., 2022). Результаты нашей новой статьи дополняют предыдущую работу, так как показывают, что, несмотря на небольшие размеры выборок, метод сверточных нейронных сетей позволяет достигать высокого уровня точности в классификации разных, независимых друг от друга групп людей, различающихся по уровню стресса. Взятые вместе, результаты обоих исследований показывают, что применение нейронных сетей к данным, полученным при тестировании людей в рамках парадигмы стоп-сигнал, является перспективным методом для оценки их уровня стресса и степени выраженности симптоматики тревожно-депрессивных расстройств. Необходимо отметить, что результаты М.О. Зеленских с коллегами основаны на применении только поведенческих данных, полученных в парадигме стоп-сигнал, тогда как наши базируются на анализе электрических ответов мозга, полученных в том же эксперименте. Продолжением исследований должно быть применение сверточных нейронных сетей для одновременного совместного анализа и поведенческих, и нейробиологических данных с целью более точной классификации участников по уровню стресса.

Важно отметить, что большинство стандартных методов оценки уровня стресса или предрасположенности к тревожно-депрессивным расстройствам основано на применении психологических опросников или на интервью с психиатром (например, Beck et al., 1988). Однако такие методы обладают недостатком: пациент может не хотеть информировать интервьюера о своем состоянии или неадекватно оценивать самого себя. Неадекватная самооценка пациента часто является причиной неверных выводов, касающихся его предрасположенности к болезни (Nock et al., 2010). Другой подход применяет анализ поведенческих или нейрофизиологических реакций на эмоциональные стимулы. В качестве таких стимулов предъявляют либо фотографии лиц, выражающих эмоциональные состояния самого пациента или других людей (Quevedo et al., 2016), либо эмоциональные сообщения (Bocharov et al., 2020).

Этот метод позволяет объективно оценить степень нарушения аффективных функций головного мозга, но мало чувствителен к изменениям общей способности человека к самоконтролю поведения. Предлагаемый нами метод, наоборот, использует неэмоциональные стимулы для индуцирования сложной сенсомоторной реакции, требующей либо активации, либо торможения движения. Наш подход позволяет оценивать общий уровень самоконтроля поведения, но не дает возможности оценить аффективное состояние пациента. Очевидно, что эти три подхода (тестирование при помощи опросников, анализ реакций на аффективное стимулирование и анализ реакций в задачах на моторный контроль) являются взаимодополняющими, т. е. должны применяться вместе для более детальной оценки одного и того же пациента. Хотя предлагаемый нами подход нуждается в дополнительной проверке, в будущем он может дать большие результаты при разработке средств диагностики индуцированных стрессом заболеваний.

## Список литературы / References

Зеленских М.О., Сапрыгин А.Е., Тамозжников С.С., Рудыч П.Д., Лебедин Д.А., Савостьянов А.Н. Разработка нейронной сети для диагностики риска возникновения депрессии по экспериментальным данным стоп-сигнал парадигмы. *Вавиловский журнал генетики и селекции*. 2022;26(8):773-779. DOI 10.18699/VJGB-22-93  
[Zelenskih M.O., Saprygin A.E., Tamozhnikov S.S., Rudych P.D., Lebedkin D.A., Savostyanov A.N. Development of a neural network for diagnosing the risk of depression according to the experimental data of the stop signal paradigm. *Vavilovskii Zhurnal Genetiki i Seleksii = Vavilov Journal of Genetics and Breeding*. 2022;26(8): 773-779. DOI 10.18699/VJGB-22-93]

Кузнецова В.Б., Князев Г.Г., Дорошева Е.А., Боcharov A.B., Савостьянов А.Н. Роль личности и стресса в развитии депрессивных расстройств у студентов. *Журн. неврологии и психиатрии*. 2016;116(12):114-118. DOI 10.17116/jnevro201611612114-118  
[Kuznetsova V.B., Knyazev G.G., Dorosheva E.A., Bocharov A.V., Savostyanov A.N. A role of personality and stress in the development of depressive symptoms in students. *Zhurnal Nevrologii i Psikhatrii = Journal of Neurology and Psychiatry*. 2016;116(12):114-118. DOI 10.17116/jnevro201611612114-118 (in Russian)]

Aftanas L., Golosheykin S. Impact of regular meditation practice on EEG activity at rest and during evoked negative emotions. *Int. J. Neurosci*. 2005;115(6):893-909. DOI 10.1080/00207450590897969

Atchley R., Klee D., Memmott T., Goodrich E., Wahbeh H., Oken B. Event-related potentials correlates of mindfulness meditation competence. *Neuroscience*. 2016;320:83-92. DOI 10.1016/j.neuroscience.2016.01.051

Band G.P.H., van der Molen M.W., Logan G.D. Horse-race model simulations of the stop-signal procedure. *Acta Psychol*. 2003;112(2): 105-142. DOI 10.1016/S0001-6918(02)00079-3

Beck A.T., Steer R.A., Garbin M.G. Psychometric properties of the Beck Depression Inventory: twenty-five years of evaluation. *Clin. Psychol. Rev*. 1988;8(1):77-100. DOI 10.1016/0272-7358(88)90050-5

Bocharov A.V., Savostyanov A.N., Tamozhnikov S.S., Merkulova E.A., Saprygin A.E., Proshina E.A., Knyazev G.G. Oscillatory dynamics of perception of emotional sentences in healthy subjects with different severity of depressive symptoms. *Neurosci. Lett*. 2020;728: 134888. DOI 10.1016/j.neulet.2020.134888

Chiesa A., Calati R., Serretti A. Does mindfulness training improve cognitive abilities? A systematic review of neuropsychological findings. *Clin. Psychol. Rev*. 2011;31(3):449-464. DOI 10.1016/j.cpr.2010.11.003

Delorme A., Makeig S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *J. Neurosci. Methods*. 2004;134(1):9-21. DOI 10.1016/j.jneumeth.2003.10.009

Hsieh M.T., Lu H., Lin C.I., Sun T.H., Chen Y.R., Cheng C.H. Effects of trait anxiety on error processing and post-error adjustments: an event-related potential study with stop-signal task. *Front. Hum. Neurosci*. 2021;15:650838. DOI 10.3389/fnhum.2021.650838

Iwata N., Higuchi H.R. Responses of Japanese and American university students to the STAI items that assess the presence or absence of anxiety. *J. Pers. Assess*. 2000;74(1):48-62. DOI 10.1207/S15327752JPA740104

Khosla A., Khandnor P., Chand T. A comparative analysis of signal processing and classification methods for different applications based on EEG signals. *Biocybern. Biomed. Eng*. 2020;40(2):649-690. DOI 10.1016/j.bbe.2020.02.002

Kuh D., Ben-Shlomo Y., Lynch J., Hallqvist J., Power C. Life course epidemiology. *J. Epidemiol. Community Health*. 2003;57(10):778-783. DOI 10.1136/jech.57.10.778

Loffe S., Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift. *arXiv*. 2015;1502.03167. DOI 10.48550/arXiv.1502.03167

Logan G.D., Cowan W.B. On the ability to inhibit thought and action: a theory of an act of control. *Psychol. Rev*. 1984;91(3):295-327. DOI 10.1037/0033-295X.91.3.295

McCrae R.R., Costa P.T., Jr., Ostendorf F., Angleitner A., Hrebicková M., Avia M.D., Sanz J., Sánchez-Bernardos M.L., Kusdil M.E., Woodfield R., Saunders P.R., Smith P.B. Nature over nurture: temperament, personality, and life span development. *J. Pers. Soc. Psychol*. 2000;78(1):173-186. DOI 10.1037//0022-3514.78.1.173

Nock M.K., Park J.M., Finn C.T., Deliberto T.L., Dour H.J., Banaji M.R. Measuring the suicidal mind: implicit cognition predicts suicidal behavior. *Psychol. Sci*. 2010;21(4):511-517. DOI 10.1177/0956797610364762

Quevedo K., Scott R.N.H., Martin J., Smyda G., Keener M., Oppenheimer C.W. The neurobiology of self-face recognition in depressed adolescents with low or high suicidality. *J. Abnorm. Psychol*. 2016; 125(8):1185-1200. DOI 10.1037/abn0000200

Saeed S.A., Cunningham K., Bloch R.M. Depression and anxiety disorders: benefits of exercise, yoga, and meditation. *Am. Fam. Physician*. 2019;99(10):620-627

Savostyanov A.N., Tsai A.C., Liou M., Levin A.E., Lee J.D., Yurganov A.V., Knyazev G.G. EEG-correlates of trait anxiety in the stop-signal paradigm. *Neurosci. Lett*. 2009;449(2):112-116. DOI 10.1016/j.neulet.2008.10.084

Savostyanov A.N., Tamozhnikov S.S., Bocharov A.V., Saprygin A.E., Matushkin Y., Lashin S., Kolpakova G., Sudobin K., Knyazev G. The effect of meditation on comprehension of statement about oneself and others: a pilot ERP and behavioral study. *Front. Hum. Neurosci*. 2020;13:437. DOI 10.3389/fnhum.2019.00437

## ORCID ID

A.E. Saprygin orcid.org/0000-0001-6789-2953

A.N. Savostyanov orcid.org/0000-0002-3514-2901

**Благодарности.** Разработка и тестирование нейронной сети и коллекция ЭЭГ данных у медитаторов выполнялись в рамках бюджетного проекта ИЦиГ СО РАН FWNR-2022-0020. Сбор ЭЭГ данных у не-медитаторов, а также предпроцессинг всех ЭЭГ данных выполнен в рамках проекта Российского научного фонда № 22-15-00142 «ФМРТ и ЭЭГ корреляты фокуса внимания на собственной персоне как фактора предрасположенности к аффективным расстройствам».

**Конфликт интересов.** Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию 11.07.2023. После доработки 10.09.2023. Принята к публикации 13.09.2023.