

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

## Разработка нейронной сети для диагностики риска возникновения депрессии по экспериментальным данным стоп-сигнал парадигмы

М.О. Зеленских<sup>1</sup>, А.Е. Сапрыгин<sup>2, 3</sup>, С.С. Таможников<sup>3</sup>, П.Д. Рудыч<sup>1, 3, 4</sup>, Д.А. Лебедкин<sup>1, 4</sup>, А.Н. Савостьянов<sup>1, 2, 3, 4</sup> 

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

<sup>2</sup> Федеральный исследовательский центр Институт цитологии и генетики Сибирского отделения Российской академии наук, Новосибирск, Россия

<sup>3</sup> Научно-исследовательский институт нейронаук и медицины, Новосибирск, Россия

<sup>4</sup> Федеральный исследовательский центр фундаментальной и трансляционной медицины, Новосибирск, Россия

 a-sav@mail.ru

**Аннотация.** В настоящее время возможность спрогнозировать результат развития системы – залог успешного функционирования системы. Повышение качества и объема информации, усложнение ее представления, необходимость обнаруживать скрытые связи делают неэффективным, а чаще всего невозможным, применение классических статистических методов прогнозирования. Среди разнообразных методов прогнозирования особое место занимают методы, основанные на использовании искусственных нейронных сетей. Задачей нашей работы является создание нейронной сети, прогнозирующей риск возникновения депрессии у человека, с помощью данных, полученных при использовании системы тестирования показателей моторного контроля. Стоп-сигнал парадигма (ССП) – это экспериментальный метод, позволяющий оценить способность человека активировать целенаправленные движения или подавлять движения, ставшие неадекватными внешним условиям. В современной медицине СПП чаще всего применяется для диагностики двигательных нарушений, таких как болезнь Паркинсона или последствия инсульта. Мы предположили, что СПП может служить основой для выявления риска развития аффективных заболеваний, включая депрессию. В разрабатываемой нами нейронной сети предполагается комбинирование таких поведенческих показателей, как количество пропущенных ответов, количество правильных ответов, среднее время, количество верных торможений после появления стоп-сигнала. Такой набор показателей обеспечит повышенную точность прогнозирования наличия депрессии у человека. Реализованная в работе искусственная нейронная сеть позволяет по данным, полученным с помощью фиксации реакции на стимулы со стоп-сигналом, диагностировать риск возникновения депрессии. Разработана архитектура и реализована система тестирования показателей моторного контроля у человека, затем протестирована в реальных экспериментах. Проведено сравнение нейросетевых технологий и методов математической статистики. Реализована нейронная сеть для диагностирования риска возникновения депрессии по данным СПП. На примере данных с экспертной оценкой на наличие депрессии и результатов, полученных при использовании системы тестирования показателей моторного контроля, продемонстрирована эффективность нейронной сети (с точки зрения точности).

Ключевые слова: стоп-сигнал парадигма; искусственная нейронная сеть; система тестирования; риск возникновения депрессии; машинное обучение.

**Для цитирования:** Зеленских М.О., Сапрыгин А.Е., Таможников С.С., Рудыч П.Д., Лебедкин 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

## Development of a neural network for diagnosing the risk of depression according to the experimental data of the stop signal paradigm

М.О. Zelenskih<sup>1</sup>, А.Е. Saprygin<sup>2, 3</sup>, S.S. Tamozhnikov<sup>3</sup>, P.D. Rudych<sup>1, 3, 4</sup>, D.A. Lebedkin<sup>1, 4</sup>, A.N. Savostyanov<sup>1, 2, 3, 4</sup> 

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

<sup>2</sup> Institute of Cytology and Genetics of the Siberian Branch of the Russian Academy of Sciences, Novosibirsk, Russia

<sup>3</sup> Scientific Research Institute of Neurosciences and Medicine, Novosibirsk, Russia

<sup>4</sup> Federal Research Center of Fundamental and Translational Medicine, Novosibirsk, Russia

 a-sav@mail.ru

**Abstract.** These days, the ability to predict the result of the development of the system is the guarantee of the successful functioning of the system. Improving the quality and volume of information, complicating its presentation, the need to detect hidden connections makes it ineffective, and most often impossible, to use classical statistical forecasting methods. Among the various forecasting methods, methods based on the use of artificial neural networks occupy a special place. The

main objective of our work is to create a neural network that predicts the risk of depression in a person using data obtained using a motor control performance testing system. The stop-signal paradigm (SSP) is an experimental technique to assess a person's ability to activate deliberate movements or inhibit movements that have become inadequate to external conditions. In modern medicine, the SSP is most commonly used to diagnose movement disorders such as Parkinson's disease or the effects of stroke. We hypothesized that SSP could serve as a basis for detecting the risk of affective diseases, including depression. The neural network we are developing is supposed to combine such behavioral indicators as: the amount of missed responses, amount of correct responses, average time, the amount of correct inhibition of movements after stop-signal onset. Such a combination of indicators will provide increased accuracy in predicting the presence of depression in a person. The artificial neural network implemented in the work allows diagnosing the risk of depression on the basis of the data obtained in the stop-signal task. An architecture was developed and a system was implemented for testing motor control indicators in humans, then it was tested in real experiments. A comparison of neural network technologies and methods of mathematical statistics was carried out. A neural network was implemented to diagnose the risk of depression using stop-signal paradigm data. The efficiency of the neural network (in terms of accuracy) was demonstrated on data with an expert assessment for the presence of depression and data from the motor control testing system.

Key words: stop signal paradigm; artificial neural network; system for depression risk assessment; machine learning.

**For citation:** 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

## Введение

В настоящее время возможность спрогнозировать результат развития системы является залогом успешного функционирования системы. Повышение качества и объема информации, усложнение ее представления, необходимость обнаруживать скрытые связи делают неэффективным, а чаще всего невозможным, применение классических статистических методов прогнозирования. Особое место занимают методы, базирующиеся на использовании искусственных нейронных сетей.

Основная задача нашей работы – создание нейронной сети, прогнозирующей риск возникновения депрессии у человека, с использованием данных, полученных с помощью системы тестирования показателей моторного контроля (Хайкин, 2006). Все данные взяты из открытой базы ИЦиГ СО РАН (ICBrainDB dataset <https://icbraindb.cytogen.ru/api-v2>).

Группа пациентов с депрессией была обследована на базе клиники НИИ нейронаук и медицины. Наличие большого депрессивного расстройства диагностировалось врачом-психиатром в ходе закрытого интервью на основании критериев МКБ-10. В качестве контрольной группы здоровых людей приглашали участников, которые никогда не проходили лечения в психиатрических клиниках и не обращались к психиатрам за врачебной помощью. Все участники контрольной группы отрицали наличие у них в момент обследования или в течение пяти лет до обследования каких-либо неврологических или психиатрических заболеваний. Кроме того, как пациенты, так и контрольные участники отрицали наличие у них алкогольной или наркотической зависимости и употребление иных психоактивных веществ.

Основные отличия искусственных нейронных сетей от методов математической статистики – параллельная обработка информации и способность к обучению без учителя, т. е. к самообучению (<https://wiki.loginom.ru/articles/normalization.html>). Ниже в виде таблицы представлены результаты сравнения нейронных сетей и методов математической статистики по выбранным критериям (табл. 1).

Устойчивость к лишним данным – важный показатель при работе с большим количеством параметров и отсут-

ствии явных зависимостей, которые мы получаем из данных стоп-сигнал парадигмы (ССП). Самообучение дает возможность выполнять поставленные задачи без стороннего вмешательства, что способствует поиску закономерности между параметрами.

Применение методов математической статистики при поиске зависимостей между стоп-сигнал парадигмой и рисками наличия депрессии не позволяет в полной мере обнаружить их наличие из-за неустойчивости методов к лишним данным, а тем более диагностировать в дальнейшем риск возникновения депрессии у человека. Необходимо использовать технологии нейронных сетей, которые, в отличие от статистических методов, обладают устойчивостью к лишним данным и возможностью для самообучения.

Нейронная сеть должна принимать на вход датасет, состоящий из данных, полученных с помощью ССП, и выводить результат диагностики на риск возникновения депрессии.

Стоп-сигнал парадигма – это экспериментальный метод, позволяющий оценить способность человека активировать целенаправленные движения или подавлять движения, ставшие неадекватными внешним условиям. В современной медицине ССП чаще всего применяется для диагностики двигательных нарушений, таких как болезнь Паркинсона или последствия инсульта. Мы предположили, что ССП может служить основой для выявления риска развития аффективных заболеваний, включая депрессию. В разрабатываемой нами нейронной сети предполагается комбинирование таких поведенческих показателей, как количество пропущенных ответов, количество правильных ответов, среднее время, количество верных стоп-сигналов. Такой набор показателей обеспечит повышенную точность прогнозирования наличия депрессии у человека.

Цель настоящей работы – разработка нейронной сети для диагностики риска возникновения депрессии по данным стоп-сигнал парадигмы. Реализованная в работе искусственная нейронная сеть позволяет по данным, полученным с помощью фиксации реакции на стимулы со стоп-сигналом, диагностировать риск возникновения депрессии.

**Таблица 1.** Сравнение нейронных сетей и математической статистики

Критерий	Нейронные сети	Методы математической статистики
Уровень насыщения	Большой уровень насыщения	Маленький уровень насыщения
Вычислительная мощность	Обладают большой вычислительной мощностью	Обладают меньшей вычислительной мощностью, чем искусственные нейронные сети
Прогрессирование алгоритмов	Постоянное развитие алгоритмов построения искусственных нейронных сетей	Развитие происходит медленно
Отсутствие необоснованного результата	Наличие необоснованных результатов	Отсутствие необоснованных результатов
Затраты времени на разработку	Большое количество времени на разработку	Меньшие затраты времени на разработку
Количество данных для получения результата	Для обучения необходимо большое количество данных	Для использования необходимо меньше данных, чем для искусственных нейронных сетей
Устойчивость к лишним данным	Устойчивы к лишним данным	Неустойчивы к лишним данным
Возможность самообучения	Наличие возможности самообучения	Отсутствие возможности самообучения

**Таблица 2.** Используемый стек технологий

Технология	Мотивация
Язык программирования: Python	На данный момент позволяет проще и быстрее работать с нейронными сетями, чем другие языки программирования (например, Java). Поддерживает широкий спектр библиотек
Библиотека для обработки данных: Pandas – это библиотека с открытым исходным кодом, предоставляющая инструменты для работы с различными структурами данных для языка программирования Python (Виноградова, 2012). Библиотека была использована для парсинга результатов экспериментов и для дальнейшей работы с датасетом	Позволяет обрабатывать необходимые расширения (.dat, .csv, .datx)
Библиотека для построения и работы с графиками: matplotlib – это библиотека для создания таких визуализаций, как гистограммы, столбчатые диаграммы, полосы погрешности, графики когерентности и многое другое (Ivanov et al., 2022). Библиотека была использована для построения графиков потерь во время тренировки и валидации нейронной сети, точности тренировки и валидации	Выбрана из-за возможности построения гистограмм
Библиотека для взаимодействия с искусственными нейронными сетями: Keras – это библиотека глубокого обучения, представляющая собой API, написанное на Python, работающее поверх платформы для машинного обучения TensorFlow ( <a href="https://keras.io/about/">https://keras.io/about/</a> )	Выбрана как одна из наиболее популярных технологий для взаимодействия с нейросетями
Система контроля версий – Github	Выбрана как одна из наиболее популярных систем контроля версий

## Материалы и методы

**Реализация нейронной сети.** В табл. 2 приведены используемые технологии для реализации с аргументацией выбора.

**Архитектура модели.** Для работы с моделью и слоями были использованы классы Sequential и Dense библиотеки Keras.

Класс Sequential представляет собой последовательную архитектуру нейронной сети, что эквивалентно последовательному вызову слоев ([https://keras.io/api/layers/core\\_layers/dense/](https://keras.io/api/layers/core_layers/dense/)).

Класс Dense реализует операцию

$$\text{output} = \text{activation}(\text{dot}(\text{input}, \text{kernel}) + \text{bias}), \quad (1)$$

где activation – поэлементная функция активации, передаваемая в качестве аргумента, kernel – матрица всех весов, созданная слоем, bias – вектор смещения, созданный слоем (<https://keras.io/api/layers/activations/>). Были выделены два слоя:

- слой  $x$ , т.е. слой для работы с объектами, основанными на входных данных, за исключением категории тестируемого;
- слой  $y$ , т.е. слой для работы с ответами, основанными на категории тестируемого.

Для работы со слоем  $x$  была использована функция активации relu. Функция relu – возвращает число, если принимает положительный аргумент, в остальных случаях возвращает 0 (<https://matplotlib.org/stable/index.html>). Для работы со слоем  $y$  была использована функция активации sigmoid, необходимая для вероятностного прогнозирования. Сигмоидная функция активации:

$$\text{sigmoid}(x) = \frac{1}{(1 + \exp(-x))}. \quad (2)$$

Для малых значений функция возвращает значение, близкое к 0, а для больших значений – близкое к 1, причем сигмоида всегда возвращает от 0 до 1 ([https://www.probabilitycourse.com/chapter9/9\\_1\\_5\\_mean\\_squared\\_error\\_MSE.php](https://www.probabilitycourse.com/chapter9/9_1_5_mean_squared_error_MSE.php)).

**Сбор данных для обучения.** В ходе подготовки к разработке нейронной сети был создан сбалансированный датасет на основе данных, полученных при обследовании здоровых людей и пациентов с диагностированной депрессией.

Были выделены следующие входные данные:

- Missed – количество пропущенных ответов у тестируемого;
- Right – суммарное количество правильных ответов у тестируемого;
- Av\_time – среднее время реакции за эксперимент у тестируемого;
- Stop – количество верных игнорирований на стоп-сигнал у тестируемого;
- Practice – количество верных ответов в блоке «Практика» у тестируемого;
- Right\_stop – количество правильных ответов без учета стоп-сигнала;
- Incor\_stop – количество неверных реакций на стоп-сигнал;
- Survive – категория тестируемого (здоров или диагностирована депрессия).

**Подготовка и нормализация данных.** Нормализация данных – это процедура предобработки входных данных, при которой значения признаков, образующих входной вектор, приводятся к заданному диапазону. Нормализация необходима потому, что исходные значения могут изменяться в большом диапазоне и работа нейронной сети с такими данными может привести к некорректному результату (<https://keras.io/api/models/>). Нормализация данных к диапазону [0...1] важна для выставления единой привилегированности признаков, т.е. для выставления одинаковой значимости каждого признака, что позволит сравнивать их между собой в равных условиях.

Для нормализации были выбраны все входные данные датасета, за исключением Survive, так как данный параметр является оценкой и принимает всего два значения, 0 или 1.

**Выбор топологии** искусственной нейронной сети – один из важнейших этапов при использовании нейросетевых технологий для решения практических задач. От этого этапа напрямую зависит адекватность обучения

нейросетевой модели ([https://keras.io/api/models/model\\_training\\_apis/](https://keras.io/api/models/model_training_apis/)). Так как перед нами стоит задача классификации и важно найти любые скрытые связи, то необходимо, чтобы каждый искусственный нейрон был связан с другими нейронами.

Исходя из концепций типов нейронных сетей, был выбран полносвязный тип, поскольку, как упоминалось ранее, каждый искусственный нейрон передает свой выход остальным нейронам.

**Экспериментальный подбор параметров обучения.** В ходе данного этапа разработки нейронной сети необходимо подобрать оптимальные параметры обучения, которые будут демонстрировать наилучшие показатели точности и потерь. Подбор осуществляется путем запуска нейронной сети с возможными параметрами и тестовым датасетом.

В табл. 3 представлены результаты экспериментального подбора параметров обучения, т.е. подбора количества прохождений датасета от начала до конца (epochs) и количества данных на валидацию (validation\_split), на сбалансированном датасете (50 % здоровых, 50 % с диагностированной депрессией, всего 205).

На рис. 1 продемонстрирована точность обучения и валидации при обучении на сбалансированном датасете с выбором epochs = 500 и validation\_split = 0.2.

Таким образом, из-за отсутствия подходящих параметров для дальнейшей работы было решено использовать несбалансированный датасет (65 % здоровых, 35 % с диагностированной депрессией, всего 500).

В табл. 4 приведены результаты экспериментального подбора параметров обучения на несбалансированном датасете.

На рис. 2 показаны точность обучения и валидации при обучении на несбалансированном датасете с epochs = 5000 и validation\_split = 0.2.

Исходя из полученных результатов, было выбрано количество прохождений от начала датасета и до конца (epoch) = 4000, количество данных для валидации (validation\_split) = 0.2.

**Обучение нейронной сети.** Чтобы гарантировать корректность работы искусственной нейронной сети, выборка была поделена на две части: обучающие данные для

**Таблица 3.** Подбор параметров на сбалансированном датасете

Эпохи	Валидация	Точность тренировки	Точность валидации	Потери тренировки	Потери валидации	Вывод
500	0.2	0.1–0.9	0.9–0	0.3–0	0.2–1	Не удовлетворяет
1000	0.2	1	0	0.2–0	0.3–1	Не удовлетворяет
200	0.2	0.1–0.9	0.9–0	0.3–0	0.2–0.8	Не удовлетворяет
100	0.2	1	0	0.13–0.3	0.45–0.8	Не удовлетворяет
1000	0.1	0.2–0.82	1–0	0.31–0	0.2–0.67	Не удовлетворяет
500	0.1	0.18–0.81	1–0	0.3–0	0.2–0.7	Не удовлетворяет
200	0.1	0.82	0	0.1–0	0.45–0.7	Не удовлетворяет
100	0.1	0.19–0.81	1–0	0.35–0	0.1–0.7	Не удовлетворяет
100	0.05	0.2–0.79	1–0	0.27–0.15	0.2–0.45	Не удовлетворяет
100	0.02	0.21–0.78	1–0	0.3–0.2	0.15–0.4	Не удовлетворяет

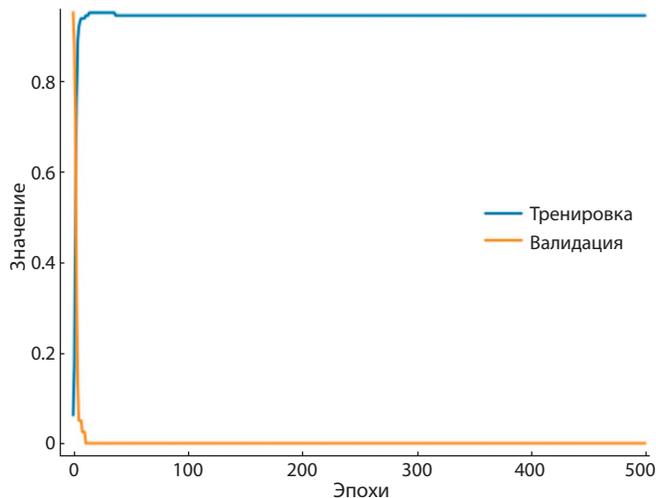


Рис. 1. Пример графика точности обучения и точности валидации при обучении на сбалансированном датасете.

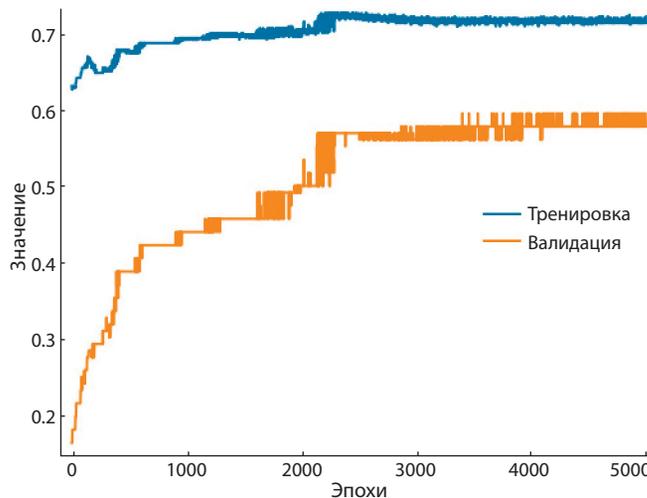


Рис. 2. Пример графика точности обучения и точности валидации при обучении на несбалансированном датасете.

Таблица 4. Подбор параметров на несбалансированном датасете

Эпохи	Валидация	Точность тренировки	Точность валидации	Потери тренировки	Потери валидации	Вывод
1000	0.1	0.6–0.68	0.9–0.85	0.22–0.2	0.16–0.15	Не удовлетворяет
1000	0.05	0.9	0	0	0.9	Не удовлетворяет
1000	0.2	0.13–0.72	0–0.82	0.37–0.2	0.45–0.2	Удовлетворяет
3000	0.2	0.13–0.7	0–0.8	0.37–0.19	0.45–0.2	Удовлетворяет
4000	0.2	0.12–0.73	0–0.84	0.37–0.18	0.45–0.2	Удовлетворяет

Таблица 5. Проверка адекватности обучения

№	1	2	3	4	5	6	7	8
Категория	1	1	0	1	0	0	0	0
Результат	0.767	0.824	0.24	0.927	0.316	0.293	0.276	0.367

Примечание. 0 – с диагностированной депрессией; 1 – без депрессии.

обучения и проверочные данные для проверки работы нейронной сети.

Для обучения были использованы методы `compile` и `fit`. Аргументы метода `compile`: оптимизатор, функция потерь, метрики, веса потерь, список метрик. В методе `fit` аргументы: входные данные, целевые данные, количество выборок, количество эпох, список обратных вызовов, количество данных на валидацию (<https://pandas.pydata.org/pandas-docs/stable/>).

Аргументы, используемые в методе `compile`:

- `loss = "mse"` – среднеквадратическая ошибка:

$$E[(X - \hat{X})^2] = E[(X - g(Y))^2], \quad (3)$$

пусть  $\hat{X} = g(Y)$  – оценка случайной величины  $X$ , учитывающая наблюдение за случайной величиной  $Y$  (<https://www.journaldev.com/45330/relu-function-in-python/>);

- `optimizer = "sgd"` – оптимизатор градиентного спуска с учетом импульса (<https://keras.io/api/optimizers/sgd/>);
- `metrics = ["accuracy"]`.

Аргументы, используемые в методе `fit`:

- $x$  – входные данные;
- $y$  – целевые данные, т. е. оценка;
- `epochs = "4000"` – количество эпох;
- `validation_split = "0.2"` – количество данных на валидацию, используемых в обучающей выборке.

**Проверка адекватности обучения.** Тестирование адекватности обучения проводится на данных, которых не было в обучающих выборках, т. е. используются новые для нейронной сети данные.

Пример последовательности значений (`PSurvived`), полученных в результате работы нейронной сети, с учетом категории данных приведен в табл. 5.

## Результаты

**Технические испытания.** Для технических испытаний нейронной сети были выбраны данные, полученные в ходе экспериментов с использованием нашей системы тестирования показателей моторного контроля у человека

**Таблица 6.** Результаты работы нейронной сети

№	Категория тестируемого	Результат работы нейронной сети	Оценка на основе результата нейронной сети
1	Без экспертной оценки на наличие депрессии	0.8637	Здоровый
2	»	0.5195	Здоровый
3	»	0.6937	Здоровый
4	»	0.7821	Здоровый
5	»	0.7885	Здоровый
6	»	0.4915	Предполагаемо с риском возникновения депрессии
7	»	0.8123	Здоровый
8	»	0.2868	Предполагаемо с риском возникновения депрессии
9	Без экспертной оценки	0.7568	Здоровый
10	С диагностированной депрессией	0.1478	Риск возникновения депрессии – соответствует категории
11	Здоровый	0.9487	Здоровый – соответствует категории
12	С диагностированной депрессией	0.3227	Риск возникновения депрессии – соответствует категории
13	»	0.3114	Риск возникновения депрессии – соответствует категории
14	»	0.2721	Риск возникновения депрессии – соответствует категории
15	»	0.2993	Риск возникновения депрессии – соответствует категории

(без экспертной оценки на наличие депрессии, т. е. без клинического подтверждения), и ранее не использованные данные, которые не участвовали в обучающей выборке (с экспертной оценкой).

Целью технических испытаний является исследование того, как разработанная нейронная сеть будет справляться с классификацией на наличие рисков возникновения депрессии по данным стоп-сигнал парадигмы.

**Входные данные.** Для технических испытаний нейронной сети были выбраны следующие входные данные:

- несбалансированный датасет (0.37 – с диагностированной депрессией, 0.63 – без депрессии);
- максимальное количество пропущенных ответов – 85;
- максимальное суммарное количество правильных ответов у тестируемого – 92;
- максимальное среднее время за эксперимент у тестируемого – 750.0;
- максимальное количество верных игнорирований на стоп-сигнал у тестируемого – 34;
- максимальное количество верных ответов в блоке «практика» у тестируемого – 31;
- максимальное количество правильных ответов без учета стоп-сигнала – 65;
- максимальное количество неверных реакций на стоп-сигнал – 35;
- количество данных для валидации – 0.2, количество эпох – 4000.

**Результаты испытаний.** В табл. 6 описаны результаты работы нейронной сети с оценкой полученных значений.

Таким образом, в ходе технических испытаний получены результаты работы нейронной сети, которые демонстрируют, к какой категории (здоровый/с риском возникновения депрессии) относится тестируемый. По-

лученные показатели полностью соответствуют поставленным диагнозам.

### Заключение

На основе экспериментальных данных, полученных с помощью ССП, был сформирован датасет. Разработана реализация нейронной сети для диагностирования риска возникновения депрессии по данным ССП и далее протестирована. На примере данных с экспертной оценкой на наличие депрессии и данных, полученных с использованием системы тестирования показателей моторного контроля, была продемонстрирована точность классификации нейронной сети. Результаты испытаний в виде показателей качества исполнения нейронной сети описаны ниже:

Показатель	Значение
Потери обучения	0.1657
Точность обучения	0.7821
Потери валидации	0.2415
Точность валидации	0.6667

Методика стоп-сигнал обычно используется для диагностики двигательных нарушений, таких как болезнь Паркинсона, детская гиперактивность или посттравматические расстройства. Ранее для диагностики депрессии методика стоп-сигнала никем не применялась. Мы использовали данную методику в сочетании с методами нейронных сетей и показали, что результаты ССП дают возможность эффективно классифицировать людей на больных депрессией и без депрессии. Необходимо также отметить, что мы не сравнивали больных депрессией с больными с заболеваниями, не связанными с депрессией, неврологическими. Поэтому в данный момент еще не ясно, позволяет ли наш метод разделять больных разными расстройствами на различные подклассы.

## Список литературы / References

- Виноградова Е.Ю. Принципы выбора оптимальной топологии нейронной сети для поддержки принятия управленческих решений. *Управленец*. 2012;7-8:74-78.  
[Vinogradova E.Yu. Principles of choosing the optimal topology of neural network to support managerial decision making. *Upravlenets = The Manager*. 2012;7-8:74-78. (in Russian)]
- Нормализация входных векторов (Normalization) – Loginom Wiki [Электронный ресурс]. URL: <https://wiki.loginom.ru/articles/normalization.html>.  
[Normalization of input vectors (Normalization) – Loginom Wiki [Electronic resource]. URL: <https://wiki.loginom.ru/articles/normalization.html>.]
- Хайкин С. Нейронные сети. Полный курс. М.: Вильямс, 2006.  
[Haykin S. Neural Networks. A Comprehensive Foundation. Moscow: Williams Publ., 2006. (in Russian)]
- About Keras [Электронный ресурс]. URL: <https://keras.io/about/>.  
Dense layer [Электронный ресурс]. URL: [https://keras.io/api/layers/core\\_layers/dense/](https://keras.io/api/layers/core_layers/dense/).  
Layer activation functions [Электронный ресурс]. URL: <https://keras.io/api/layers/activations/>.  
Matplotlib documentation – Matplotlib 3.5.1 documentation [Электронный ресурс]. URL: <https://matplotlib.org/stable/index.html>.  
Mean Squared Error (MSE) [Электронный ресурс]. URL: [https://www.probabilitycourse.com/chapter9/9\\_1\\_5\\_mean\\_squared\\_error\\_MSE.php](https://www.probabilitycourse.com/chapter9/9_1_5_mean_squared_error_MSE.php).  
Model training APIs [Электронный ресурс]. URL: [https://keras.io/api/models/model\\_training\\_apis/](https://keras.io/api/models/model_training_apis/).  
Models API [Электронный ресурс]. URL: <https://keras.io/api/models/>.  
Pandas documentation – pandas 1.4.2 documentation [Электронный ресурс]. URL: <https://pandas.pydata.org/pandas-docs/stable/>.  
ReLU Function in Python – JournalDev [Электронный ресурс]. URL: <https://www.journaldev.com/45330/relu-function-in-python>.  
SGD [Электронный ресурс]. URL: <https://keras.io/api/optimizers/sgd/>.  
Ivanov R., Kazantsev F., Zavarzin E., Klimenko A., Milakhina N., Matushkin Yu., Savostyanov A., Lashin S. ICBrainDB: An integrated database for finding associations between genetic factors and EEG markers of depressive disorders. *J. Pers. Med.* 2022;12(1):53. DOI 10.3390/jpm12010053.

---

### ORCID ID

A.E. Saprygin [orcid.org/0000-0001-6789-2953](https://orcid.org/0000-0001-6789-2953)  
P.D. Rudych [orcid.org/0000-0003-3105-6931](https://orcid.org/0000-0003-3105-6931)  
D.A. Lebedkin [orcid.org/0000-0002-4356-9067](https://orcid.org/0000-0002-4356-9067)  
A.N. Savostyanov [orcid.org/0000-0002-3514-2901](https://orcid.org/0000-0002-3514-2901)

**Благодарности.** Обработка данных при помощи нейронной сети выполнена при финансовой поддержке гранта Российского научного фонда № 22-75-10105. Подготовка базы экспериментальных данных выполнена с участием А.Е. Сапрыгина и А.Н. Савостьянова в рамках бюджетного проекта ИЦиГ СО РАН № FWNR-2022-0020 «Системная биология и биоинформатика: реконструкция, анализ и моделирование структурно-функциональной организации и эволюции генных сетей человека, животных, растений и микроорганизмов».

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

Поступила в редакцию 19.09.2022. После доработки 20.11.2022. Принята к публикации 21.11.2022.