

## ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ ОПУХОЛЕЙ ГОЛОВНОГО МОЗГА

М. О. Тимошкин<sup>1</sup>, Е. Г. Романова<sup>2</sup>

<sup>1</sup> Московский государственный университет имени М. В. Ломоносова, Москва, Россия

<sup>2</sup> Пензенский государственный университет, Пенза, Россия

<sup>1</sup> max.timoshkin@inbox.ru, <sup>2</sup> romanova.elenar2016@yandex.ru

**Аннотация.** *Актуальность и цели.* Глубокое обучение – это активно развивающаяся область машинного обучения, которая позволяет находить зависимости в слабоструктурированных данных. Актуальность работы заключается в том, что в настоящее время автоматическая классификация типов тканей играет важную роль в компьютерной диагностике. Цель работы заключается в автоматизации процесса определения вида опухоли головного мозга по ее изображению с помощью методов глубокого обучения. *Материалы и методы.* В работе применяются методы глубокого обучения для автоматической классификации вида опухоли головного мозга по ее изображению. *Результаты и выводы.* Было произведено сравнение нейросетевых моделей при различных архитектурах, в различных режимах обучения и при наличии и отсутствии обогащения выборки. В процессе обучения с помощью лучшей архитектуры удалось достичь качества 96 % на валидационной выборке.

**Ключевые слова:** классификация опухолей головного мозга, глубокое обучение, архитектуры нейронных сетей, обогащение выборки, МРТ-изображения, режимы обучения

**Для цитирования:** Тимошкин М. О., Романова Е. Г. Применение нейросетевых алгоритмов глубокого обучения для классификации опухолей головного мозга // Надежность и качество сложных систем. 2024. № 3. С. 51–65. doi: 10.21685/2307-4205-2024-3-6

## APPLICATION OF DEEP LEARNING NEURAL NETWORK ALGORITHMS FOR BRAIN TUMOR CLASSIFICATION

M.O. Timoshkin<sup>1</sup>, E.G. Romanova<sup>2</sup>

<sup>1</sup> Moscow State University named after M.V. Lomonosov, Moscow, Russia

<sup>2</sup> Penza State University, Penza, Russia

<sup>1</sup> max.timoshkin@inbox.ru, <sup>2</sup> romanova.elenar2016@yandex.ru

**Abstract.** *Background.* Deep learning is a rapidly developing area of machine learning that allows you to find dependencies in semi-structured data. The relevance of the work lies in the fact that currently automatic classification of tissue types plays an important role in computer diagnostics. The goal of the work is to automate the process of determining the type of brain tumor from its image using deep learning methods. *Materials and methods.* The work uses deep learning methods to automatically classify the type of brain tumor based on its image. *Results and conclusions.* A comparison was made of neural network models with different architectures, in different training modes, and with and without sample enrichment. During the training process, using the best architecture, it was possible to achieve a quality of 96 % on the validation set.

**Keywords:** brain tumor classification, deep learning, neural network architectures, sample enrichment, MRI images, learning modes

**For citation:** Timoshkin M.O., Romanova E.G. Application of deep learning neural network algorithms for brain tumor classification. *Nadezhnost' i kachestvo slozhnykh sistem = Reliability and quality of complex systems.* 2024;(3):51–65. (In Russ.). doi: 10.21685/2307-4205-2024-3-6

### Введение

Существуют медицинские компании, занимающиеся лечением опухолей головного мозга. Автоматическая классификация типов тканей играет важную роль в компьютерной диагностике. Существуют различные виды опухолей: менингиома, глиома, опухоли гипофиза и др. Дано большое количество изображений трех видов опухолей головного мозга. Требуется автоматизировать

процесс определения вида опухоли, т.е. по изображению опухоли определить ее вид. Автоматизированный процесс определения вида опухоли должен быть как можно более точнее, так как в случае неверно определенного вида опухоли пациенту будет предоставлено несоответствующее медицинское лечение, которое потребует излишних финансовых затрат и может привести даже к смерти пациента.

### Описание данных

Исходные данные представляют собой набор Т1-взвешенных МРТ-изображений с контрастным усилением, содержащих образцы опухолей головного мозга: менингиомы (1), глиомы (2) и опухоли гипофиза (3) [1].

Набор данных опухолей головного мозга содержит 3064 Т1-взвешенных изображения с контрастным усилением от 233 пациентов с тремя видами опухолей головного мозга:

- менингиома (708 изображений-срезов);
- глиома (1426 изображений-срезов);
- опухоль гипофиза (930 изображений-срезов).

Генеральной совокупностью в данном случае будет являться совокупность всевозможных изображений, содержащих один из трех видов опухоли головного мозга.

Объектом является изображение-срез одного (из трех возможных) вида опухоли головного мозга. Совокупность всех объектов образует выборочную совокупность.

Выборка данных была получена после прохождения МРТ и получения различных Т1-взвешенных изображений с контрастным усилением 233 пациентами с опухолью головного мозга. Данное множество изображений (выборка) является подмножеством всевозможных изображений, содержащих один из трех видов опухоли головного мозга (генеральная совокупность).

Можно считать, что данные пациенты были выбраны случайным образом из всего множества больных с опухолью головного мозга. Следовательно, можно считать, что выборка была получена методом бесповторного отбора данных из генеральной совокупности. Кроме того, были соблюдены принципы «равновозможности» и «случайности» попадания единиц в выборочную совокупность. Следовательно, обеспечена репрезентативность собранных данных относительно генеральной совокупности.

В выборку входят изображения-срезы только 233 пациентов с известным видом опухоли. Планируется поступление новых данных – МРТ Т1-взвешенных изображений-срезов опухоли головного мозга для новых пациентов (из генеральной совокупности), для которых вид опухоли необходимо определить (классифицировать) по изображению. Можно считать, что новые пациенты также будут поступать случайным образом из генеральной совокупности, т.е. методом бесповторного отбора из генеральной совокупности. Следовательно, репрезентативность новых данных относительно генеральной совокупности будет обеспечена по тем же причинам, что и для собранных данных.

Цель исследователей, которые осуществляли сбор данных, заключается в разработке подхода, который может автоматически классифицировать опухоли головного мозга по изображению ее среза [2].

Был выполнен анализ пропусков и анализ правдоподобности. Исходные данные не содержат пропусков, все изображения являются правдоподобными, что было выявлено путем их просмотра.

Каждое изображение в выборочной совокупности представляет собой двумерный срез. Набор данных изображений-срезов головного мозга с Т1-взвешиванием был получен в больнице Наньфан, Гуанчжоу, Китай и больнице общего профиля Тяньцзинского медицинского университета, Китай, с 2005 по 2010 г. Было собрано 3064 среза от 233 пациентов, содержащих 708 менингиом, 1426 глиом и 930 опухолей гипофиза. Изображения имеют плоскостное разрешение  $512 \times 512$  с размером пикселя  $0,49 \times 0,49$  мм<sup>2</sup>. Толщина среза – 6 мм, зазор между срезами – 1 мм. Граница опухоли была очерчена вручную тремя опытными радиологами [2].

Таким образом, каждый объект представляется растровым изображением (трехмерным тензором) фиксированного размера. Целевой признак (вид опухоли) является категориальным признаком с тремя различными возможными значениями: менингиома (1), глиома (2), опухоль гипофиза (3).

Набор данных изображений опухолей головного мозга, доступный по ссылке [1], содержит три папки «1», «2», «3», соответствующие изображениям различных классов опухолей: менингиомы, глиомы и опухоли гипофиза соответственно.

### Формальная задача

Дано: множество МРТ-изображений опухолей головного мозга и соответствующих видов опухоли  $\{(x_i, y_i)\}_{i=1}^l$ , где  $x_i$  – трехмерный тензор размерности  $[512, 512, 4]$ ,  $y_i \in Y$ ,  $Y = \{0, 1, 2\}$ .

*Найти:* стратегию, которая классифицирует любой объект из генеральной совокупности  $x \in X$ , т.е. определяет целевую переменную  $y \in Y$ .

*Показатель качества:* точность классификации

$$Accuracy = \frac{P}{N},$$

где  $P$  – количество верно классифицированных объектов;  $N$  – общее количество элементов в выборке.

Все части формальной постановки задачи полностью соответствуют содержательной постановке задачи:

– множество изображений опухолей головного мозга определено как  $\{x_i\}_{i=1}^l$ ;

– множество видов опухолей: (менингиома, глиома, опухоль гипофиза) определено как  $= \{0, 1, 2\}$ .

*Показатель качества* был выбран таким, так как именно он отражает качество классификации, т.е. долю верно классифицированных видов опухоли головного мозга. Большое качество классификатора соответствует большому количеству людей, которым вид опухоли диагностирован верно и, следовательно, большей части больных может быть предоставлено соответствующее медицинское лечение.

### Разбиение выборки

Для сохранения репрезентативности были соблюдены принципы «равновозможности» и «случайности» попадания единиц в выборочную совокупность; был выбран метод бесповторного отбора (табл. 1).

Таблица 1

Разбиение выборки на обучающую, валидационную и контрольную

Выборка	Абсолютные размеры выборки	Относительные размеры выборки
Исходная	3064	100 %
Обучающая	1839	60 %
Валидационная	612	20 %
Контрольная	613	20 %

### Распознавание

Архитектура распознавания для одного объекта (рис. 1) включает шаги:

1. переход от слабоструктурированного описания к первичному структурированному представлению;
2. переход от первичного структурированного представления к основному структурированному представлению;
3. получение выхода для объекта. (Оценка, неявно преобразуемая в апостериорное распределение);
4. принятие окончательного бизнес-решения.

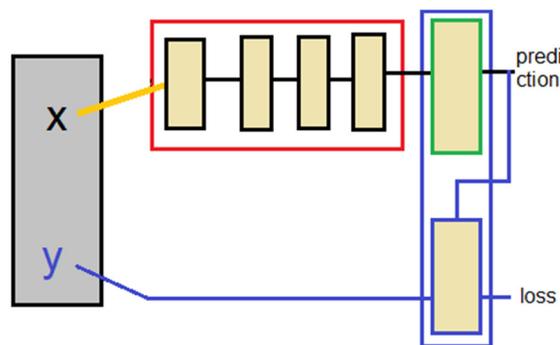


Рис. 1. Архитектура решения для распознавания одного объекта: unstructured  $x$   $\rightarrow$  structured  $\rightarrow$  representation  $\rightarrow$  posterior  $\rightarrow$  prediction

0. На вход подается слабоструктурированное наблюдаемое описание объекта – МРТ-изображение опухоли головного мозга,  $x$ -трехмерный тензор размерности [512, 512, 4], где каждый элемент тензора представляет собой натуральное значение в интервале [0; 255].

1. От слабоструктурированного описания выполняется переход к первичному структурированному представлению. Изображение преобразуется в формат RGB и нормализуется. Структурированное представление –  $x$ -трехмерный тензор размерности [512, 512, 3], где каждый элемент тензора представляет собой вещественное число в интервале [0; 1].

2. От первичного структурированного представления происходит переход к основному структурированному представлению. Переход происходит через несколько промежуточных представлений. Каждое промежуточное представление – это выход некоторого слоя нейронной сети в процессе применения. Основное структурированное представление – выход предпоследнего слоя нейронной сети, который представляет собой вектор некоторого размера и отражает скрытые высокоуровневые свойства данного объекта  $x$ .

3. Получение выхода для объекта. Выход для объекта – это выход последнего слоя нейронной сети в процессе применения, который представляет собой вектор размера 3 (в работе классифицируется три вида опухолей головного мозга) и оценку апостериорного распределения на классы (виды опухолей).

4. Принятие окончательного решения для соответствующего МРТ-изображения опухоли (объекта  $x$ ) определяется по виду опухоли, доставляющему максимум апостериорному распределению (выходу для данного объекта). Математически,  $\bar{y} = \arg \max_{i \in Y} a_i(x)$ , где  $\bar{y}$  – окончательное решение;  $Y = \{0, 1, 2\}$  – множество видов опухолей;  $a(x)$  – выход для объекта  $x$  (оценка апостериорного распределения).

Для прецедентов (объектов с известным скрытым состоянием  $y$ ) дополнительно можно рассчитать фактическое значение функции потерь:

$$L(y, \bar{y}) = [y = \bar{y}] = \begin{cases} 1, & y = \bar{y}, \\ 0, & y \neq \bar{y}. \end{cases}$$

### Переход к структурированному представлению

*Дано:* слабоструктурированное наблюдаемое описание объекта – МРТ-изображение опухоли головного мозга,  $x$ -трехмерный тензор размерности [512, 512, 4], где каждый элемент тензора представляет собой натуральное значение в интервале [0; 255].

Изображение преобразуется в формат RGB. Структурированное представление –  $x$ -трехмерный тензор размерности [512, 512, 3].

Полученный тензор нормализуется, т.е. каждый элемент полученного тензора делится на значение 255. Каждый элемент преобразованного тензора представляет собой вещественное число в интервале [0; 1].

### Обогащение выборки

Обогащение выборки проводится как этап предобработки объекта, т.е. отдельные объекты генерируются очень быстро. Обогащение выборки производится как часть предобработки с помощью библиотеки Keras.

Были выделены следующие допустимые преобразования для обогащения выборки для данной задачи:

- случайное отображение изображения (Random Flip) (рис. 2). В данном случае не уместно только отображение по горизонтали;

- случайный сдвиг изображения (Random Translation) (рис. 3) по горизонтали и вертикали. В данном случае уместны небольшие сдвиги (смещение до 20 %);

- случайный поворот изображения (Random Rotation) (рис. 4). В данном случае уместны только небольшие повороты (менее 45 градусов);

- случайное масштабирование изображения (Random Zoom) (рис. 5) по горизонтали и вертикали. В данном случае уместен небольшой процент масштабирования (менее 20 %);

- случайное изменение контрастности изображения (Random Contrast) (рис. 6). Допустим небольшой коэффициент изменения контрастности;
- случайное изменение яркости изображения (Random Brightness) (рис. 7). Допустим небольшой коэффициент изменения яркости.

Таким образом, для данной содержательной задачи было выделено множество допустимых преобразований для обогащения выборки (рис. 8).

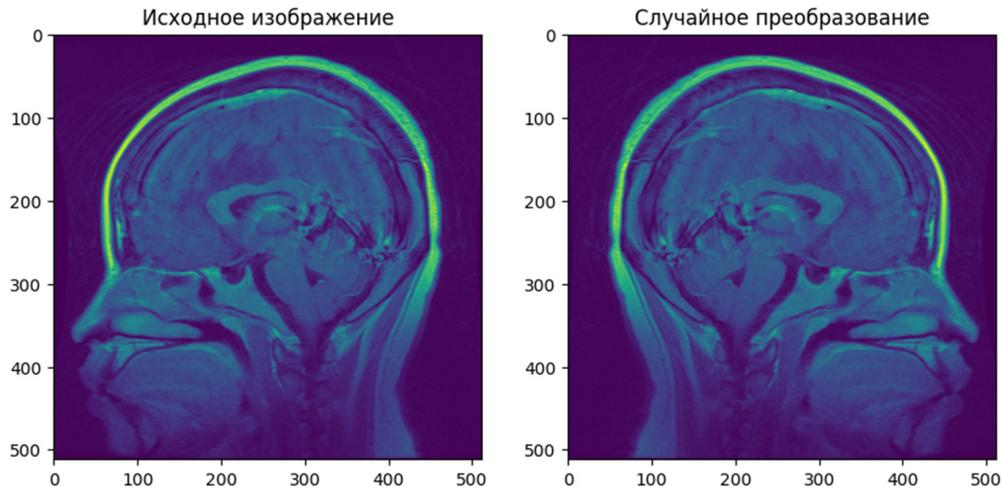


Рис. 2. Случайное отображение изображения по горизонтали

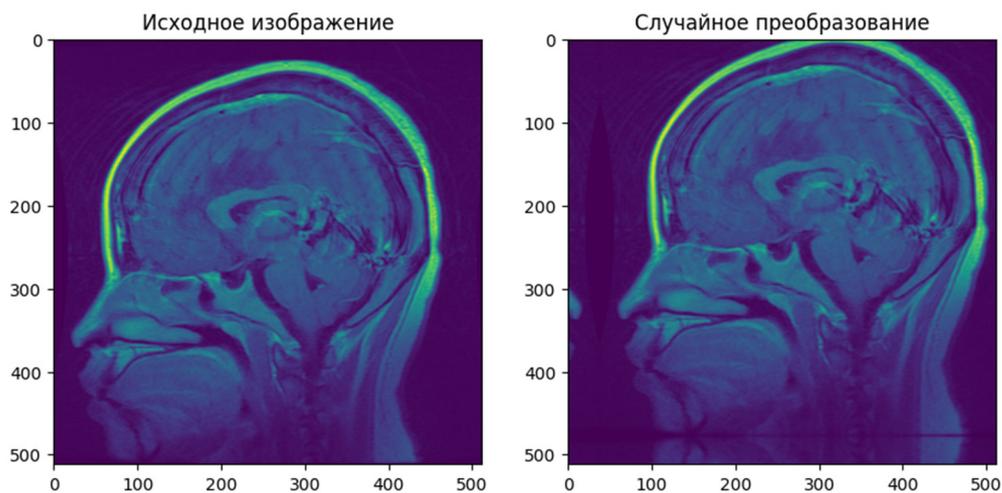


Рис. 3. Случайный сдвиг изображения

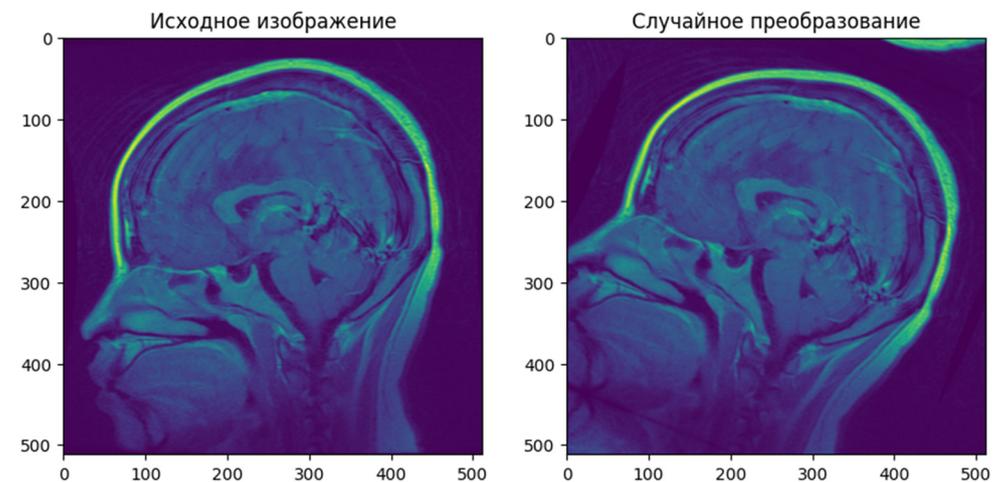


Рис. 4. Случайный поворот изображения

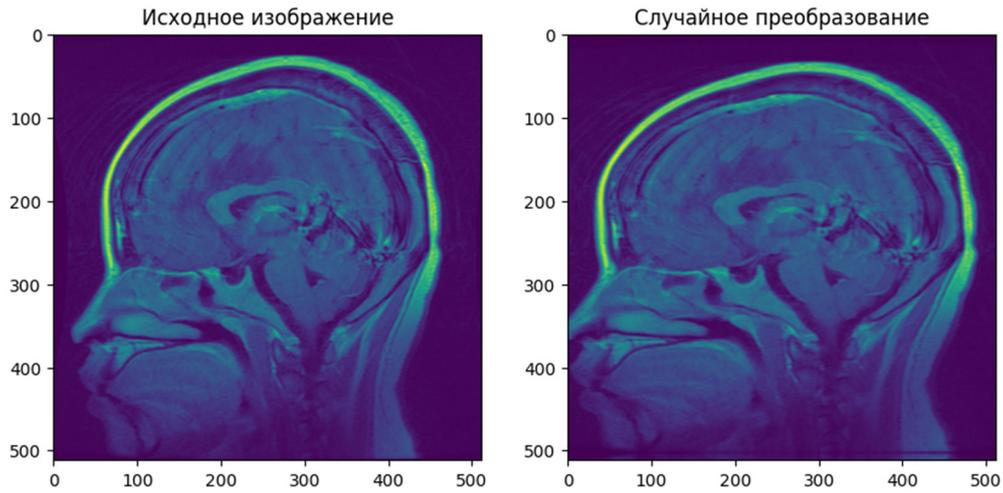


Рис. 5. Случайное масштабирование по горизонтали и вертикали

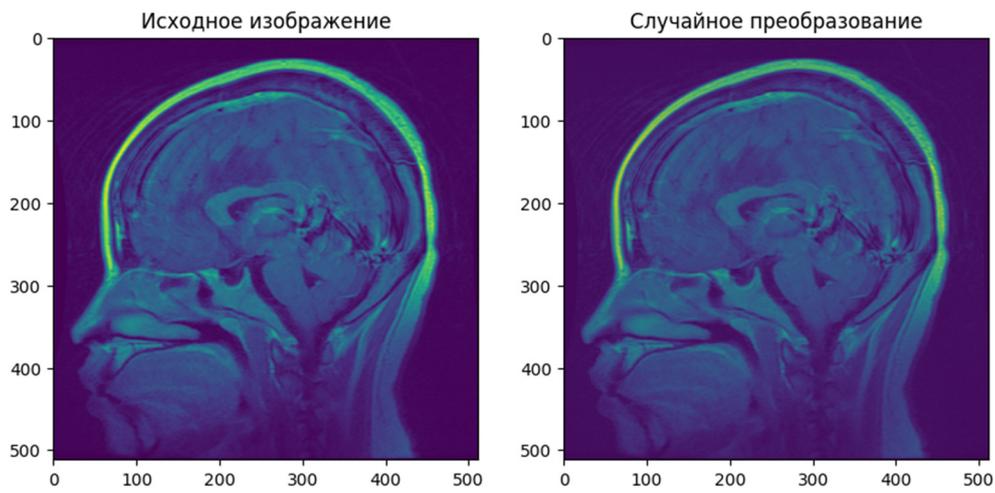


Рис. 6. Случайное изменение контрастности изображения

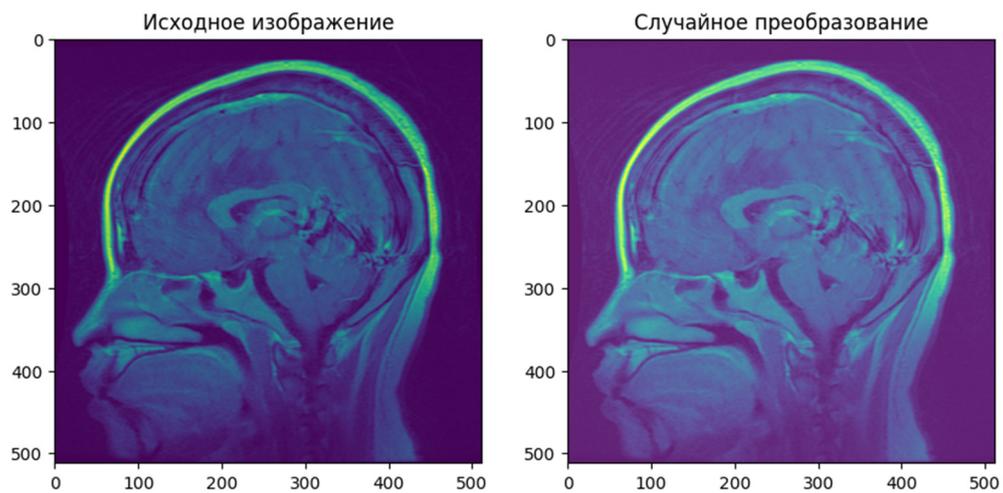


Рис. 7. Случайные изменения яркости изображения

Также было проверено, что обогащение объекта в некоторых случаях помогает при его распознавании. При распознавании по объекту было сгенерировано 50 псевдообъектов при обогащении. Каждый псевдообъект был классифицирован моделью и ответы агрегированы. Изначально модель классифицировала объект неверно, но при обогащении и агрегации модель классифицировала большее количество псевдообъектов (26 / 17 / 7) к верному классу.

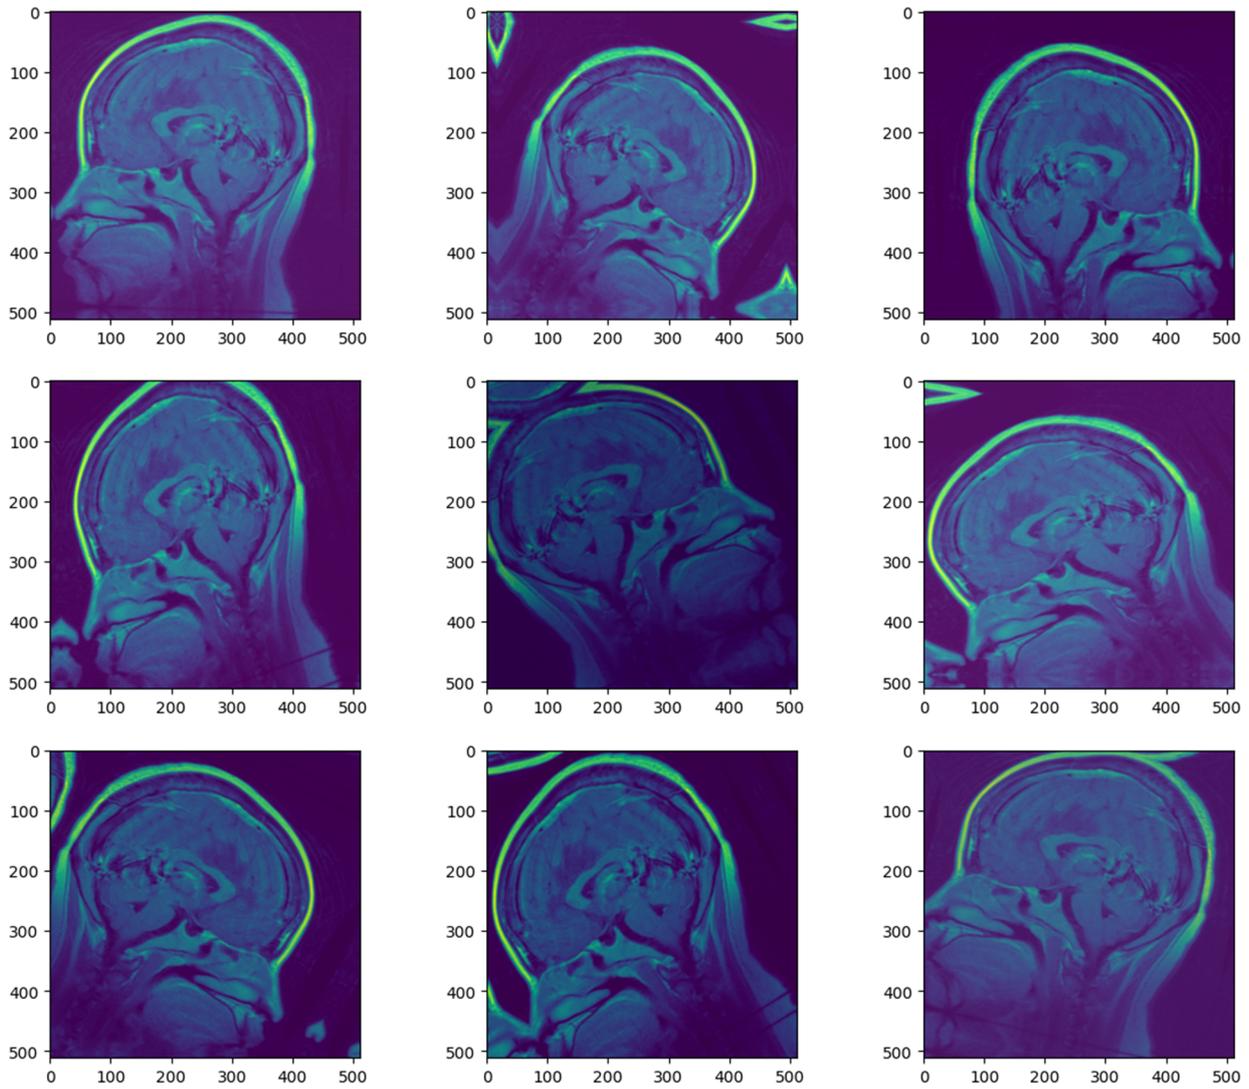


Рис. 8. Визуализация многократного совместного применения всех случайных преобразований для одного изображения

### Разные режимы обучения

Для классификации применялись алгоритмы глубокого обучения. Глубокое обучение – это активно развивающаяся область машинного обучения, которая в настоящее время применяется для решения различных задач [4, 5].

Были рассмотрены несколько архитектур для совместного обучения этапов 2 и 3.

Первая архитектура (рис. 9) состоит из четырех последовательно расположенных сверточных слоев и операции взятия подвыборки (MaxPooling), за которыми идут два полносвязных слоя. Существенный недостаток такой архитектуры заключается в большом числе нейронов в полносвязном слое (262144).

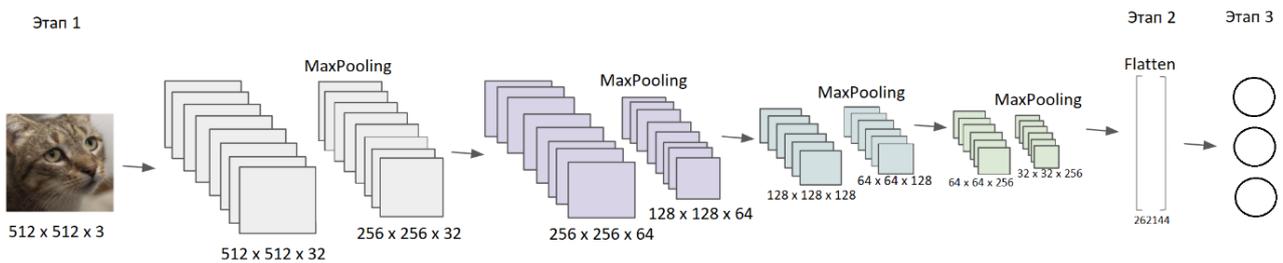


Рис. 9. Архитектура обучения № 1

Недостаток первой архитектуры может быть устранен добавлением еще двух сверточных слоев и уменьшением количества сверток на каждом сверточном слое (рис. 10).

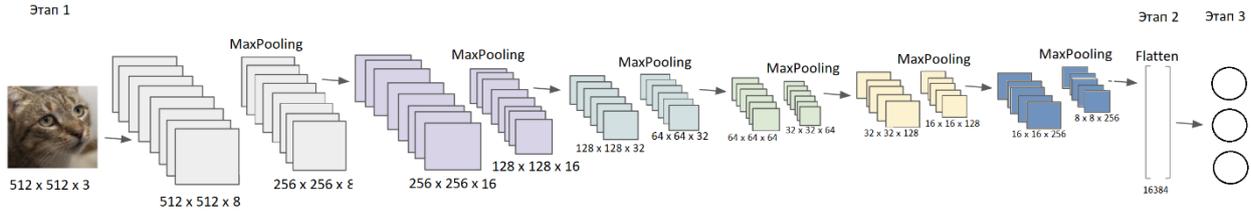


Рис. 10. Архитектура обучения № 2

В третьем виде архитектуры после каждого сверточного слоя и операции взятия подвыборки добавляется пакетная нормализация (Batch Normalization) для более быстрого и стабильного обучения нейронных сетей [6].

Также в данной архитектуре был уменьшен размер вектора основного векторного представления путем добавления дополнительного полносвязного слоя (рис. 11).

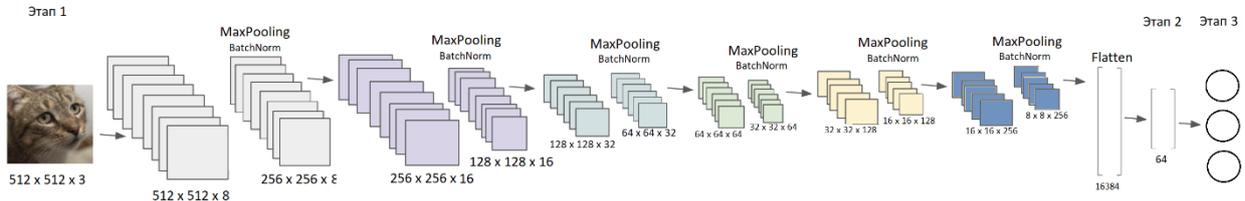


Рис. 11. Архитектура обучения № 3

На этапе 1 для всех трех архитектур имеется трехмерный тензор размерности [512, 512, 3], а на этапе 3 для всех трех архитектур имеется оценка апостериорного распределения на 3 класса (3 вида опухоли). На этапе 2 в зависимости от вида архитектуры были получены векторы различного размера:

- 1) вектор размера 262.144;
- 2) вектор размера 16.384;
- 3) вектор размера 64.

Следует отметить, что до получения основного представления было получено множество промежуточных представлений (рис. 9–11).

Обработка объектов осуществлялась индивидуально, т.е. была построена последовательная модель, в которой от основного представления выполнялся переход сразу к апостериорному распределению. Использовалась Cross-Entropy функция потерь:

$$H(p, q) = - \sum_x p(x) \cdot \log q(x),$$

$p(x)$  – истинное распределение на классы  $y \in Y$ ;  $q(x)$  – распределение на классы  $y \in Y$ , предсказанное моделью;  $Y = \{0, 1, 2\}$  – множество видов опухолей.

1. Были рассмотрены несколько режимов обучения.

1) обучение производилось по жестким классам (использовалось One-Hot кодирование как истинное распределение на классы  $p(x)$ ), т.е. для объекта  $(x, y)$  верное распределение на классы было следующим:

$$p_z(x) = \begin{cases} 1, & z = y \\ 0, & z \neq y \end{cases}, \quad z \in Y = \{0, 1, 2\};$$

2) обучение производилось по классам со сглаживанием меток (label smoothing) [8]:

$$p'_y(x) = (1 - \varepsilon) p_y(x) + \varepsilon u(y|x),$$

$u(y|x)$  – распределение шума;  $\varepsilon \in [0; 1]$ .

Также обработка объектов производилась наборами.

2. Обучение по парам объектов («сиамская архитектура», contrastive loss). Для получения основного векторного представления для каждого объекта пары (Этап 2) использовалась сверточная нейронная сеть из пяти последовательных сверточных слоев (включающих операции свертки, Max-Pooling и пакетную нормализацию) и двух полносвязных слоев (по 64 и 10 нейронов). Таким образом, эмбединг каждого объекта в данной архитектуре представляет собой вектор размера 10. Во время обучения для расчета расстояния между эмбедингами использовалось евклидово расстояние.

После обучения векторных представлений таким образом был отдельно обучен этап 3 (получение оценок апостериорных вероятностей).

3. Обучение по тройкам объектам (triplet loss) с отбором троек. Для обучения эмбединга по тройкам использовалась точно такая же архитектура нейронной сети, как в режиме 2. Таким образом, эмбединг каждого объекта представляет собой также вектор размера 10.

Следует отметить, что обучение во всех рассмотренных режимах производилось для архитектуры № 3, так как она продемонстрировала наилучшее качество при обучении. Другие архитектуры были обучены только в режиме обучения 1.1.

Также следует отметить, что архитектура модели при обучении и применении сильно отличается. В режимах обучения 1.1 и 1.2 обучение этапа 2 и 3 производится совместно. В режимах обучения 2, 3 обучение этапа 2 (построение векторного представления) происходит отдельно от этапа 3 (получение оценок апостериорных вероятностей).

Во время обучения этапа 3 веса нейронной сети, обученной для построения эмбединга, не изменялись.

### Сравнение систем и окончательные выводы

Для корректности проводимого эксперимента обучение моделей всех архитектур производилось в течение 20 эпох. Для различных архитектур моделей и при наличии/отсутствии обогащения выборки было оценено качество моделей на обучающей и валидационной выборках (табл. 1). Из данной таблицы следует вывод, что для получения хорошего качества при обучении на обогащенной выборке требуется большее число эпох.

Таблица 1

Качество моделей различных архитектур при наличии/отсутствии обогащения выборки на обучающей и валидационной выборках

Модель	Наличие / отсутствие	Обучающая выборка	Валидационная выборка
№ 1	Без обогащения	1,00	0,90
	С обогащением	0,84	0,84
№ 2	Без обогащения	1,00	0,93
	С обогащением	0,90	0,85
№ 3	Без обогащения	1,00	0,96
	С обогащением	0,89	0,90

Были построены диаграммы качества моделей для различных архитектур моделей и при наличии/отсутствии обогащения выборки на обучающей и валидационной выборках (рис. 12, 13).

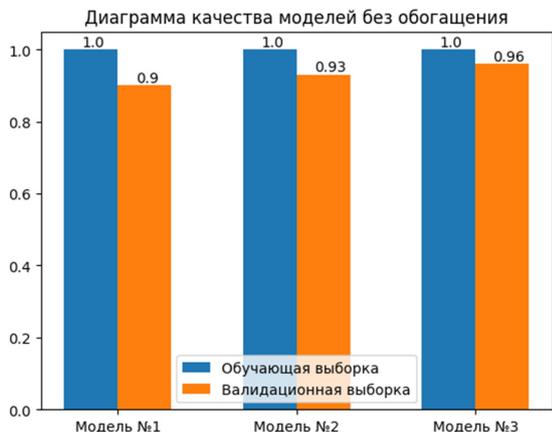


Рис. 12. Диаграмма качества моделей без обогащения

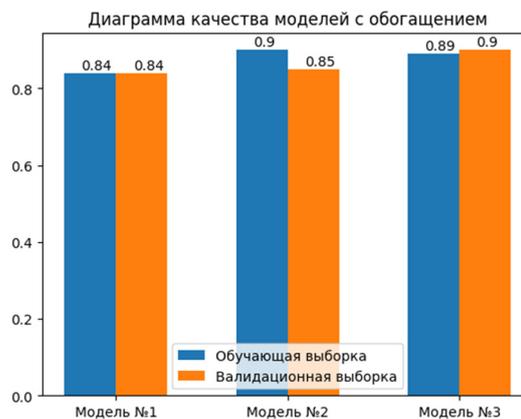


Рис. 13. Диаграмма качества моделей с обогащением

Было произведено сравнение времени обучения (всех модели также обучались ровно 20 эпох для чистоты эксперимента) и применения моделей всех рассмотренных архитектур при наличии/отсутствии обогащения выборки (табл. 2).

Таблица 2

Время обучения и применения моделей различных архитектур при наличии/отсутствии обогащения выборки

Модель	Наличие / отсутствие	Время обучения	Время применения
№ 1	Без обогащения	7 м 23 с	7 с
	С обогащением	11 м 10 с	6 с
№ 2	Без обогащения	4 м 47 с	7 с
	С обогащением	4 м 23 с	7 с
№ 3	Без обогащения	4 м 37 с	7 с
	С обогащением	5 м 1 с	7 с

Из данной таблицы видно, что время обучения моделей существенно отличается, а время применения практически одинаково.

Модель архитектуры № 3 была обучена в различных режимах обучения, было оценено качество (табл. 3) и время обучения/применения соответствующих моделей (табл. 4).

Таблица 3

Качество моделей при различных режимах обучения этапа 2 при наличии/отсутствии обогащения выборки на обучающей и валидационной выборках

Режим обучения	Наличие / отсутствие	Обучающая выборка	Валидационная выборка
Обучение по жестким классам	Без обогащения	1,00	0,96
	С обогащением	0,89	0,90
Обучение со сглаживанием меток	Без обогащения	1,00	0,96
	С обогащением	0,92	0,90
Обучение по парам объектов	Без обогащения	0,88	0,89
	С обогащением	0,88	0,90
Обучение по тройкам объектов	Без обогащения	0,63	0,63
	С обогащением	0,61	0,63

Таблица 4

Время обучения и применения моделей в различных режимах обучения при наличии/отсутствии обогащения выборки

Режим обучения	Наличие / отсутствие	Время обучения	Время применения
Обучение по жестким классам	Без обогащения	6 м 43 с	7 с
	С обогащением	5 м 32 с	7 с
Обучение со сглаживанием меток	Без обогащения	7 м 6 с	7 с
	С обогащением	4 м 40 с	9 с
Обучение по парам объектов	Без обогащения	7 м 10 с	1 с
	С обогащением	6 м 3 с	1 с
Обучение по тройкам объектов	Без обогащения	1 м 3 с	1 с
	С обогащением	1 м 10 с	1 с

Были построены диаграммы качества моделей в различных режимах обучения и при наличии/отсутствии обогащения выборки на обучающей и валидационной выборках (рис. 14, 15).

Модель-победитель выбиралась по качеству на валидационной выборке среди всех моделей. Моделью-победителем оказалась модель архитектуры № 3 без обогащения, достигшая качества 0,96 на валидационной выборке (и качества 1,0 на тренировочной выборке). Также для модели-победителя была получена точечная оценка качества на контрольной выборке: 0,989.





основного векторного представления объекты также будут обладать такой кластерной структурой, что и позволяет выполнять их верную классификацию.

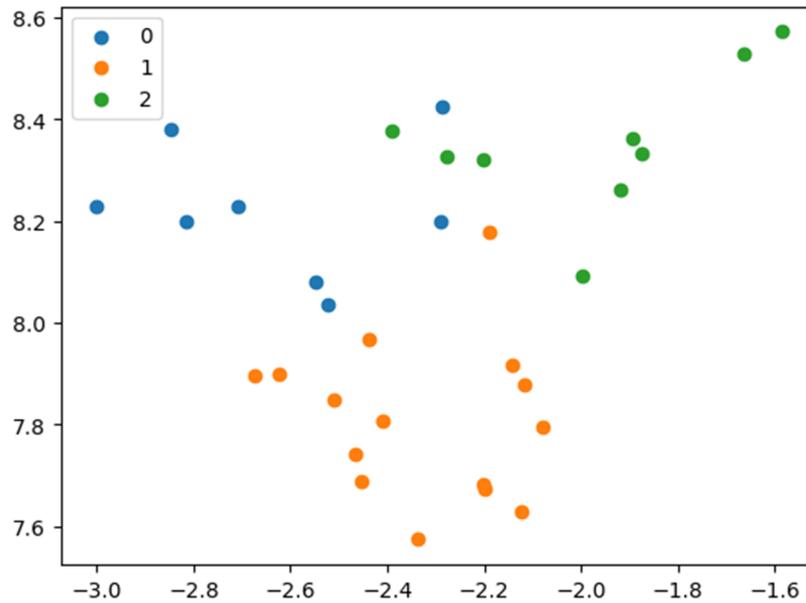


Рис. 19. Визуализация основного векторного представления пакета объектов тренировочной выборки на двумерной плоскости с помощью T-SNE

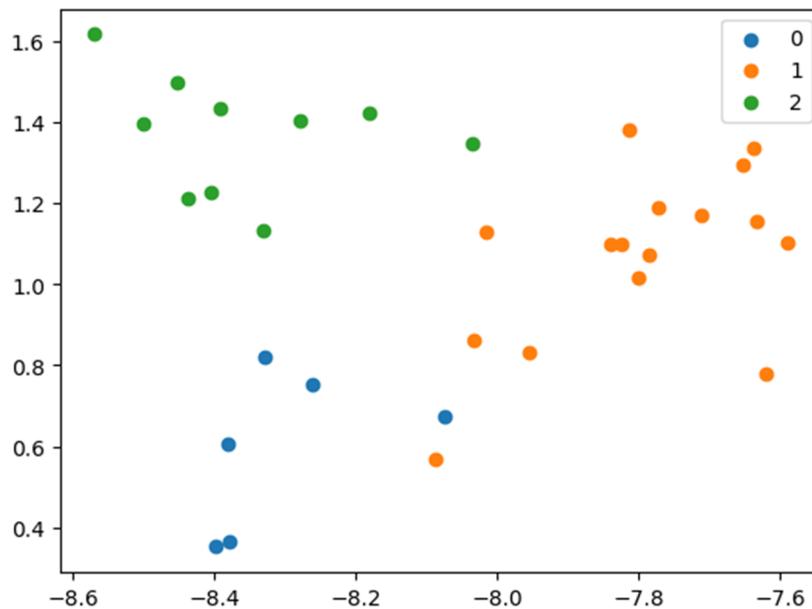


Рис. 20. Визуализация основного векторного представления пакета объектов валидационной выборки на двумерной плоскости с помощью T-SNE

### Заключение

Таким образом, в ходе написания данной работы:

- была поставлена содержательная задача автоматизации процесса определения вида опухоли;
- были описаны генеральная совокупность, выборка, объекты и данные для поставленной задачи;
- была сформулирована формальная постановка задачи;
- произведено разбиение выборки с сохранением репрезентативности;
- был описан и программно реализован процесс распознавания объекта, т.е. процесс применения обученных моделей классификации различных архитектур;

– был описан и программно реализован переход от слабоструктурированного представления к структурированному представлению;

– было произведено обогащение выборки и произведено обучение моделей в различных режимах обучения и различных архитектур моделей при наличии и отсутствии обогащения;

– были описаны четыре режима обучения моделей для поставленной задачи;

– была описана попытка интерпретируемости основного векторного представления;

– произведено сравнение времени обучения и применения моделей; сравнение качества распознавания моделей. Сравнение качества по выборке было осуществлено не только точечной оценкой, но доверительным интервалом, полученным приближенно с помощью метода bootstrap. Окончательным победителем оказалась архитектура № 3.

### Список литературы

1. Brain Tumor Image Dataset. URL: <https://www.kaggle.com/datasets/denizkavi1/brain-tumor> (дата обращения: 20.03.24).
2. Cheng J. Enhanced performance of brain tumor classification via tumor region augmentation and partition // *PloS one*. 2015. Т. 10, № 10. С. e0140381.
3. Оценка моделей. URL: [http://www.machinelearning.ru/wiki/images/archive/5/54/20151010103437!Kitov-ML-05-Model\\_evaluation.pdf](http://www.machinelearning.ru/wiki/images/archive/5/54/20151010103437!Kitov-ML-05-Model_evaluation.pdf) (дата обращения: 20.03.24).
4. Тимошкин М. О., Романова Е. Г. Применение метода Q-обучения для оптимизации производств // Аналитические и численные методы моделирования естественно-научных и социальных проблем : сб. ст. по материалам науч.-техн. конф. Пенза : Изд-во ПГУ, 2021. С. 100–107.
5. Тимошкин М. О., Романова Е. Г. Применение метода глубокого Q-обучения для обучения агентов в логических играх // Математическое и компьютерное моделирование естественно-научных и социальных проблем : материалы XVI Всерос. науч.-техн. конф. Пенза : Изд-во ПГУ, 2022. С. 199–206.
6. Генеральная совокупность – 2022. URL: [https://ru.wikipedia.org/wiki/Генеральная\\_совокупность](https://ru.wikipedia.org/wiki/Генеральная_совокупность) (дата обращения: 20.03.24).
7. Основы теории статистики – 2022. URL: <https://elar.urfu.ru/bitstream/10995/34746/1/978-5-7996-1520-8.pdf> (дата обращения: 20.03.24).
8. Label Smoothing. 2023. URL: <https://leimao.github.io/blog/Label-Smoothing/> (дата обращения: 20.03.24).
9. Image similarity estimation using a Siamese Network with a contrastive loss. 2023. URL: [https://keras.io/examples/vision/siamese\\_contrastive/](https://keras.io/examples/vision/siamese_contrastive/) (дата обращения: 20.03.24).
10. Batch normalization. URL: [https://en.wikipedia.org/wiki/Batch\\_normalization](https://en.wikipedia.org/wiki/Batch_normalization) (дата обращения: 20.03.24).
11. Репрезентативность. 2022. URL: <https://ru.wikipedia.org/wiki/Репрезентативность> (дата обращения: 20.03.24).
12. Звенигородский И. И., Зырянов Ю. Т., Ульшин Д. И. Использование нейросетевых регуляторов для повышения энергоэффективности и качества системы вентиляции и кондиционирования воздуха заглубленного сооружения // *Надежность и качество сложных систем*. 2023. № 1. С. 99–105.
13. Иванов А. И., Иванов А. П., Горбунов К. А. Нейросетевое преобразование биометрии в код аутентификации: дополнение энтропии хэмминга энтропией корреляционных связей между разрядами // *Надежность и качество сложных систем*. 2023. № 1. С. 91–98.
14. Иванов А. И., Кубасов И. А. Сильный искусственный интеллект: повышение качества нейросетевых решений с переходом к обработке входных данных большого объема // *Надежность и качество сложных систем*. 2021. № 1. С. 9–16.

### References

1. *Brain Tumor Image Dataset*. Available at: <https://www.kaggle.com/datasets/denizkavi1/brain-tumor> (accessed 20.03.24).
2. Cheng J. Enhanced performance of brain tumor classification via tumor region augmentation and partition. *PloS one*. 2015;10(10):e0140381.
3. *Otsenka modeley = Evaluation of models*. (In Russ.). Available at: [http://www.machinelearning.ru/wiki/images/archive/5/54/20151010103437!Kitov-ML-05-Model\\_evaluation.pdf](http://www.machinelearning.ru/wiki/images/archive/5/54/20151010103437!Kitov-ML-05-Model_evaluation.pdf) (accessed 20.03.24).
4. Timoshkin M.O., Romanova E.G. Application of the Q-learning method for production optimization. *Analiticheskie i chislennyye metody modelirovaniya estestvenno-nauchnykh i sotsial'nykh problem: sb. st. po materialam nauch.-tekhn. konf. = Analytical and numerical methods for modeling natural science and social problems : collection of articles based on the materials of scientific and technical conf.* Penza: Izd-vo PGU, 2021:100–107. (In Russ.)
5. Timoshkin M.O., Romanova E.G. Application of the deep Q-learning method for training agents in logic games. *Matematicheskoe i komp'yuternoe modelirovanie estestvenno-nauchnykh i sotsial'nykh problem: materialy XVI*

- Vseros. nauch.-tekhn. konf.* = *Mathematical and computer modeling of natural science and social problems : materials of the XVI All-Russian scientific and technical conf.* Penza: Izd-vo PGU, 2022:199–206. (In Russ.)
6. *General'naya sovokupnost' – 2022 = General combination – 2022.* (In Russ.). Available at: [https://ru.wikipedia.org/wiki/General'naya\\_sovokupnost'](https://ru.wikipedia.org/wiki/General'naya_sovokupnost') (accessed 20.03.24).
  7. *Osnovy teorii statistiki – 2022 = Fundamentals of the theory of statistics – 2022.* (In Russ.). Available at: <https://elar.urfu.ru/bitstream/10995/34746/1/978-5-7996-1520-8.pdf> (accessed 20.03.24).
  8. *Label Smoothing.* 2023. Available at: <https://leimao.github.io/blog/Label-Smoothing/> (accessed 20.03.24).
  9. *Image similarity estimation using a Siamese Network with a contrastive loss.* 2023. Available at: [https://keras.io/examples/vision/siamese\\_contrastive/](https://keras.io/examples/vision/siamese_contrastive/) (accessed 20.03.24).
  10. *Batch normalization.* Available at: [https://en.wikipedia.org/wiki/Batch\\_normalization](https://en.wikipedia.org/wiki/Batch_normalization) (accessed 20.03.24).
  11. *Reprezentativnost' = Representativeness.* 2022. (In Russ.). Available at: <https://ru.wikipedia.org/wiki/Reprezentativnost'> (accessed 20.03.24).
  12. Zvenigorodskiy I.I., Zyryanov Yu.T., Ul'shin D.I. The use of neural network regulators to improve energy efficiency and quality of the ventilation and air conditioning system of a buried structure. *Nadezhnost' i kachestvo slozhnykh system = Reliability and quality of complex systems.* 2023;(1):99–105. (In Russ.)
  13. Ivanov A.I., Ivanov A.P., Gorbunov K.A. Neural network transformation of biometrics into authentication code: addition of hamming entropy by entropy of correlations between bits. *Nadezhnost' i kachestvo slozhnykh system = Reliability and quality of complex systems.* 2023;(1):91–98. (In Russ.)
  14. Ivanov A.I., Kubasov I.A. Strong artificial intelligence: improving the quality of neural network solutions with the transition to processing large-volume input data. *Nadezhnost' i kachestvo slozhnykh system = Reliability and quality of complex systems.* 2021;(1):9–16. (In Russ.)

### Информация об авторах / Information about the authors

#### Максим Олегович Тимошкин

студент,  
Московский государственный университет  
имени М. В. Ломоносова  
(Россия, г. Москва, ул. Ленинские Горы, 1)  
E-mail: max.timoshkin@inbox.ru

#### Maksim O. Timoshkin

Student,  
Moscow State University  
named after M.V. Lomonosov  
(1 Leninskie Gory street, Moscow, Russia)

#### Елена Геннадьевна Романова

кандидат технических наук, доцент,  
доцент кафедры высшей и прикладной математики,  
Пензенский государственный университет  
(Россия, г. Пенза, ул. Красная, 40)  
E-mail: romanova.elenar2016@yandex.ru

#### Elena G. Romanova

Candidate of technical sciences, associate professor,  
associate professor of the sub-department of higher  
and applied mathematics,  
Penza State University  
(40 Krasnaya street, Penza, Russia)

**Авторы заявляют об отсутствии конфликта интересов /**

**The authors declare no conflicts of interests.**

**Поступила в редакцию / Received 20.06.2024**

**Поступила после рецензирования / Revised 27.07.2024**

**Принята к публикации / Accepted 30.08.2024**