

УДК 004.032.26, 004.932.2

Д. Н. Тумаков¹, А. Р. Бердигулов¹, Д. И. Хайруллина¹, И. И. Бариев²

¹Институт вычислительной математики и информационных технологий,
Федеральное государственное автономное образовательное учреждение высшего
образования «Казанский (Приволжский) федеральный университет»
420008, г. Казань, ул. Кремлевская, 18

²Автономная некоммерческая организация высшего образования "Университет Иннополис"
420500, г. Иннополис, ул. Университетская, 1

ПРИМЕНЕНИЕ АНСАМБЛЕЙ НЕЙРОННЫХ СЕТЕЙ ТИПА LENET-5 ДЛЯ ДИАГНОСТИРОВАНИЯ ПНЕВМОНИИ НА РЕНТГЕНОВСКИХ ИЗОБРАЖЕНИЯХ ЛЕГКИХ

D. N. Tumakov¹, A. R. Berdigulov¹, D. I. Khairullina¹, I. I. Bariev²

¹Institute of Computational Mathematics and Information Technology,
Federal State Autonomous Educational Institution of Higher Education "Kazan Federal University"
420008, Kazan, Kremlevskaya St., 18

Autonomous Non-Commercial Organization of Higher Education "Innopolis University"
420500, Innopolis, Universitetskaya St., 1

APPLICATION OF LENET-5-TYPE NEURAL NETWORK ENSEMBLES FOR DIAGNOSING PNEUMONIA IN LUNG X- RAY IMAGES

Рассмотрены ансамбли неглубоких нейронных сетей типа для определения пневмонии по рентгеновским изображениям. Результирующий ответ ансамблей построен по принципу, если хотя бы одна из его нейросетей определила пневмонию, то ансамбль тоже даёт ответ «пневмония». Такой подход по агрегации результатов отдельных нейросетей позволил максимально увеличить полноту (recall) класса «пневмония». Чтобы минимизировать ухудшение точности (precision), которое неизбежно при таком подходе агрегирования, нейросети из ансамбля рассмотрены одного типа – LeNet-5. Предложено шесть архитектур нейросетей, которые получают на вход изображения размером 256 на 256 пикселей и имеют различные размеры сверточных матриц. Также архитектуры рассмотренных сетей имеют разную глубину. На тестовой выборке для оптимальных ансамблей полнота составила 0.991, а точность изменяется в интервале от 0.934 до 0.936.

Ключевые слова: ансамбли нейронных сетей, LeNet-5, полнота, точность, пневмония.

Ensembles of shallow neural networks for identifying pneumonia from X-ray images are considered. The ensemble's resulting response is constructed according to the principle: if at least one of its neural networks identifies pneumonia, the ensemble also returns the answer "pneumonia." This approach to aggregating the results of individual neural networks maximizes the recall of the "pneumonia" class. To minimize the deterioration in precision that is inevitable with this aggregation approach, the ensemble's neural networks are all of the same type—LeNet-5. Six neural network architectures are proposed, each receiving 256 by 256 pixel images as input and having different convolutional matrix sizes. The architectures of the networks considered also have different depths. On the test set, the recall for the optimal ensembles was 0.991, while the precision varied between 0.934 and 0.936.

Key words: neural network ensembles, LeNet-5, recall, precision, pneumonia.

Введение

Сверточные нейронные сети на сегодняшний день широко используются в задачах классификации изображений. Простейшие классические сети, такие как LeNet-5, ориентированные на классификацию изображений небольшого размера, используются в основном для распознавания «простых» объектов [1], [2]. Однако их применение не ограничивается лишь подобными изображениями [3], и сети такого типа также используются в различных модификациях [4], [5] и комбинациях [5], [6] для классификации более сложных объектов.

Нейронная сеть LeNet-5, несмотря на свою простоту, даёт сопоставимые результаты с более сложными архитектурами [7], а зачастую и лучшие, чем такие сети как Handcrafted CNN, MobileNet, VGG16 и VGG19 для определения пневмонии [8]. Также в [9] сделан вывод, что для небольших наборов данных, модели LeNet-5 и AlexNet обеспечивают лучшие результаты классификации пневмонии, чем MobileNet, ResNet18 и Vision Transformer.

После появления первых нейронных сетей постоянно идёт совершенствование их архитектур для достижения лучших результатов в задачах классификации. Также используются и другой подход, называемый ансамблевое обучение, который объединяет несколько архитектур для устранения ограничений одиночных моделей. Два основополагающих исследования [10], [11] заложили основу современных ансамблевых методов, и с тех пор ансамблевое обучение успешно применяется к различным задачам благодаря своей высокой точности. Первоначально разработанные для моделей на основе деревьев решений, такие алгоритмы, как бэггинг и бустинг [12], [13], продемонстрировали как точность, так и устойчивость в области машинного обучения.

В последние годы ансамблевые методы были распространены на глубокое обучение, где несколько нейронных сетей обучаются независимо, а их результаты чаще всего объединяются с помощью голосования большинства или усреднения ответов. Этот подход доказал свою эффективность в снижении переобучения и уменьшении разбросов ответов между отдельными моделями [14], [15]. Ансамбли широко используются для улучшения точности при решении различных задач. Например, в [17] предложена модель для прогнозирования неисправностей промышленного оборудования, в которой использован ансамблевый подход в проведении операции голосования между сверточной нейронной сетью, логистической регрессией и методом опорных векторов. Выбор именно этих алгоритмов обусловлен низкой корреляцией их предсказаний друг с другом. Итоговая вероятность выхода оборудования из строя вычисляется как линейная комбинация трёх моделей с соответствующими весами.

Ансамблевое обучение получило распространение и в области компьютерного зрения, включая обнаружение объектов [17], [18]. Например, в [19] для обработки текстовой и визуальной информации использован ансамбль из трёх моделей LLaVa, CogVLM, Mini-Gemini. В области медицинской визуализации ансамбли также активно применяются для повышения эффективности диагностики [20-22]. В [23] предложена ансамблевая модель глубокого обучения (EDL-COVID) для классификации КТ-изображений, связанных с COVID-19. Этот подход повысил точность до 99,05%, что оказалось существенно лучше прогнозов индивидуальных моделей.

Хотя ансамблевое обучение способствует повышению точности и надежности, производительность в реальном времени остаётся важной в клинических условиях. Большие ансамблевые модели увеличивают потребление памяти и времени, что создаёт трудности для практического применения, особенно на устройствах с ограниченными ресурсами. Поэтому использование нейронных сетей с малым числом весов может существенно снизить требования к аппаратному и программному обеспечению.

Распознавание текстов на медицинских изображениях с помощью ансамблей, содержащих модели на основе нейронной сети LeNet-5 рассмотрено в [24]. Здесь каждый классификатор обучен на отдельном подмножестве, полученном методом бутстрэппинга, и оценивался на оставшихся валидационных данных в каждой итерации обучения. Ансамбль из трёх LeNet-5 с замененными функциями активации на ReLU позволил достичь точности 96% при классификации изображений пневмонии [25]. В [8] построенные ансамбли нейронных сетей с LeNet-5 для класса «пневмония» достигли $\text{recall} = 0.9785$ и $\text{precision} = 0.9830$.

С одной стороны результаты применения ансамблей различных нейронных сетей, в том числе и LeNet-5, дает высокую точность, а с другой стороны, сети типа LeNet-5 дают зачастую результаты, сопоставимую с результатами других нейронных сетей [26], и даже превосходящими их на небольших объемах обучающих данных. Также неглубокие нейронные сети не требуют больших вычислительных мощностей [27]. Принимая все это во внимание, в настоящей работе предпринята попытка рассмотреть ансамбли нейронных сетей типа LeNet-5 для определения пневмонии по рентгеновским снимкам. Результирующий ответ строится по следующему принципу: если хотя бы одна нейросеть в ансамбле определяет класс «пневмония», то общим результатом ансамбля будет тоже класс «пневмония». Такой подход по объединению (агрегации) результатов отдельных нейросетей необходим, чтобы максимально увеличить recall (полноту или чувствительность) класса «пневмония» и не пропустить пациента с заболеванием.

Однако предложенный подход, очевидно, уменьшает метрику precision (точность). Чтобы минимизировать понижение точности, нейросети рассматриваются одного типа. Первая сеть отличается от классической LeNet-5 размером входного изображения – он составляет 256 на 256 пикселей. Остальные нейросети могут отличаться от первой размерами сверточной матрицы – 3 на 3 или 7 на 7 вместо 5 на 5, что позволяет учитывать различные размеры особенностей. Также архитектуры рассмотренных сетей имеют разную глубину, а две сети имеют dropout на последних слоях.

В работе рассмотрено всего шесть вариантов нейронных сетей типа LeNet-5 и всевозможные ансамбли, получаемые этими сетями. Сделаны выводы об оптимальных комбинациях сетей для достижения максимальных метрик.

1 Постановка задачи классификации

Оценим возможности ансамблей простейших нейронных сетей типа LeNet-5 для классификации пневмонии по рентгеновским изображениям лёгких. Чтобы применить подобные сети для анализа рентгеновских изображений, нужно принять во внимание следующий момент. Исходная сеть LeNet-5 используется для работы с изображениями малых размеров – чаще всего 28 на 28 пикселей. Однако для извлечения признаков из рентгеновских изображений, которые в большинстве случаев имеют линейные размеры более тысячи пикселей, в исходной сети необходимо изменить размеры входного изображения, иначе при сильном сжатии начального снимка часть важной информации может быть потеряна. С учетом этого, положим, что на вход нейронной сети будут подаваться изображения размером 256 на 256 пикселей.

На начальном этапе обучим отдельные нейронные сети и оценим их точности. Затем сопоставим истинные и ошибочные результаты, полученные на тестовых выборках предложенных нейронных сетей. Так как рассматриваемые сети имеют близкую архитектуру (к LeNet-5), то стоит ожидать, что результаты классификации не должны сильно отличаться. Однако различия для отдельных случаев пневмонии могут дать возможность большего обнаружения заболеваний.

Наконец, на заключительном этапе рассмотрим и оценим точности получаемых ансамблей в различных комбинациях нейронных сетей, сделав основную ставку на выявление («непропускания») пациентов с пневмонией.

Набор данных содержит 5856 рентгеновских снимка (JPEG) и две категории (пневмония – 4273 снимка и норма – 1583 снимка). Рентгеновские снимки грудной клетки (переднезадние) отобраны из ретроспективных когорт педиатрических пациентов в возрасте от одного до пяти лет из Женского и детского медицинского центра Гуанчжоу. Все рентгенограммы грудной клетки были выполнены в рамках клинического ухода за пациентами и первоначально проверены на контроль качества путем удаления всех некачественных или нечитаемых сканов.

2 Классификация отдельными нейронными сетями

Рассмотрим применение отдельных нейронных сетей для задачи классификации пневмонии. Начнём с модели, наиболее приближенной к классической сети LeNet-5.

Модель 1

Данная модель по структуре полностью совпадает с классической LeNet-5, отличаясь размерами входного изображения и, как следствие, числом нейронов на всех последующих слоях (Рис. 1).




Рисунок 1 – Архитектура модели 1.

Модель имеет следующую архитектуру:

1. Свёрточный слой, принимающий на вход изображение 256 на 256 пикселей. Состоит из 6 фильтров размера 5 на 5 элементов с шагом в 1 элемент. После применения данных преобразований получаются 6 матриц размером 252 на 252 элемента.
2. Слой пулинга с размером фильтра 2 на 2 элемента, шагом в 2 элемента, который производит выборку среднего значения. После применения преобразований получается 6 матриц размера 126 на 126 элементов.
3. Свёрточный слой, принимающий на вход 6 матриц размера 126 на 126 элементов. Состоит из 16 фильтров размера 5 на 5 элементов. После применения преобразований получается 16 матриц размера 122 на 122 элемента.
4. Слой пулинга с размером фильтра 2 на 2 элемента, шагом в 2 элемента, который производит выборку среднего значения. После применения преобразований получается 16 матриц размера 61 на 61 элемент.

5. Свёрточный слой, принимающий на вход 16 матриц размера 61 на 61 элемент. Состоит из 120 фильтров размера 5 на 5 элементов. После применения преобразований получается 120 матриц размера 57 на 57 элементов.
6. Полносвязный слой, принимающий на вход $120 \cdot 57 \cdot 57 = 389880$ нейронов, на выходе получается 84 нейрона.
7. Полносвязный слой, принимающий на вход 84 нейрона, на выходе получается 2 нейрона (принадлежность к одному из классов: пневмония и здоровый).

В качестве функции активации используется гиперболический тангенс.

Для всех моделей функцией ошибки выбрана перекрёстная энтропия (cross entropy loss), а обучение проводится алгоритмом AdamW. Графики зависимостей значений функции потерь для обучающей и валидационной выборок от номера эпохи приведены на Рис. 2.




Рисунок 2 – Зависимость значений функции потерь от номера эпохи обучения для модели 1.

Для оценки качества работы моделей, обученных классифицировать рентгеновские изображения лёгких по категориям «здоровый» и «пневмония», на тестовой выборке использованы метрики accuracy, precision, recall и F1-score (F1-мера). По итогам обучения модели 1 на тестовой выборке полученные результаты представлены в таблице 1. Заметим, что обучение проводится с учетом валидации: т.е. сохраняются веса на эпохе, на которой «валидационная» функция потерь (красная линия) имеет минимальное значение. Для модели 1 это соответствует 9 эпохе.

Таблица 1 – Результаты модели 1 на тестовой выборке

Класс/Метрика	Precision	Recall	F1-score	Количество
Здоровый	0.908	0.867	0.887	240
Пневмония	0.951	0.967	0.959	639
Accuracy	93,97%			879

Можно заметить, что для класса «Здоровый» наблюдается низкое значение recall, это обусловлено распределением данных в обучающей выборке. Указанным значениям метрик соответствует матрица ошибок, указанная в таблице 2.

Таблица 2 – Матрица ошибок модели 1 на тестовой выборке

Метка/Предсказание	Здоровый	Пневмония
Здоровый	208	32
Пневмония	21	618

Модель 2

Следующая модель, по сравнению с моделью 1, сможет обнаруживать более глубокие особенности изображений легких, используя дополнительные сверточный и объединяющий (pooling) слои. Фактически к предыдущей модели между 5 и 6 слоями добавляются ещё два слоя.

Зависимость значений функции потерь для обучающей и валидационной выборок от номера эпохи приведено на Рис. 3.




Рисунок 3 – Зависимость значений функции потерь от номера эпохи обучения для модели 2.

По красному графику на Рис. 3 можно видеть, что функция потерь на валидационной выборке для модели 2 немного больше 0.15. Также и обучающая выборка даёт несколько худшие функции потерь на всех эпохах. Результаты обучения модели 2 представлены в таблице 3.

Таблица 3 – Результаты модели 2 на тестовой выборке

Класс/Метрика	Precision	Recall	F1-score	Количество
Здоровый	0.890	0.879	0.885	240
Пневмония	0.955	0.959	0.957	639
Accuracy	93,74%			879

Можно заметить, что для класса «Здоровый» значение recall больше, а для класса «пневмония» меньше. Указанным значениям метрик соответствует матрица ошибок, указанная в таблице Таблица 4.

Таблица 4 – Матрица ошибок модели 2 на тестовой выборке

Метка/Предсказание	Здоровый	Пневмония
Здоровый	211	29
Пневмония	26	613

Модель 3

Данная модель по структуре совпадает с моделью 1, отличаясь лишь уменьшенным размером матриц свёрток (3 на 3 элемента) на всех слоях. Предложенная модель отыскивает признаки меньших размеров в отличие от первых двух моделей за счёт уменьшения размеров сверточной матрицы. Функции потерь для этого случая приведены на Рис. 4.




Рисунок 4 – Зависимость значений функции потерь от номера эпохи обучения для модели 3.

Можно отметить, что разница между функциями потерь обучающийся и валидационной выборками здесь меньше. Скорее всего это обусловлено тем, что признаки при малых свертках для различных изображений отличаются меньше. Результаты метрик для тестовой выборки приведены в таблицах 5 и 6.

Таблица 5 – Результаты модели 3 на тестовой выборке

Класс/Метрика	Precision	Recall	F1-score	Количество
Здоровый	0.914	0.842	0.876	240
Пневмония	0.942	0.970	0.956	639
Accuracy	93,52%			879

Таблица 6 – Матрица ошибок модели 3 на тестовой выборке

Метка/Предсказание	Здоровый	Пневмония
Здоровый	202	38
Пневмония	19	620

Модель 4

Рассмотрим также модель, имеющую большую сверточную матрицу (7 на 7 элемента) на всех слоях. Таким образом можно учесть характерные особенности большего размера.

Зависимость значений функции потерь для обучающей и валидационной выборок от номера эпохи приведено на Рис. 5.




Рисунок 5 – Зависимость значений функции потерь от номера эпохи обучения для модели 4

Начиная с 9-й эпохи модель начинает переобучаться. Оптимальная точность на валидационной выборке достигается 5, 6, 9 эпохах и имеет значения функции потерь немного большие 0.15. Результаты тестирования для модели 4 приведены в таблицах 7 и 8.

Таблица 7 – Результаты модели 4 на тестовой выборке

Класс/Метрика	Precision	Recall	F1-score	Количество
Здоровый	0.927	0.850	0.887	240
Пневмония	0.945	0.975	0.960	639
Accuracy	94,08%			879

Таблица 8 – Матрица ошибок модели 4 на тестовой выборке

Метка/Предсказание	Здоровый	Пневмония
Здоровый	204	36
Пневмония	16	623

Точности на валидационной выборке для рассмотренных четырех моделей практически близки. На тестовой выборке лучший результат показала модель 4 – она определила 623 больных пневмонией из 639, худший – модель 2: определила 613. Для выбора архитектуры ещё двух моделей будем опираться на валидационную выборку. Исходя из меньшей переобучаемости моделей выберем за основу модели с размером сверточных матриц 3 на 3. Также для уменьшения переобучения добавим dropout.

Модель 5

Данная модель похожа на модель 3 и имеет следующие особенности. После 5 шага добавляются пулинг, свёртка и пулинг, перед последним слоем – слой dropout, производящий случайное отключение весов с вероятностью 0.45.

В этой и следующей моделях в качестве функции активации используется ReLU. После каждого свёрточного слоя производится нормализация значений. Архитектура сети также визуализирована на Рис. 6.




Рисунок 6 – Архитектура модели 5.

Зависимость значений функции потерь для обучающей и валидационной выборок от номера эпохи приведено на Рис. 7.




Рисунок 7 – Зависимость значений функции потерь от номера эпохи обучения для модели 5.

Точность валидационной выборки в этой модели выше, чем в предыдущих: значения функций потерь здесь менее 0.1 против 0.15 для предыдущих моделей. Результаты на тестовой выборке для модели 5 приведены в таблицах 9 и 10.

Таблица 9 – Результаты модели 5 на тестовой выборке

Класс/Метрика	Precision	Recall	F1-score	Количество
Здоровый	0.924	0.912	0.918	240
Пневмония	0.967	0.972	0.970	639
Ассугасу	95,56%			879

Таблица 10 – Матрица ошибок модели 5 на тестовой выборке

Метка/Предсказание	Здоровый	Пневмония
Здоровый	219	21
Пневмония	18	621

Модель 6

Данная модель основана на модели 5, но содержит дополнительные dropout (отключение весов с вероятностью 0.45) и полносвязный слой. Функции потерь на валидационной выборке для данной модели также менее 0.1 (Рис. 8).




Рисунок 8 – Зависимость значений функции потерь от номера эпохи обучения для модели 6.

Результаты тестирования модели обобщены в таблицах Таблица 11 и 12.

Таблица 11 – Результаты модели 6 на тестовой выборке

Класс/Метрика	Precision	Recall	F1-score	Количество
Здоровый	0.952	0.904	0.921	240
Пневмония	0.965	0.983	0.974	639
Ассурасу	96,13%			879

Таблица 12 – Матрица ошибок модели 6 на тестовой выборке

Метка/Предсказание	Здоровый	Пневмония
Здоровый	217	23
Пневмония	11	628

Последняя две модели имеет более высокие точности. Однако при принятии решения ансамблями, когда хотя бы одна нейронная сеть нашла заболевание, это не является самым важным критерием. Поэтому далее рассмотрим уже непосредственно сами ансамбли.

3 Классификация ансамблями нейронных сетей

Последняя две модели имеет более высокие точности. Однако при принятии решения ансамблями, когда хотя бы одна нейронная сеть нашла заболевание, это не является самым важным критерием. Поэтому далее рассмотрим уже непосредственно сами ансамбли.

Рассмотрим применение комбинаций нейронных сетей, когда каждая сеть независимо проводит классификацию, а затем происходит принятие решения с учётом всех результирующих классов, полученных отдельными нейронными сетями. Подобные структуры называют ансамблями. Так как в медицинской диагностике существенно важнее не пропустить заболевание, то в случае, если хотя бы одна сеть нашла пневмонию, то будем считать, что заболевание есть. Учитывая, что предложено 6 различных моделей сетей, рассмотрим ансамбли, содержащие от 2 до 6 различных нейронных сетей в своей структуре.

Для каждой модели оптимальное число эпох обучения получилось различным, так как это определяется минимальным значением функции потерь на валидационной выборке. Например, для модели 1 получилось 9 эпох (красная кривая на Рис. 2), а для модели 3 – 17 эпох (Рис. 4). Для шести изображений из тестовой выборки (person275_virus_565, person154_bacteria_728, person1181_bacteria_3129, person1192_bacteria_3141, person432_virus_881, person277_virus_571) всеми моделями класс «пневмония» был распознан неправильно как «Здоровый». Остальные изображения с пневмонией, кроме 27, приведенных в Таблице 13, классифицированы правильно. Буквой «П» обозначен правильный диагноз – пневмония, «-» – ошибочное диагностирование, как здорового. Изображения в таблице упорядочены в порядке возрастания числа нейронных сетей, которые правильно определяют класс «пневмония»: так первые три изображения правильно классифицированы только одной сетью, а следующие 10 – двумя сетями.

Таблица 13 – Таблица предсказанных классов из тестовой выборки различными моделями для «плохо-классифицируемых» изображений

Изображение/Модель	1	2	3	4	5	6
person485_bacteria_2049	-	-	-	-	-	П
person35_bacteria_178	-	-	-	-	-	П
person1461_virus_2510	-	-	-	-	-	П
person472_virus_969	П	-	П	-	-	-
person451_virus_932	-	-	П	-	П	-
person21_virus_53	-	-	-	-	П	П
person1582_bacteria_4137	-	-	-	-	П	П
person109_virus_203	-	-	П	П	-	-
person1497_virus_2607	-	-	П	П	-	-
person1286_virus_2209	-	-	-	-	П	П
person1252_virus_2124	-	-	-	-	П	П
person1230_virus_2081	-	-	-	П	-	П
person1227_virus_2078	-	-	-	-	П	П
person1155_virus_1934	-	-	-	П	П	П
person811_virus_1447	П	-	-	П	-	П
person781_virus_1412	П	П	П	П	-	-
person1174_virus_1980	П	П	П	П	-	-
person1225_virus_2076	П	-	-	П	П	П
person333_bacteria_1539	-	П	П	П	-	П
person317_bacteria_1473	П	П	П	П	-	-
person428_bacteria_1869	-	П	П	П	П	П
person1172_bacteria_3119	П	-	П	П	П	П
person590_bacteria_2428	П	-	П	П	П	П
person733_bacteria_2635	П	П	-	П	П	П
person754_virus_1379	П	П	П	П	-	П
person914_virus_1571	П	-	П	П	П	П
person983_bacteria_2910	П	-	П	П	П	П

Первые три изображения из Таблицы 13 правильно классифицированы только моделью 6. Это может свидетельствовать о том, что ансамбль с моделью 6 будет давать лучшие результаты, чем без неё. Проведем анализ на точность классификации всеми различными комбинациями ансамблей и приведем результаты лучших ансамблей по валидационной выборке. Также для этих ансамблей представим точности и на тестовой выборке. Отметим, что различных вариантов ансамблей всего 57. Результаты по обоим выборкам приведены в Таблице 14.

Таблица 14 – Результаты наилучших ансамблей для классификации пневмонии на валидационной и тестовой выборках

Класс/Метрика	Валидационная выборка		Тестовая выборка	
	Precision	Recall	Precision	Recall
Размер ансамбля = 2 (модели 3+6)				
Здоровый	0.972	0.861	0.970	0.817
Пневмония	0.951	0.991	0.935	0.991
Размер ансамбля = 3 (модели 3+5+6)				
Здоровый	0.976	0.861	0.970	0.812
Пневмония	0.951	0.992	0.934	0.991
Размер ансамбля = 3 (модели 1+4+6)				
Здоровый	0.958	0.861	0.970	0.821
Пневмония	0.950	0.986	0.936	0.991
Размер ансамбля = 4 (модели 2+3+5+6)				
Здоровый	0.976	0.857	0.970	0.796
Пневмония	0.949	0.992	0.928	0.991
Размер ансамбля = 5 (модели 1+2+3+5+6)				
Здоровый	0.976	0.853	0.969	0.792
Пневмония	0.948	0.992	0.927	0.991
Размер ансамбля = 6 (все модели)				
Здоровый	0.976	0.845	0.969	0.787
Пневмония	0.945	0.992	0.925	0.991

Лучшие результаты выделены жирным шрифтом. Для валидационной выборки максимальные точность и полнота достигается при размере ансамбля, равным трём (модели 3+5+6), для тестовой выборки оптимальный ансамбль также состоит из трёх нейросетей (модели 1+4+6). Во все оптимальные ансамбли входит модель 6.

Очевидно, что при добавлении новой модели в ансамбль, метрика precision уменьшается, так как появляются изображения, которые диагностируются добавленной моделью как изображение с пневмонией. Это видно по уменьшению значений precision с увеличением размеров ансамбля.

По результатам классификации на тестовой выборке оптимальным размером ансамблей можно считать 2 и 3. В этих случаях recall = 0.991, а precision варьируется в интервале от 0.934 до 0.936.

Заключение

Проведенный анализ позволяет отметить некоторые недостатки и определенные достоинства нейронных сетей.

Рассмотрено шесть вариантов нейронных сетей типа LeNet-5 с размером входного изображения 256 на 256 пикселей. Нейронные сети отличаются размерами сверточных матриц, что позволяет «обрабатывать» различные размеры особенностей изображений. Также архитектуры сетей имеют разную глубину, а у двух рассмотренных сетей есть dropout на последних полносвязанных слоях. Нейронные сети независимо обучены на одинаковой обучающей выборке, содержащей рентгеновские снимки здоровых пациентов и пациентов с пневмонией. Полученные метрики recall и precision для всех имеют примерно одинаковые значения с recall, изменяющимся в интервале от 0.959 до 0.983. Отметим, что с медицинской точки зрения под термином полнота (recall) понимается чувствительность (sensitivity), что трактуется как чувствительность модели к снимкам с пневмонией.

Рассмотрены ансамбли, содержащие от двух до шести обученных нейросетей в различной комбинации. Результирующий ответ ансамбля строится по принципу, если хотя бы одна из нейросетей определила пневмонию, то ансамбль тоже даёт ответ «пневмония». Такой подход позволил максимально увеличить полноту класса «пневмония», которая при наилучшем выборе нейросетей достигла значения 0.991, что означает 9 пропущенных больных из 1000. Полученное значение для recall превышает значения, достигаемое глубокими сетями [28]. Например, в [29] с помощью Quaternion CNN было получено значение 0.956, в [30] нейросетью VGG-16 – 0.959, а в [31], используя AlexNet, достигнуто значение 0.982.

Дальнейшее улучшение точности определения пневмонии может быть достигнуто за счёт анализа неверно интерпретированных снимков и подбора моделей нейронных сетей, правильно классифицирующих подобные рентгеновские изображения.

Список литературы

1. Balasubramaniam S. A modified LeNet CNN for breast cancer diagnosis in ultrasound images / S. Balasubramaniam, Y. Velmurugan, D. Jaganathan, S. Dhanasekaran. *Diagnostics*. 2023. Vol. 13, No. 17. P. 2746. DOI: 10.3390/diagnostics13172746.
2. Devesh R. Comparative analysis of machine learning algorithms in pneumonia detection / R. Devesh, V. Harsh, A. Mohd, S. Sonal. *Innovative Computing & Communication (ICICC 2024): Proceedings of the International Conference*. 2024. DOI: 10.2139/ssrn.4776487.
3. Demetgul M. Intelligent monitoring of linear stages with ensembles of improved LeNet DCNN and random forest classifiers / M. Demetgul, Y. Zhao, I.N. Tansel, J. Fleischer. *Measurement and Control*. 2025. [In press]. DOI: 10.1177/00202940251317395.
4. Hansen L. K. Neural network ensembles / L. K. Hansen, P. Salamon. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1990. Vol. 12, No. 10. P. 993–1001. DOI: 10.1109/34.58871.
5. Kayumov Z. Convolution neural network learning features for handwritten digit recognition / Z. Kayumov, D. Tumakov. *East-West Design and Test Symposium (EWDTS 2020): Proceedings of the 2020 IEEE*. 2020. P. 330–334. DOI: 10.1109/EWDTS50664.2020.9224822.
6. Kayumov Z. Hierarchical convolutional neural network for handwritten digits recognition / Z. Kayumov, D. Tumakov, S. Mosin. *Procedia Computer Science*. 2020. Vol. 171. P. 1927–1934. DOI: 10.1016/j.procs.2020.04.206.
7. Tiar M. L. Pneumonia Classification using deep learning: a comparative study / M. L. Tiar, N. Terki, J.J. Dominguez-Jimenez. *Image and Signal Processing and their Applications (ISPA): Proceedings of the 8th International Conference*. 2024. P. 1–6. DOI: 10.1109/ISPA59904.2024.10536711.
8. Tuliabaeva D. On the recognition of weakly blurred, highly contrasting objects by neural networks / D. Tuliabaeva, D. Tumakov, A. Egorchev. *AIP Conference Proceedings*. 2024. Vol. 3243. Art. No. 020087. DOI: 10.1063/5.0247350.
9. Verdhan V. Image classification using LeNet / V. Verdhan. *Computer Vision Using Deep Learning: Neural Network Architectures with Python and Keras*. Apress, 2021. 308 p.
10. Yang Y. Pneumonia Recognition by Deep Learning: A Comparative Investigation / Y. Yang, G. Mei. *Applied Sciences*. 2022. Vol. 12, No. 9. P. 4334. DOI: 10.3390/app12094334.
11. Schapire R. E. The strength of weak learnability / R.E. Schapire. *Machine Learning*. 1990. Vol. 5, No. 2. P. 197–227. DOI: 10.1007/BF00116037.
12. Breiman L. Random forests / L. Breiman. *Machine Learning*. 2001. Vol. 45. P. 5–32. DOI: 10.1023/A:1010933404324.
13. Freund Y. A decision-theoretic generalization of on-line learning and an application to boosting / Y. Freund, R.E. Schapire. *Journal of Computer and System Sciences*. 1997. Vol. 55, No. 1. P. 119–139. DOI: 10.1006/jcss.1997.1504.
14. Dehaerne E. Optimizing YOLOv7 for semiconductor defect detection / E. Dehaerne, B. Dey, S. Halder, S. De Gendt. *Proceedings of SPIE*. 2023. Vol. 12496. P. 635–642. DOI: 10.48550/arXiv.2302.09565.
15. Chung A. Cloud computed machine learning based real-time litter detection using micro-UAV surveillance / A. Chung, D.Y. Kim, E. Kwok, M. Ryan, E. Tan, R. Gamadia. *MIT Undergraduate Research Technology Conference (URTC): Proceedings of the IEEE*. 2018. P. 1–4. DOI: 10.1109/URTC45901.2018.9244800.

16. Чернухин А.В. Построение модели предиктивной аналитики неисправностей промышленного оборудования / А.В. Чернухин, Е.А. Богданова, Т.В. Савицкая. *Программные продукты и системы*. 2024. Т. 37, № 2. С. 254–261. DOI: 10.15827/0236-235X.142.254-261.
17. Sasaki K. Lightweight and accurate YOLOv7-based ensembles with knowledge distillation for urinary sediment detection / K. Sasaki, H. Nishikawa, I. Taniguchi, T. Onoye. *IEEE Access*. 2025. Vol. 13. P. 93468–93480. DOI: 10.1109/ACCESS.2025.3574169.
18. Viola P. Robust real-time face detection / P. Viola, M.J. Jones. *International Journal of Computer Vision*. 2004. Vol. 57, No. 2. P. 137–154. DOI: 10.1023/B:VISI.0000013087.49260.fb.
19. Бессарабов Н.А. Автоматизированная разметка изображений с беспилотного летательного аппарата при помощи предобученных моделей искусственного интеллекта / Н.А. Бессарабов, А.А. Сапожников, Д.В. Татарников, Р.П. Тюгунов, А.М. Цыганов. *Программные продукты и системы*. 2025. Т. 38, № 2. С. 251–260. DOI: 10.15827/0236-235X.150.251-260.
20. Nanni L. Ensemble of convolutional neural networks for bioimage classification / L. Nanni, S. Ghidoni, S. Brahnam. *Applied Computing and Informatics*. 2021. Vol. 17, No. 1. P. 19–35. DOI: 10.1016/j.aci.2018.06.002.
21. Balaji S. A context for effective prediction and classification of diabetic retinopathy disease using deep ensemble AlexNet & LeNet classifier / S. Balaji, B. Karthik. *Computing for Sustainable Global Development (INDIACom): Proceedings of the 11th International Conference*. 2024. P. 414–421. DOI: 10.23919/INDIACom61295.2024.10498405.
22. Rajeashwari S. Enhancing pneumonia diagnosis with ensemble-modified classifier and transfer learning in deep-CNN based classification of chest radiographs / S. Rajeashwari, K. Arunesh. *Biomedical Signal Processing and Control*. 2024. Vol. 93. Art. ID 106130. DOI: 10.1016/j.bspc.2024.106130.
23. Zhou T. The ensemble deep learning model for novel COVID-19 on CT images / T. Zhou, H. Lu, Z. Yang, S. Qiu, B. Huo, Y. Dong. *Applied Soft Computing*. 2021. Vol. 98. Art. ID 106885. DOI: 10.1016/j.asoc.2020.106885.
24. Osagie E. Ensemble learning for medical image character recognition based on enhanced LeNet-5 / E. Osagie, W. Ji, N. Helian. *Computational Intelligence in Bioinformatics and Computational Biology (CIBCB): Proceedings of the 2023 IEEE Conference*. 2023. P. 1–8. DOI: 10.1109/CIBCB56990.2023.10264911.
25. Jaganathan D. Concatenated modified LeNet approach for classifying pneumonia images / D. Jaganathan, S. Balsubramaniam, V. Sureshkumar, S. Dhanasekaran. *Journal of Personalized Medicine*. 2024. Vol. 14, No. 3. – Art. ID 328. – DOI: 10.3390/jpm14030328.
26. Meir Y. Efficient shallow learning as an alternative to deep learning / Y. Meir, O. Tevet, Y. Tzach, S. Hodassman, R.D. Gross, I. Kanter // *Scientific Reports*. – 2023. – Vol. 13. – Art. ID 5423. – DOI: 10.1038/s41598-023-32559-8.
27. Пикалёв Я.С. О нейронных архитектурах извлечения признаков для задачи распознавания объектов на устройствах с ограниченной вычислительной мощностью / Я.С. Пикалёв, Т.В. Ермоленко // *Проблемы искусственного интеллекта*. – 2023. – № 3(30). – С. 44–54.
28. Sharma S. A systematic literature review on deep learning approaches for pneumonia detection using chest X-ray images / S. Sharma, K. Guleria // *Multimedia Tools and Applications*. – 2024. – Vol. 83. – P. 24101–24151. – DOI: 10.1007/s11042-023-16419-1.
29. Singh S. Pneumonia classification using quaternion deep learning / S. Singh, B.K. Tripathi // *Multimedia Tools and Applications*. – 2022. – Vol. 81. – P. 1743–1764. – DOI: 10.1007/s11042-021-11409-7.
30. Hasan M.D.K. Deep learning approaches for detecting pneumonia in COVID-19 patients by analyzing chest X-Ray images / M.D.K. Hasan [и др.] // *Mathematical Problems in Engineering*. – 2021. – Art. ID 9929274. – 8 p. – DOI: 10.1155/2021/9929274.
31. Ibrahim A.U. Pneumonia classification using deep learning from chest X-ray images during COVID-19 / A.U. Ibrahim, M. Ozsoz, S. Serte, F. Al-Turjman, P.S. Yakoi // *Cognitive Computation*. – 2024. – Vol. 16. – P. 1589–1601. – DOI: 10.1007/s12559-020-09787-5.

References

1. Balasubramaniam S. A modified LeNet CNN for breast cancer diagnosis in ultrasound images / S. Balasubramaniam, Y. Velmurugan, D. Jaganathan, S. Dhanasekaran // *Diagnostics*. – 2023. – Vol. 13, No. 17. – P. 2746. – DOI: 10.3390/diagnostics13172746.
2. Devesh R. Comparative analysis of machine learning algorithms in pneumonia detection / R. Devesh, V. Harsh, A. Mohd, S. Sonal // *Innovative Computing & Communication (ICICC 2024): Proceedings of the International Conference*. – 2024. – DOI: 10.2139/ssrn.4776487.

3. Demetgul M. Intelligent monitoring of linear stages with ensembles of improved LeNet DCNN and random forest classifiers / M. Demetgul, Y. Zhao, I.N. Tansel, J. Fleischer // *Measurement and Control*. – 2025. – [In press]. – DOI: 10.1177/00202940251317395.
4. Hansen L. K. Neural network ensembles / L. K. Hansen, P. Salamon // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 1990. – Vol. 12, No. 10. – P. 993–1001. – DOI: 10.1109/34.58871.
5. Kayumov Z. Convolution neural network learning features for handwritten digit recognition / Z. Kayumov, D. Tumakov // *East-West Design and Test Symposium (EWDTS 2020): Proceedings of the 2020 IEEE*. – 2020. – P. 330–334. – DOI: 10.1109/EWDTS50664.2020.9224822.
6. Kayumov Z. Hierarchical convolutional neural network for handwritten digits recognition / Z. Kayumov, D. Tumakov, S. Mosin // *Procedia Computer Science*. – 2020. – Vol. 171. – P. 1927–1934. – DOI: 10.1016/j.procs.2020.04.206.
7. Tiar M. L. Pneumonia Classification using deep learning: a comparative study / M. L. Tiar, N. Terki, J.J. Dominguez-Jimenez // *Image and Signal Processing and their Applications (ISPA): Proceedings of the 8th International Conference*. – 2024. – P. 1–6. – DOI: 10.1109/ISPA59904.2024.10536711.
8. Tuliabaeva D. On the recognition of weakly blurred, highly contrasting objects by neural networks / D. Tuliabaeva, D. Tumakov, A. Egorchev // *AIP Conference Proceedings*. – 2024. – Vol. 3243. – Art. No. 020087. – DOI: 10.1063/5.0247350.
9. Verdhan V. Image classification using LeNet / V. Verdhan // *Computer Vision Using Deep Learning: Neural Network Architectures with Python and Keras*. – Apress, 2021. – 308 p.
10. Yang Y. Pneumonia Recognition by Deep Learning: A Comparative Investigation / Y. Yang, G. Mei // *Applied Sciences*. – 2022. – Vol. 12, No. 9. – P. 4334. – DOI: 10.3390/app12094334.
11. Schapire R. E. The strength of weak learnability / R.E. Schapire // *Machine Learning*. – 1990. – Vol. 5, No. 2. – P. 197–227. – DOI: 10.1007/BF00116037.
12. Breiman L. Random forests / L. Breiman // *Machine Learning*. – 2001. – Vol. 45. – P. 5–32. – DOI: 10.1023/A:1010933404324.
13. Freund Y. A decision-theoretic generalization of on-line learning and an application to boosting / Y. Freund, R.E. Schapire // *Journal of Computer and System Sciences*. – 1997. – Vol. 55, No. 1. – P. 119–139. – DOI: 10.1006/jcss.1997.1504.
14. Dehaerne E. Optimizing YOLOv7 for semiconductor defect detection / E. Dehaerne, B. Dey, S. Halder, S. De Gendt // *Proceedings of SPIE*. – 2023. – Vol. 12496. – P. 635–642. – DOI: 10.48550/arXiv.2302.09565.
15. Chung A. Cloud computed machine learning based real-time litter detection using micro-UAV surveillance / A. Chung, D.Y. Kim, E. Kwok, M. Ryan, E. Tan, R. Gamadia // *MIT Undergraduate Research Technology Conference (URTC): Proceedings of the IEEE*. – 2018. – P. 1–4. – DOI: 10.1109/URTC45901.2018.9244800.
16. Chernukhin A.V. Postroyeniye modeli prediktivnoy analitiki neispravnostey promyshlennogo oborudovaniya / A.V. Chernukhin, E.A. Bogdanova, T.V. Savitskaya // *Programmnyye produkty i sistemy*. – 2024. – T. 37. № 2. – S. 254–261. – DOI: 10.15827/0236-235X.142.254-261.
17. Sasaki K. Lightweight and accurate YOLOv7-based ensembles with knowledge distillation for urinary sediment detection / K. Sasaki, H. Nishikawa, I. Taniguchi, T. Onoye // *IEEE Access*. – 2025. – Vol. 13. – P. 93468–93480. – DOI: 10.1109/ACCESS.2025.3574169.
18. Viola P. Robust real-time face detection / P. Viola, M.J. Jones // *International Journal of Computer Vision*. – 2004. – Vol. 57, No. 2. – P. 137–154. – DOI: 10.1023/B:VISI.0000013087.49260.fb.
19. Bessarabov N.A. Avtomatizirovannaya razmetka izobrazheniy s bespilotnogo letatel'nogo apparata pri pomoshchi predobuchennykh modeley iskusstvennogo intellekta / N.A. Bessarabov, A.A. Sapozhnikov, D.V. Tatarnikov, R.R. Tyugunov, A.M. Tsyganov // *Programmnyye produkty i sistemy*. – 2025. – T. 38. № 2. – S. 251–260. – DOI: 10.15827/0236-235X.150.251-260.
20. Nanni L. Ensemble of convolutional neural networks for bioimage classification / L. Nanni, S. Ghidoni, S. Brahnam // *Applied Computing and Informatics*. – 2021. – Vol. 17, No. 1. – P. 19–35. – DOI: 10.1016/j.aci.2018.06.002.
21. Balaji S. A context for effective prediction and classification of diabetic retinopathy disease using deep ensemble AlexNet & LeNet classifier / S. Balaji, B. Karthik // *Computing for Sustainable Global Development (INDIACom): Proceedings of the 11th International Conference*. – 2024. – P. 414–421. – DOI: 10.23919/INDIACom61295.2024.10498405.
22. Rajeashwari S. Enhancing pneumonia diagnosis with ensemble-modified classifier and transfer learning in deep-CNN based classification of chest radiographs / S. Rajeashwari, K. Arunesh // *Biomedical Signal Processing and Control*. – 2024. – Vol. 93. – Art. ID 106130. – DOI: 10.1016/j.bspc.2024.106130.

23. Zhou T. The ensemble deep learning model for novel COVID-19 on CT images / T. Zhou, H. Lu, Z. Yang, S. Qiu, B. Huo, Y. Dong. *Applied Soft Computing*. 2021. Vol. 98. Art. ID 106885. DOI: 10.1016/j.asoc.2020.106885.
24. Osagie E. Ensemble learning for medical image character recognition based on enhanced LeNet-5 / E. Osagie, W. Ji, N. Helian. *Computational Intelligence in Bioinformatics and Computational Biology (CIBCB): Proceedings of the 2023 IEEE Conference*. 2023. P. 1–8. DOI: 10.1109/CIBCB56990.2023.10264911.
25. Jaganathan D. Concatenated modified LeNet approach for classifying pneumonia images / D. Jaganathan, S. Balsubramaniam, V. Sureshkumar, S. Dhanasekaran. *Journal of Personalized Medicine*. 2024. Vol. 14, No. 3. Art. ID 328. DOI: 10.3390/jpm14030328.
26. Meir Y. Efficient shallow learning as an alternative to deep learning / Y. Meir, O. Tevet, Y. Tzach, S. Hodassman, R.D. Gross, I. Kanter. *Scientific Reports*. 2023. Vol. 13. Art. ID 5423. DOI: 10.1038/s41598-023-32559-8.
27. Pikalev Ya.S. O neyronnykh arkhitekturakh izvlecheniya priznakov dlya zadachi raspoznavaniya obyektov na ustroystvakh s ogranichennoy vychislitelnoy moshchnostyu / Ya.S. Pikalev. T.V. Ermolenko *Problemy iskusstvennogo intellekta*. 2023. № 3(30). S. 44–54.
28. Sharma S. A systematic literature review on deep learning approaches for pneumonia detection using chest X-ray images / S. Sharma, K. Guleria. *Multimedia Tools and Applications*. 2024. Vol. 83. P. 24101–24151. DOI: 10.1007/s11042-023-16419-1.
29. Singh S. Pneumonia classification using quaternion deep learning / S. Singh, B.K. Tripathi. *Multimedia Tools and Applications*. 2022. Vol. 81. P. 1743–1764. DOI: 10.1007/s11042-021-11409-7.
30. Hasan M.D.K. Deep learning approaches for detecting pneumonia in COVID-19 patients by analyzing chest X-Ray images / M.D.K. Hasan [и др.] *Mathematical Problems in Engineering*. 2021. Art. ID 9929274. 8 p. DOI: 10.1155/2021/9929274.
31. Ibrahim A.U. Pneumonia classification using deep learning from chest X-ray images during COVID-19 / A.U. Ibrahim, M. Ozsoz, S. Serte, F. Al-Turjman, P.S. Yakoi. *Cognitive Computation*. 2024. Vol. 16. – P. 1589–1601. DOI: 10.1007/s12559-020-09787-5.

RESUME

D. N. Tumakov, A. R. Berdigulov, D. I. Khairullina, I. I. Bariev

Application of lenet-5-type neural network ensembles for diagnosing pneumonia in lung x-ray images

Background: Numerous studies are devoted to identifying various diseases from X-ray images. The neural networks used in these studies are deep, which leads to significant resource consumption for the algorithms implemented using such approaches. In a number of fields, ensembles of neural networks using bagging and boosting are used for classification tasks. Almost all studies emphasize computational accuracy rather than the completeness of disease identification.

Materials and methods: X-ray lung images were analyzed. The open Ped-Pneumonia dataset, containing 5,856 X-ray images in JPEG format and two classes (pneumonia – 4,273 images; normal – 1,583 images), was used. Pneumonia classification was performed using ensembles with varying numbers of shallow neural networks. The ensemble response selection criterion is based on the principle that if at least one neural network detects pneumonia, the ensemble also detects pneumonia. This maximizes recall.

Results: The optimal number of neural networks in the ensembles is 2 and 3. The maximum completeness of the "pneumonia" class for the best set of neural networks reached a value of 0.991.

Conclusion: The effective set of neural networks for use in the algorithm is proposed. Further improvement in pneumonia detection accuracy can be achieved by analyzing misinterpreted images and selecting neural network models that correctly classify such X-ray images.

РЕЗЮМЕ

Д. Н. Тумаков, А. Р. Бердигулов, Д. И. Хайруллина, И. И. Бариев
Применение ансамблей нейронных сетей типа LeNet-5 для
диагностирования пневмонии на рентгеновских изображениях легких

История вопроса, исходные данные: Большое количество работ посвящено определению различных заболеваний по рентгеновским снимкам. Нейронные сети, используемые в этих работ, являются глубокими. Это приводит к большим затратам ресурсов, которые необходимы для алгоритмов, реализуемых с помощью таких подходов. В ряде областей для задач классификации используются ансамбли нейронных сетей с использованием бэггинга и бустинга. Почти во всех работах ставка делается на точность вычислений, а не на полноту определения заболевания.

Материалы и методы: Исследованы рентгеновские изображения лёгких. Использован открытый датасет Ped-Pneumonia, содержащий 5856 рентгеновских снимков в формате JPEG и два класса: (пневмония – 4273 снимка и норма – 1583 снимка).

Классификация пневмонии проведена ансамблями с различным количеством неглубоких нейронных сетей. Условие выбора ответа ансамбля построено по принципу, если хотя бы одна из нейросетей определила пневмонию, то ансамбль тоже определяет пневмонию. Это позволяет максимально увеличить полноту.

Результаты: Оптимальное число нейронных сетей в ансамблях равняется 2 и 3. Максимальная полнота класса «пневмония», для лучшего набора нейросетей достигла значения 0.991.

Заключение: Предложен эффективный набор нейронных сетей для использования в составе алгоритма. Дальнейшее улучшение точности определения пневмонии может быть достигнуто за счёт анализа неверно интерпретированных снимков и подбора моделей нейронных сетей, правильно классифицирующих подобные рентгеновские изображения.

Тумаков Д. Н. – к.ф.-м.н., заместитель директора института вычислительной математики и информационных технологий по научной деятельности, ФГБОУ ВО К(П)ФУ, кафедра прикладной математики и искусственного интеллекта, 420008, Казань, ул. Кремлевская, 18, тел +7(965) 586-79-97, dtumakov@kpfu.ru. *Область научных интересов:* нейронные сети, машинное зрение, обработка изображений, искусственный интеллект, проектирование антенных устройств.

Бердигулов А. Р. – магистрант института вычислительной математики и информационных технологий, ФГБОУ ВО К(П)ФУ, кафедра прикладной математики и искусственного интеллекта, 420008, Казань, ул. Кремлевская, 18, тел +7(937) 527-78-44, berdigulov.airat@mail.ru. *Область научных интересов:* нейронные сети, машинное зрение, искусственный интеллект в медицине.

Хайруллина Д. И. – магистрант института вычислительной математики и информационных технологий, ФГБОУ ВО К(П)ФУ, кафедра прикладной математики и искусственного интеллекта, 420008, Казань, ул. Кремлевская, 18, тел +7(927) 402-96-11, dina07.khayrullina.99@mail.ru. *Область научных интересов:* нейронные сети, машинное зрение, кластеризация.

Бариев И. И. – директор, АНО ВО «Университет Иннополис», 420500, Иннополис, ул. Университетская, 1, тел +7 (843) 203-92-53, i.bariev@innopolis.ru. *Область научных интересов:* нейронные сети, искусственный интеллект в медицине.

Статья поступила в редакцию 17.07.2025.