

Разработка методики автоматизации медицинского скрининга работников предприятий с элементами поддержки принятия решений

С.А. Сорокина, О.Н. Кузяков

Тюменский индустриальный университет, Тюмень

Аннотация: В статье предлагается новая методика для автоматизации скрининга лучевой диагностики работников предприятий с использованием элементов поддержки принятия врачебных решений, в частности U-образной архитектуры сверточной нейронной сети с двойным механизмом внимания. Особенностью архитектуры является использование механизма внимания на основе блоков «сжатия и возбуждения», позволяющего повысить качество и точность анализа цифровых медицинских данных с учетом особенностей изображений компьютерной томографии.

Ключевые слова: машинное обучение, сверточная нейронная сеть, компьютерная томография, архитектура, хроническая обструктивная болезнь лёгких.

Введение

Своевременная и точная диагностика профессиональных заболеваний в существующих условиях охраны труда и здоровья работников предприятий приобрела особую значимость. В соответствии с требованиями Трудового кодекса РФ и приказом Министерства здравоохранения от 28.01.2021 N 29н, работодатели обязаны обеспечивать безопасные условия труда и проводить регулярные медицинские осмотры [1]. Одним из наиболее распространенных профессиональных заболеваний является хроническая обструктивная болезнь легких (ХОБЛ) [2]. Для скрининга патологических изменений при ХОБЛ применяется компьютерная томография (КТ) грудной клетки с низкой дозой излучения [3]. Традиционная методика анализа КТ-изображений, включающая визуальную оценку врачом-рентгенологом, может занимать до 36 минут на одно исследование [4]. Это приводит к снижению эффективности, скорости и точности диагностики, особенно при высокой нагрузке на медицинский персонал. В связи с этим возрастаёт необходимость во внедрении автоматизированных методов обработки и анализа КТ-изображений в медицинскую практику [5]. С целью решения данной проблемы была разработана новая методика лучевой диагностики патологий

легких, которая включила следующие этапы: проведение КТ грудной клетки, предобработку медицинских изображений, анализ с применением сверточной нейронной сети (Convolutional Neural Network – CNN) и интерпретацию результатов врачом-рентгенологом. По результатам исследования была разработана функциональная схема последовательности действий для новой методики лучевой диагностики патологий легких, которая представлена на рис.1.

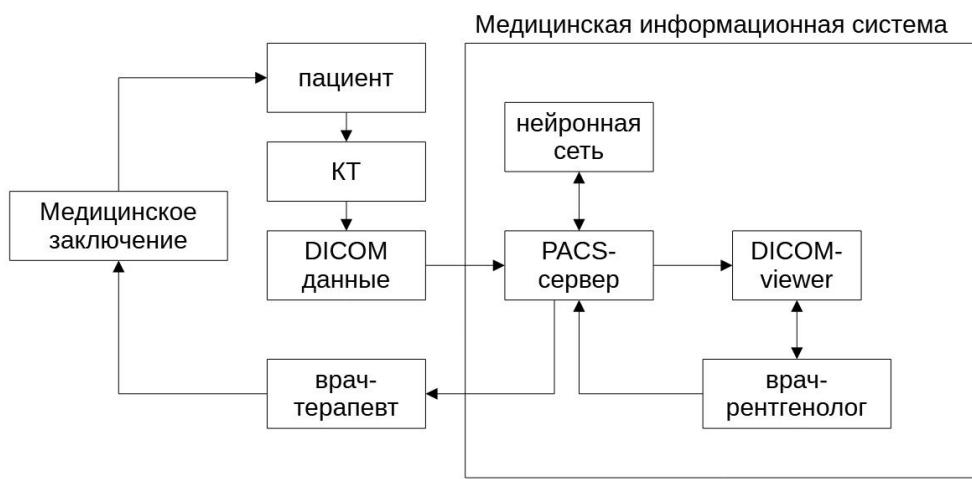


Рис. 1. – Функциональная схема автоматизированного процесса лучевой диагностики

На первом этапе, по результатам КТ-исследования, серия аксиальных изображений грудной клетки пациента преобразуется в данные формата визуализации и передачи медицинских изображений (Digital Imaging and Communications in Medicine – DICOM), которые импортируются на сервер архивирования изображений и связи (Picture Archiving and Communication System – PACS) [6], откуда, после предварительной обработки, поступают на вход CNN. Результат анализа КТ-изображения передается обратно на сервер PACS. Доступ к серверу предоставляется посредством сетевой архитектуры «клиент-сервер» с автоматизированного рабочего места медицинского

специалиста. Врач-рентгенолог получает доступ как к результатам анализа CNN, так и к исходному КТ-изображению, которое можно открыть с помощью специализированного программного обеспечения для просмотра DICOM-данных (DICOM-viewer). На основании полученной информации врач-рентгенолог может оценить точность и корректность работы CNN, а также составить протокол исследования, который будет направлен к врачу-терапевту для дальнейшей диагностики.

Для выполнения автоматизированного анализа КТ-изображений была предложена новая архитектура нейронной сети на основе преобразованной архитектуры CNN, имеющей U-образную форму (U-net). Выбор использования архитектуры U-net был обоснован тем, что CNN данного типа позволяет эффективно решать задачи классификации, обнаружения и сегментации патологий на КТ-изображениях, когда набор данных для тренировки разрабатываемой модели ограничен [7], что особенно актуально из-за специфики медицинских данных. Интеграция механизмов двойного внимания или блоков «сжатия и возбуждения» (Squeeze-and-Excitation Blocks – SE-блоков) позволяет сети динамически перераспределять веса каналов нейронной сети [8], что улучшает способность CNN фокусироваться на наиболее значимых признаках патологии. В данном исследовании для улучшения CNN с использованием SE-блоков была преобразована кодирующая часть архитектуры U-Net. В каждый блок свертки был добавлен SE-блок после второго сверточного слоя. Также были использованы слои типа «узкое место» посредством замены стандартных сверточных слоев, что позволило сохранить информацию о признаках без значительного увеличения затрат на вычисления. В декодирующую часть архитектуры U-net были использованы остаточные блоки с целью уменьшения переобучения сети. После чего была разработана структура новой модели CNN, которая представлена на рис. 2.

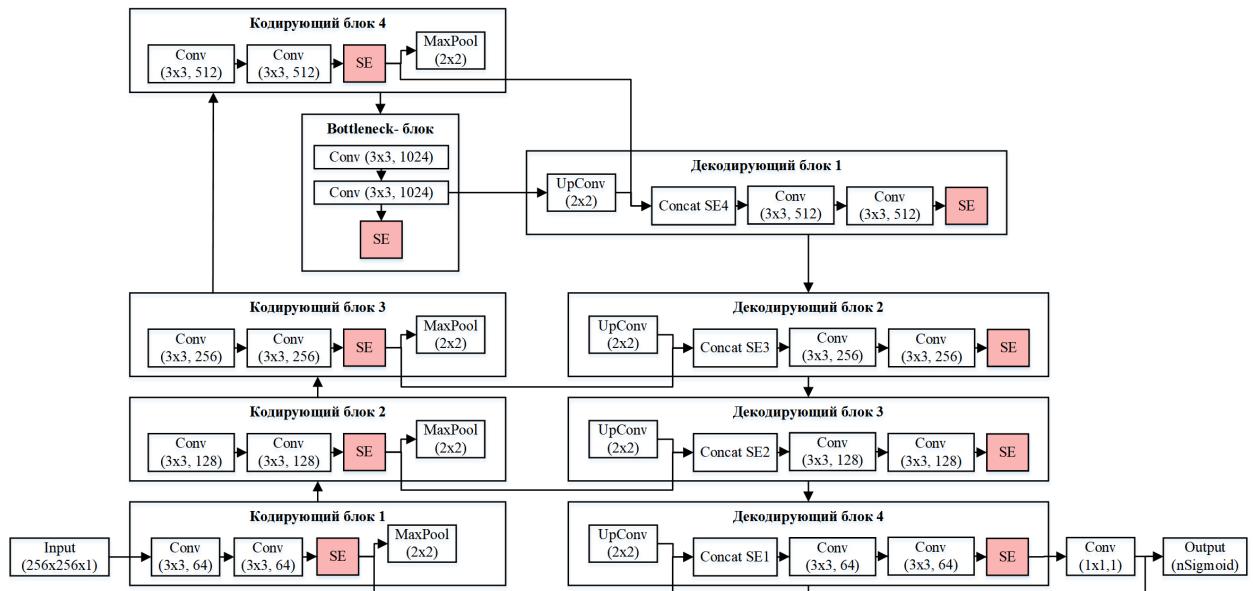


Рис. 2. – Параметры слоев CNN архитектуры U-net с применением SE-блоков

Использование двойного механизма внимания в новой архитектуре CNN U-net, позволило объединить и использовать при анализе как глубокие, так и поверхностные признаки КТ-изображения (рис.3).

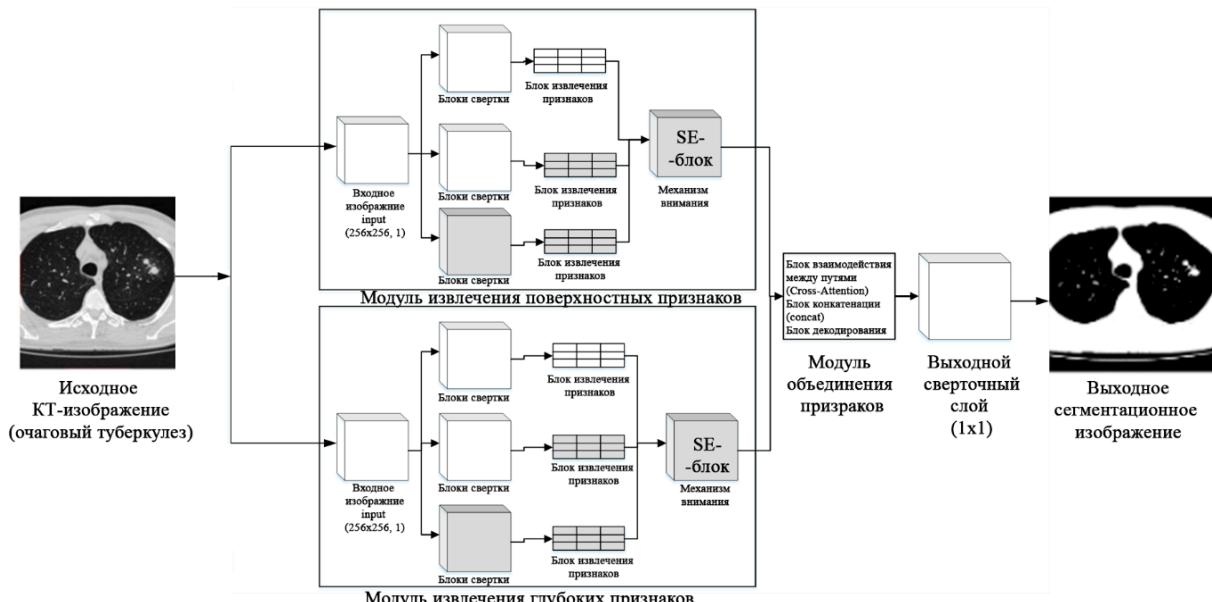


Рис. 3. – Архитектура U-net с применением двойного механизма внимания

Это было достигнуто путем реализации двух параллельных каналов внимания. Первый канал был направлен на выявление глубоких признаков, а второй обрабатывал поверхностные признаки КТ-изображения. Обеспечение дифференцированного взаимодействия между этими двумя каналами позволило учитывать их взаимное влияние друг на друга и компенсировать это. Глубокие признаки выступали в качестве ключевого источника информации о сложных морфологических структурах КТ-изображения, в то время как поверхностные признаки способствовали выделению и сохранению общих характеристик медицинского изображения, которые в противном случае могли быть упущены в процессе автоматизированного анализа. В результате программной реализации и тестирования была получена сравнительная характеристика по метрикам точности между базовой и преобразованной архитектурой U-Net (таблица 1).

Таблица № 1

Сравнительная характеристика по метрикам точности между базовой архитектурой U-Net и преобразованной архитектурой U-Net с SE-блоками

Метрика (показатель)	Набор данных «ChestX-ray8»		Набор данных «Montgomery»		Набор данных «Shenzhen»	
	U-Net	U-Net + SE блоки	U-Net	U-Net + SE блоки	U-Net	U-Net + SE блоки
Доля правильных ответов	0.85	0.90	0.82	0.87	0.84	0.89
Чувствительность	0.80	0.88	0.78	0.85	0.81	0.87
Специфичность	0.88	0.92	0.85	0.90	0.86	0.91
F1-мера	0.84	0.90	0.81	0.88	0.83	0.89

В качестве основных наборов данных для обучения, тестирования и валидации новой модели CNN были использованы: набор «ChestX-ray8», содержащий аннотированные КТ-изображения грудной клетки фронтальной

проекции ряда распространённых лёгочных патологий, включая ХОБЛ, набор данных «Montgomery County X-ray Set» и набор данных «Shenzhen Hospital X-ray Set», содержащие КТ-изображения легких, на которых определялись рентгенологические признаки ХОБЛ туберкулезного типа: очаги уплотнения тканей (инфильтраты) и гиперинфляция легких [9].

Для оценки производительности и точности представленных архитектур сети был использован ряд следующих метрик: доля правильных ответов, чувствительность, специфичность, F1-мера [10]. При анализе наборов данных архитектура U-Net с SE-блоками продемонстрировала более высокую долю правильных ответов по сравнению с базовой архитектурой U-Net на 5-7%. Это указывает на то, что SE-блоки способствуют более эффективной фокусировке на значимых признаках патологии и улучшают общую точность классификации. Показатели чувствительности и специфичности также увеличиваются при использовании SE-блоков на 4-8%, что указывает на улучшение способности сети правильно классифицировать отрицательные случаи. Полученные результаты по показателю «F1-меры» указывают на более сбалансированную производительность преобразованной архитектуры U-Net на 6-7%.

Заключение

Таким образом, использование SE-блоков в архитектуре U-Net представляется целесообразным для улучшения качества анализа медицинских изображений при диагностике ХОБЛ. Новая методика с использованием архитектуры CNN U-Net на основе двойного механизма позволила осуществить дифференциальное взаимодействие признаков через изучение различий между ключевыми характеристиками патологий, что делает разработанную архитектуру более универсальной и применимой к ряду других задач в лучевой диагностике.

Литература

1. Кукушкин Д. В., Пузанкова Н. В. Структура хронической профессиональной заболеваемости бронхолегочной системы // Вестник науки. 2025. №3. С. 580-586.
2. Бабанов С.А., Вострокнутова М.Ю., Васина И.Н., Бабанов А.С., Артемьева М.С. Профессиональная хроническая обструктивная болезнь легких и коморбидность: вопросы диагностики, прогностические критерии // Новые Санкт-Петербургские врачебные ведомости. 2025. №2. С. 39-47.
3. Филиппенко Е. В. Жолдыбай Ж. Ж., Жакенова Ж. К., Захырова Х. Роль компьютерной томографии в диагностике ХОБЛ (обзор литературы) // Вестник КазНМУ. 2018. №1. С. 22-26.
4. Шутова А.А. Искусственный интеллект в системе здравоохранения: пределы уголовной ответственности врачей // Правоприменение. 2025. №3. С. 144-153.
5. Тимохин М.Ю., Шаранин В.Ю. Искусственный интеллект и теория принятия решений: современные тенденции // Инженерный вестник Дона, 2023, № 10. URL: ivdon.ru/ru/magazine/archive/n10y2023/8746.
6. Скворцова И.В., Нурулин Ю.Р., Сомов А.Г. Исследование влияния искусственного интеллекта на качество и скорость принятия решений // Инженерный вестник Дона, 2025. №10. URL: ivdon.ru/ru/magazine/archive/n10y2025/10417.
7. Kuzyakov O. N., Sorokina S. A., Shutova E. A. Development of an Automated Diagnostic System of Lung Pathologies in Lymphoma // 2023 International Russian Smart Industry Conference. 2023. pp. 55-59.
8. Gong L, Jiang S, Yang Z, Zhang G, Wang L. Automated pulmonary nodule detection in CT images using 3D deep squeeze-and-excitation networks // Int J CARS 14. vol. 14. №11. 2019. pp. 1969-1979.

9. Nijiati P, Abudoubari S, Zimin Y, Tuersun A. Development and application of a deep learning-based tuberculosis diagnostic assistance system in remote areas of Northwest China // Sci Rep. vol. 15 №38192. 2025. pp. 1-9.
10. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. vol. 521. № 7553. 2015. pp. 436-44.

References

1. Kukushkin D. V., Puzankova N. V. Vestnik nauki. 2025. №3. Pp. 580-586.
2. Babanov S.A., Vostroknutova M.Yu., Vasina I.N., Babanov A.S., Artem'eva M.S. Novye Sankt-Peterburgskie vrachebnye vedomosti. 2025. №2. Pp. 39-47.
3. Filippenko E. V. Zholdybay Zh. Zh., Zhakenova Zh. K., Zakhryrova Kh. Vestnik KazNNU. 2018. №1. Pp. 22-26.
4. Shutova A.A. Pravoprimenenie. 2025. №3. Pp. 144-153.
5. Timokhin M.Yu., Sharanin V.Yu. Inzhenernyj vestnik Dona, 2023, № 10. URL: ivdon.ru/ru/magazine/archive/n10y2023/8746.
6. Skvortsova I.V., Nurulin Yu.R., Somov A.G. Inzhenernyj vestnik Dona, 2025. №10. URL: ivdon.ru/ru/magazine/archive/n10y2025/10417.
7. Kuzyakov O. N., Sorokina S. A., Shutova E. A. 2023 International Russian Smart Industry Conference. 2023. Pp. 55-59.
8. Gong L, Jiang S, Yang Z, Zhang G, Wang L. Int J CARS 14. vol. 14. №11. 2019. Pp. 1969-1979.
9. Nijiati P, Abudoubari S, Zimin Y, Tuersun A. Sci Rep. vol. 15 №38192. 2025. Pp. 1-9.
10. LeCun Y., Bengio Y., Hinton G. Nature. vol. 521. № 7553. 2015. Pp. 436-44.

Дата поступления: 4.11.2025

Дата публикации: 27.12.2025