



<http://dx.doi.org/10.35596/1729-7648-2025-31-4-55-64>

УДК 004.932.2

ПРИМЕНЕНИЕ КОМПЬЮТЕРНОГО ЗРЕНИЯ ДЛЯ АВТОМАТИЗИРОВАННОЙ ОБРАБОТКИ МЕДИЦИНСКИХ ДОКУМЕНТОВ

Е. А. КУРЛЮК¹, Н. А. ЛАРЧЕНКО¹, М. В. ДАВЫДОВ¹, Е. К. КУРЛЯНСКАЯ²

¹Белорусский государственный университет информатики и радиоэлектроники
(Минск, Республика Беларусь)

²Республиканский научно-практический центр «Кардиология» (Минск, Республика Беларусь)

Аннотация. Рассмотрена задача автоматизации обработки медицинских изображений при диагностике артериальной гипертензии с применением методов искусственного интеллекта и технологий компьютерного зрения. Разработан программный компонент, обеспечивающий автоматическое извлечение и структурирование информации из визуальных представлений медицинских документов (включая результаты биохимического анализа, общего анализа крови и данных суточного мониторинга артериального давления), что позволяет минимизировать количество ошибок и ускорить процессы ввода и интерпретации медицинской информации. Созданы и апробованы алгоритмы предобработки изображений (увеличение разрешения, устранение шумов, коррекция наклона), сегментации и распознавания текстовых данных с помощью нейросетевых моделей Real-ESRGAN и EasyOCR. Особое внимание уделено улучшению качества распознавания текста при наличии характерных артефактов, возникающих при сканировании или фотографировании документов. Для оценки качества использовались метрики CER, WER, исследовалась эффективность работы модуля с применением суперразрешения и без него. Результаты исследования подтвердили эффективность предлагаемого подхода и показали, что интеграция технологии Real-ESRGAN позволяет повысить точность обработки медицинских изображений в условиях наличия значительных шумов и низкого разрешения исходных данных. Практическая значимость исследования заключается в упрощении и ускорении процесса диагностики гипертонии и создании основы для персонализированного подхода к лечению пациентов.

Ключевые слова: гипертония, машинное обучение, компьютерное зрение, оптическое распознавание текста, увеличение разрешения изображения, обработка медицинских данных, предобработка изображений.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Для цитирования. Применение компьютерного зрения для автоматизированной обработки медицинских документов / Е. А. Курлюк [и др.] // Цифровая трансформация. 2025. Т. 31, № 4. С. 55–64. <http://dx.doi.org/10.35596/1729-7648-2025-31-4-55-64>.

APPLICATION OF COMPUTER VISION FOR AUTOMATED PROCESSING OF MEDICAL DOCUMENTS

YAUHENI A. KURLIUK¹, NIKITA A. LARCHENKO¹, MAKSIM V. DAVYDOV¹,
ELENA K. KURLYANSKAYA²

¹Belarusian State University of Informatics and Radioelectronics (Minsk, Republic of Belarus)

²Scientific and Practical Centre "Cardiology" (Minsk, Republic of Belarus)

Abstract. This paper examines the automation of medical image processing for diagnosing arterial hypertension using artificial intelligence and computer vision technologies. A software component has been developed that automatically extracts and structures information from visual representations of medical documents (including biochemical analysis results, complete blood counts, and 24-hour blood pressure monitoring data), minimizing errors and accelerating the process of entering and interpreting medical information. Algorithms for image preprocessing (increasing image resolution, noise removal, and tilt correction), segmentation, and text recognition were

developed and tested using the Real-ESRGAN and EasyOCR neural network models. Particular attention was paid to improving text recognition quality in the presence of characteristic artifacts that arise when scanning or photographing documents. CER and WER metrics were used to evaluate quality, and the module's performance was assessed with and without superresolution. The results of the study confirmed the effectiveness of the proposed approach and demonstrated that the integration of Real-ESRGAN technology improves the accuracy of medical image processing in the presence of significant noise and low-resolution source data. The practical significance of the study lies in simplifying and accelerating the process of diagnosing hypertension and creating the basis for a personalized approach to patient treatment.

Keywords: hypertension, machine learning, computer vision, optical character recognition, image super-resolution, medical data processing, image preprocessing.

Conflict of interests. The authors declare that there is no conflict of interests.

For citation. Kurliuk Y. A., Larchenko N. A., Davydov M. V., Kurlyanskaya E. K. (2025) Application of Computer Vision for Automated Processing of Medical Documents. *Digital Transformation*. 31 (4), 55–64. <http://dx.doi.org/10.35596/1729-7648-2025-31-4-55-64> (in Russian).

Введение

Распространенность гипертонии в европейских странах составляет около 30–45 % от общей численности населения, причем этот показатель резко увеличивается с возрастом [1]. Гипертония рассматривается как наиболее значимый предиктор сердечно-сосудистой заболеваемости и смертности, превосходящий по степени влияния такие факторы, как ожирение, дислипидемия, повышенная воспалительная активность и гиперкоагуляция [2].

Ранняя диагностика гипертонической болезни остается одной из наиболее актуальных задач современной кардиологии. На начальных стадиях заболевание часто не сопровождается клиническими проявлениями, что приводит к позднему выявлению патологии. Отсутствие единых подходов к диагностике гипертонии создает разногласия среди специалистов и затрудняет своевременное выявление патологии [3].

На современном этапе развития кардиологии наблюдается активная интеграция методов искусственного интеллекта (ИИ), направленных на автоматизацию процессов анализа клинических данных [4]. Применение алгоритмов машинного обучения и компьютерного зрения обеспечивает принципиально новый подход к интерпретации медицинских изображений, снижая временные и когнитивные издержки при обработке информации и минимизируя влияние субъективных факторов [5]. Кроме того, использование компьютерного зрения в связке с большими массивами данных открывает возможности для формирования индивидуализированных терапевтических стратегий у пациентов с сердечно-сосудистыми заболеваниями [6].

При лечении пациентов с гипертонией ИИ использовался для прогнозирования частоты возникновения гипертонии в будущем у населения [7]. Применяя машинное обучение на данных более 18 000 пациентов, удалось разработать достаточно чувствительный алгоритм для предсказания начальной стадии гипертонии, превосходящий по точности стандартную логистическую регрессию и достигающий AUC почти 0,99 [8]. Также анализ медицинских карт с использованием машинного обучения позволил разработать точную прогностическую модель, определяющую вторичную гипертонию. Этот инструмент на основе ИИ способен упростить клиническую диагностику и процесс принятия решений при лечении гипертонии [9].

Наибольшую сложность при ручном вводе данных, а также их анализе врачом представляет собой суточный мониторинг артериального давления (СМАД), поскольку содержит порядка 40 строк со значениями систолического (SBP) и диастолического (DBP) давлений, среднего артериального давления (MAP), частоты сердечных сокращений (BPM) и пульсового давления (PP). Автоматизация ввода данных и их дальнейший анализ с использованием ИИ дают возможность снизить риск ошибок¹ и ускорить процессы диагностики и принятия решений². Разработанный

¹ Van Terheyden, N. Informatics and Mass Data Analysis in Digital Health [Electronic Resource] / N. van Terheyden // Digital Health. 2018. P. 55–64. Mode of access: https://link.springer.com/chapter/10.1007/978-3-319-61446-5_5. Date of access: 22.02.2025.

² Data Science in Healthcare: Benefits, Challenges and Opportunities [Electronic Resource] / Z. Abedjan [et al.] // Data Science for Healthcare: Methodologies and Applications, Springer. 2019. P. 3–38. Mode of access: https://link.springer.com/chapter/10.1007/978-3-030-05249-2_1. Date of access: 25.02.2025.

модуль позволяет автоматизировать ввод следующих медицинских данных о пациенте: общий анализ крови, биохимический анализ крови, СМАД. Кроме того, модуль можно использовать, чтобы считывать анамнез с электрокардиограмм и других медицинских документов.

Особенности ввода входных данных

Входные данные представляют собой сканы и фотографии медицинских документов, которые могут быть как цветными, так и черно-белыми. Образцы входных данных представлены на рис. 1. Формат изображений варьируется от высококачественных цифровых снимков до черно-белых сканов с более низким разрешением.

Показатель	Результат	Ед. измер.	Референс. значения
АСТ	19	Ед.	0-35 Ед.
АЛТ	19	Ед.	0-35 Ед.
Мочевина	5.5	ммоль/л	2.5-7.5 ммоль/л (0-50 лет)
Креатинин	64.2	ммоль/л	44.2-106.1 ммоль/л
Билирубин общий	1.0	ммоль/л	0.4-2.0 ммоль/л
Глюкоза	5.50	ммоль/л	3.89-5.83 ммоль/л (0-80 лет)
Общий белок	79	г/л	64-81 г/л
Натрий	138	ммоль/л	136-145 ммоль/л
Калий	4.3	ммоль/л	3.5-5.1 ммоль/л
Хлор	106	ммоль/л	98-103 ммоль/л
Холестерин общий	5.15	ммоль/л	более 5.6 ммоль/л
Триглицериды	0.97	ммоль/л	0-1.6 ммоль/л
ЛПНП-холестерин	1.16	ммоль/л	более 1.6 ммоль/л
ЛПВП-холестерин	3.95	ммоль/л	2.0-4.1 ммоль/л
Коэффициент атерогенности	3.4		1.2-3.3
Н	0.07		

Num	Time	Sys(Da)	HR	DAP	PP	QC	Comment
14	11:11	149/82	91	112	47		
2	11:20	150/82	89	115	56		
3	11:20	151/81	87	112	50		
4	11:47	138/96	87	107	42		
5	11:57	141/93	84	104	48		
6	12:14	140/112	80	123	49		
7	12:29	164/102	93	114	62		
9	13:05	136/92	89	105	44		
10	13:23	132/84	94	102	38		
11	13:32	142/88	89	109	44		
12	13:48	153/95	86	107	58		
13	14:05	158/88	88	90	50		
14	14:18	139/93	86	104	46		
15	14:37	158/86	92	95	52		
16	14:49	155/82	93	107	53		
17	14:58	158/99	86	102	56		
18	15:11	157/86	90	109	53		
19	15:22	147/86	89	100	61		
20	15:55	143/99	86	112	64	2	Artifact / erratic signal
21	16:15	130/91	90	108	59	4	Measurement timeout
22	16:31	157/94	84	105	59		
23	16:44	149/103	84	110	46		
24	17:01	143/95	85	108	48		
25	17:20	139/82	89	107	56		
26	17:58	150/103	88	115	55		
27	17:57	158/92	88	105	66	4	Measurement timeout
28	18:12	136/90	89	103	46	2	Artifact / erratic signal
29	18:32	163/102	91	116	59		
32	19:26	158/101	75	115	57	2	Artifact / erratic signal
33	19:44	167/104	84	119	63	4	Measurement timeout
34	19:56	150/103	86	108	53	4	Measurement timeout
35	20:18	156/99	96	109	57	2	Artifact / erratic signal
36	20:35	147/102	90	114	45		
37	21:06	134/81	86	95	53		
38	21:17	152/73	88	84	50		
39	21:35	158/103	89	113	55		
42	22:35	158/89	80	104	69		
43	22:58	143/89	81	102	54		

Рис. 1. Пример входных данных: *a* – биохимический анализ крови; *b* – суточный мониторинг артериального давления

Fig. 1. Example of input data: *a* – biochemical blood test; *b* – daily blood pressure monitoring

В выходных данных зачастую присутствуют следующие особенности:

- при сканировании и фотографировании нередко возникают посторонние шумы и артефакты, которые затрудняют извлечение текста и снижают точность распознавания;
- наличие наклона документа относительно горизонтальной оси требует предварительной коррекции для корректного анализа;
- фотографии часто характеризуются неравномерной освещенностью и контрастом, что усложняет сегментацию текстовых фрагментов;
- разнообразие используемых шрифтов и их масштаб, наличие мелкого текста обуславливают необходимость увеличения разрешения для адекватного распознавания;
- некоторые изображения могут содержать печатные или рукописные комментарии, что добавляет вариативности в задачу распознавания;
- сложности при извлечении табличных данных, где стандартные OCR-инструменты не справляются с распознаванием сложных структур, таких как многоуровневые таблицы и графики [10];
- необходимость обработки медицинских сокращений и терминов, которые не всегда корректно интерпретируются стандартными алгоритмами OCR³.

Эти особенности формируют набор задач при обработке медицинских документов, содержащих текст: шумоподавление, выравнивание изображения, выделение текстовых областей, корректное сегментирование строк и выделение параметров для анализа.

³ Blahuta, J. An OCR-Based Application using Tesseract Engine to Extract Text Information from Ultrasound B-MODE Images [Electronic Resource] / J. Blahuta // Proceedings of the 24th Conference Information Technologies – Applications and Theory (ITAT 2024), Drienica, Slovakia, Sept. 20–24, 2024. Mode of access: <https://ceur-ws.org/Vol-3792>. Date of access: 17.02.2025.

Архитектура модуля анализа текстовой информации

Модуль анализа текстовых данных представляет собой программный инструмент, состоящий из четырех ключевых компонентов, каждый из которых выполняет определенную задачу, связанную с обработкой и анализом текстовой информации, содержащейся в медицинских документах. Основной задачей модуля является автоматизация анализа данных, таких как результаты биохимических анализов или СМАД, с их преобразованием в структурированный формат, который можно использовать для дальнейшей обработки. Схема, иллюстрирующая структуру модуля и взаимосвязи его компонентов, представлена на рис. 2.

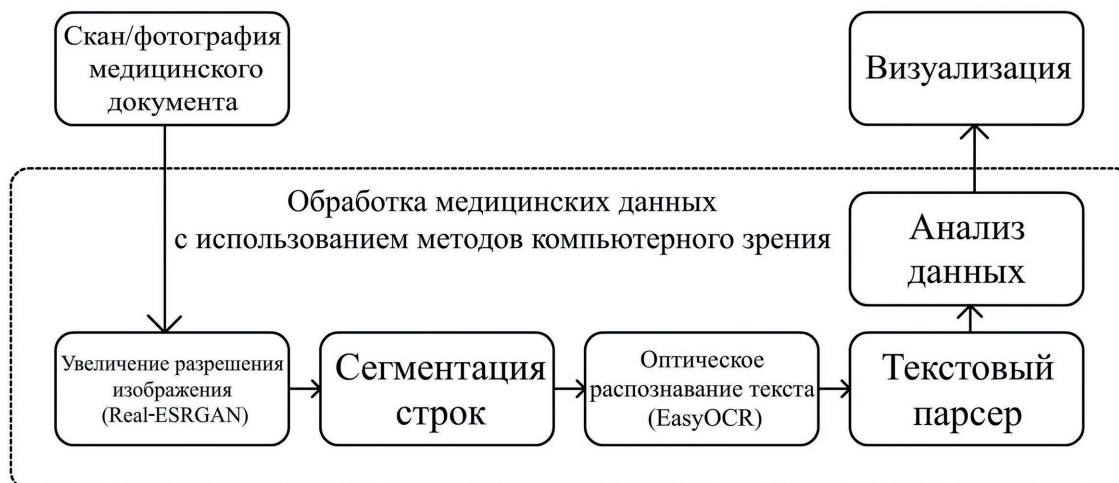


Рис. 2. Структурная схема модуля
Fig. 2. Structural diagram of the module

Взаимодействие компонентов модуля автоматизированной обработки медицинских изображений реализуется следующим образом. Первоначально входное изображение обрабатывается с применением алгоритма суперразрешения Real-ESRGAN, повышающего четкость и читаемость текста. Затем выполняется сегментация, в ходе которой изображение разделяется на отдельные строки. Далее применяется OCR-модель EasyOCR для извлечения символьной информации. Финальным этапом является анализ с помощью текстового парсера алгоритмов сопоставления с референтными значениями. Real-ESRGAN представляет собой архитектуру нейронной сети, основанную на генеративно-сопоставительных сетях (GAN), которая специально разработана для задач суперразрешения изображений. Real-ESRGAN демонстрирует худшие количественные результаты по метрикам PSNR и SSIM, однако визуальные сравнения показали, что Real-ESRGAN создает изображения с более четкими краями и улучшенной контрастностью⁴. Увеличение размера символов и их контраста с фоном изображения может повышать эффективность работы OCR.

В исследовании [11] отображены количественные результаты сравнения различных моделей суперразрешения изображений, оцениваемых по метрике Naturalness Image Quality Evaluator (NIQE). Оценка проводилась на семи различных тестовых наборах данных: Set5, Set14, BSD100, Urban100, DIV2K100, RealSR (Canon) и RealSR (Nikon). Сравнивались классические модели SRResNet, BSRGAN, SDSR, SwinIR, а также Real-ESRGAN, IRE и IRE+, обученные на основе подхода Real-ESRGAN. Результаты показывают, что модель Real-ESRGAN демонстрирует превосходство над большинством конкурентов, достигая наиболее низких значений NIQE на всех тестовых наборах, за исключением Urban100 и RealSR (Nikon). Модели IRE и IRE+, обученные на основе Real-ESRGAN, достигают лучших значений NIQE среди всех представленных моделей.

В процессе адаптации модуля оптического распознавания текста под специфику обработки текстовых данных проекта было важно обеспечить точность распознавания текстов с уче-

⁴ Yamashita, K. Medical Image Enhancement Using Super Resolution Methods [Electronic Resource] / K. Yamashita, K. Markov // Computational Science – ICCS 2020: Proceedings of the 20th International Conference, Amsterdam, Netherlands, June 2020. P. 496–508. Mode of access: https://link.springer.com/chapter/10.1007/978-3-030-50426-7_37. Date of access: 12.03.2025.

том специфических особенностей русского языка и структуры данных, используемых в проекте. Для достижения этой цели применялись синтетические датасеты, которые позволили имитировать реальные условия работы модуля. На рис. 3 представлено изображение биохимического анализа до и после использования Real-ESRGAN. Исходя из этого, можно сделать вывод, что Real-ESRGAN вносит свои искажения в символы текста, однако убирает шумы и увеличивает контрастность символов. В связи с этим 50 % синтетического датасета предварительно прошло обработку с помощью Real-ESRGAN.

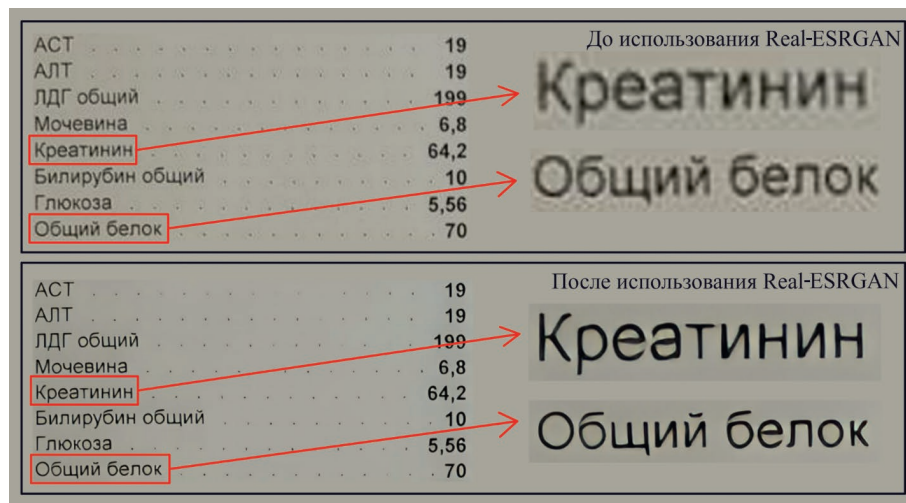


Рис. 3. Фрагмент изображения биохимического анализа до и после использования Real-ESRGAN

Fig. 3. Fragment of a biochemical analysis image before and after applying Real-ESRGAN

На рис. 4 показаны примеры сгенерированных изображений с текстом, созданных для последующего использования в обучении модели EasyOCR. Для размытия изображений применялась функция ImageFilter.GaussianBlur из библиотеки Pillow, радиус размытия изображения выбран 1,6 px.

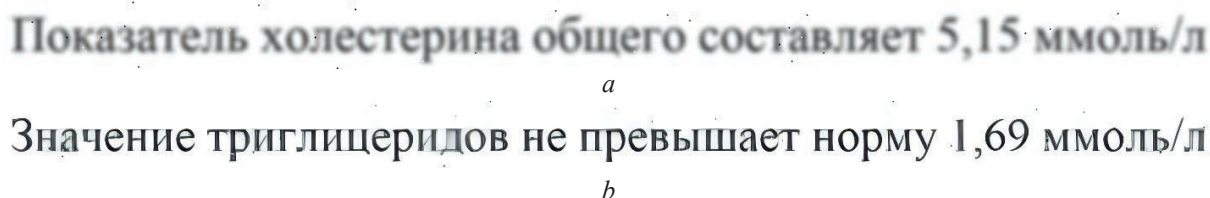


Рис. 4. Сгенерированные изображения: а – без суперразрешения; б – с использованием Real-ESRGAN

Fig. 4. Generated images: a – without superresolution; b – using Real-ESRGAN

Компонент Line Segmenter содержит инструменты для корректировки угла наклона изображения относительно вертикали, а также разделения документа на строки для повышения эффективности распознавания текста EasyOCR. Для реализации компонента использовались методы предварительной обработки с помощью OpenCV, для коррекции наклона применялся алгоритм, который опирается на анализ горизонтальных проекционных профилей и вычисление дисперсии гистограмм: изображение поворачивается на набор углов в заданном диапазоне значений, для каждого поворота строится проекция и оценивается ее дисперсия; в итоге выбирается угол с максимальной дисперсией, при котором разделение строк наиболее четкое.

EasyOCR представляет собой библиотеку для оптического распознавания текста, основанную на архитектуре, сочетающей сверточные (CNN) и рекуррентные (RNN) нейронные сети. На первом этапе с использованием CNN осуществляется локализация текстовых фрагментов на изображении, после чего RNN выполняет обработку символов в извлеченных текстовых последовательностях.

Модель EasyOCR настроена на использование CRAFT для точного обнаружения текстовых регионов и интегрирует извлекатель признаков на основе VGG с последовательной моделью BiLSTM и слоем прогнозирования CTC, специально адаптированными для распознавания

обширного набора кириллических и латинских символов. Обученная на синтетическом датасете, состоящем из 50 % сгенерированных данных и 50 % данных, обработанных Real-ESRGAN, с размером батча 64 и количеством итераций 20 000, модель обрабатывает градации серого изображения размерами 64×600 и использует скрытый размер 256 в слое BiLSTM для повышения точности распознавания.

Анализ эффективности EasyOCR, выполненный в рамках предыдущих исследований, охватывает влияние таких факторов, как контраст между символами и фоном, степень гауссового размытия и относительные размеры текста. Проведено сравнение EasyOCR и Tesseract для распознавания автомобильных номеров. Согласно результатам, метрика Character Error Rate (CER) показала, что EasyOCR превосходит Tesseract при работе с цифрами, демонстрируя итоговую точность распознавания 95 % против 88 % у Tesseract. Следовательно, EasyOCR является более подходящим вариантом для обработки изображений, содержащих СМАД⁵.

Согласно исследованию Comparison of OCR, библиотека EasyOCR показала хорошие результаты при работе с зашумленными изображениями и структурированным текстом, оставаясь при этом легковесной и производительной. В то же время библиотека Keras-OCR требовала значительных вычислительных ресурсов, что делает ее менее подходящей для реального времени, а программа Tesseract оказалась чувствительной к наличию нескольких текстовых областей на изображении, требуя предварительной сегментации⁶. Отмечено, что обработка низкокачественных изображений остается значимой проблемой, которую EasyOCR решает более эффективно за счет устойчивости к шумам и артефактам [12].

При работе с EasyOCR было изучено влияние таких параметров, как разница интенсивности символов и фона, гауссово размытие и относительный размер символов, на точность распознавания символов. EasyOCR отлично различает уникальные строчные и прописные символы, но склонна отдавать предпочтение прописным для схожих форм. Результаты показали, что высокая разница интенсивности символа и фона влияет на результаты OCR, при этом доверительные оценки варьируются от 3 до 80 %. Размытие, как правило, снижает точность, но может оказывать положительное влияние на интерпретацию отдельных символов (например, v). Размер изображения оказывал значительное влияние: при уменьшении размера до 40–30 % от оригинала распознавание символов не происходило⁷.

Можно предположить, что для повышения точности распознавания при наличии артефактов на изображениях, вызванных размытостью или низким разрешением, необходимо применять методы увеличения разрешения изображения для его предварительной обработки. Следует отметить, что методы суперразрешения, использующие GAN, позволяют улучшить точность распознавания символов более чем на 20 % при работе с изображениями низкого разрешения⁸.

В Text Parser использованы регулярные выражения для выделения в полученном EasyOCR тексте данных, таких как название, значение определенного параметра анализа крови или СМАД. Параметры сопоставляются с референтными значениями с целью выделения значимых для диагностики гипертонических заболеваний параметров.

Результаты исследований и их обсуждение

Для оценки эффективности обучения модели EasyOCR на синтетическом датасете были использованы две метрики: потери на этапах обучения и валидации, точность модели. На рис. 5 представлены графики изменения этих метрик в зависимости от числа итераций (шагов) обучения модели.

⁵ Comparative Analysis of EasyOCR and TesseractOCR for Automatic License Plate Recognition Using Deep Learning Algorithm / D. R. Vedhaviyassh [et al.] // Proceedings of the 6th International Conference on Electronics, Communication and Aerospace Technology (ICECA), Coimbatore, India, 2022. P. 966–971.

⁶ Comparison of OCR [Electronic Resource]. Mode of access: <https://github.com/mftnakrsu/Comparison-of-OCR>. Date of access: 02.03.2025.

⁷ Analysis of Optical Character Recognition Using EasyOCR under Image Degradation [Electronic Resource] / M. A. M. Salehudin [et al.] // Journal of Physics: Conference Series. 2023. Vol. 2641. Mode of access: <https://doi.org/10.1088/1742-6596/2641/1/012001>. Date of access: 11.03.2025.

⁸ Lat, A. Enhancing OCR Accuracy with Super Resolution [Electronic Resource] / A. Lat, C. V. Jawahar // 2018 24th International Conference on Pattern Recognition (ICPR). Mode of access: <https://ieeexplore.ieee.org/document/8545609>. Date of access: 14.03.2025.

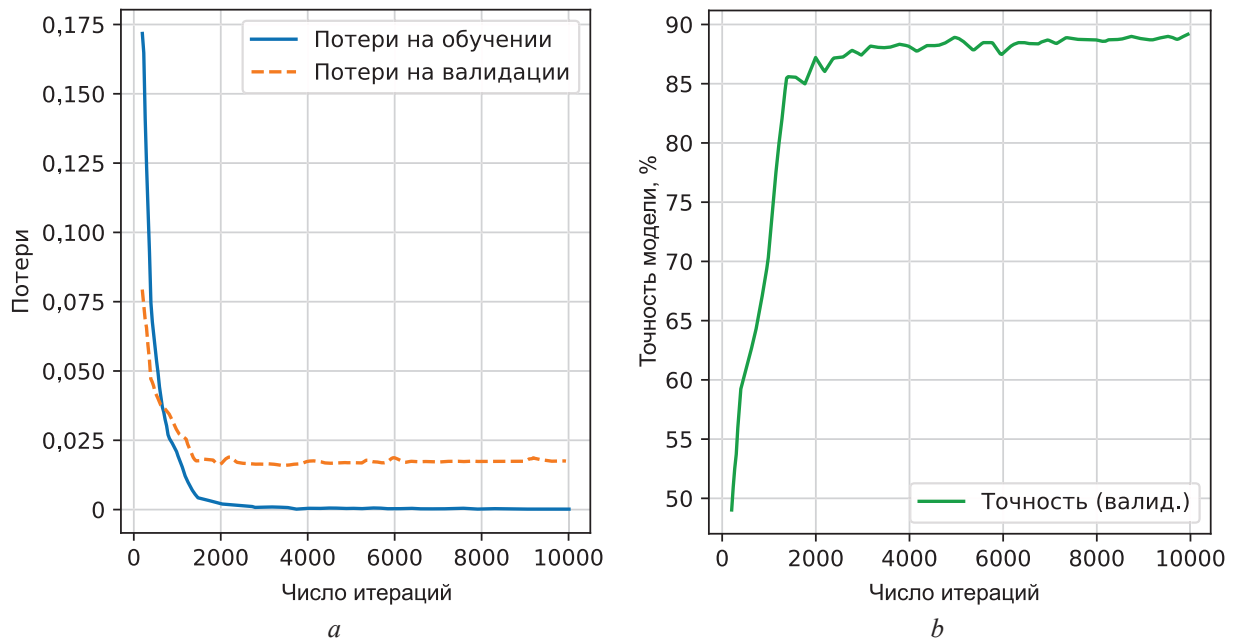


Рис. 5. Метрики качества обучения EasyOCR: *a* – потери на обучении и валидации; *b* – точность модели
Fig. 5. Model training performance metrics: *a* – training and validation loss; *b* – accuracy

На рис. 5, *a* показаны потери на этапах обучения и валидации. По оси абсцисс отложено число шагов (итераций), по оси ординат – значения потерь. Из рисунка видно, что как на обучении, так и на валидации величины потерь снижаются, достигая минимальных значений при увеличении числа шагов. На рис. 5, *b* представлена динамика изменения точности модели в зависимости от числа шагов обучения. График показывает, что модель быстро достигает высокого уровня точности, превышая 85 % уже после первых 2000 итераций.

После этапа обучения модели проводились эксперименты по определению эффективности использования Real-ESRGAN на синтетически созданном датасете и на фотографиях медицинских документов. На рис. 6 представлены зависимости точности распознавания текста от радиуса размытия изображения без использования суперразрешения и с применением Real-ESRGAN.

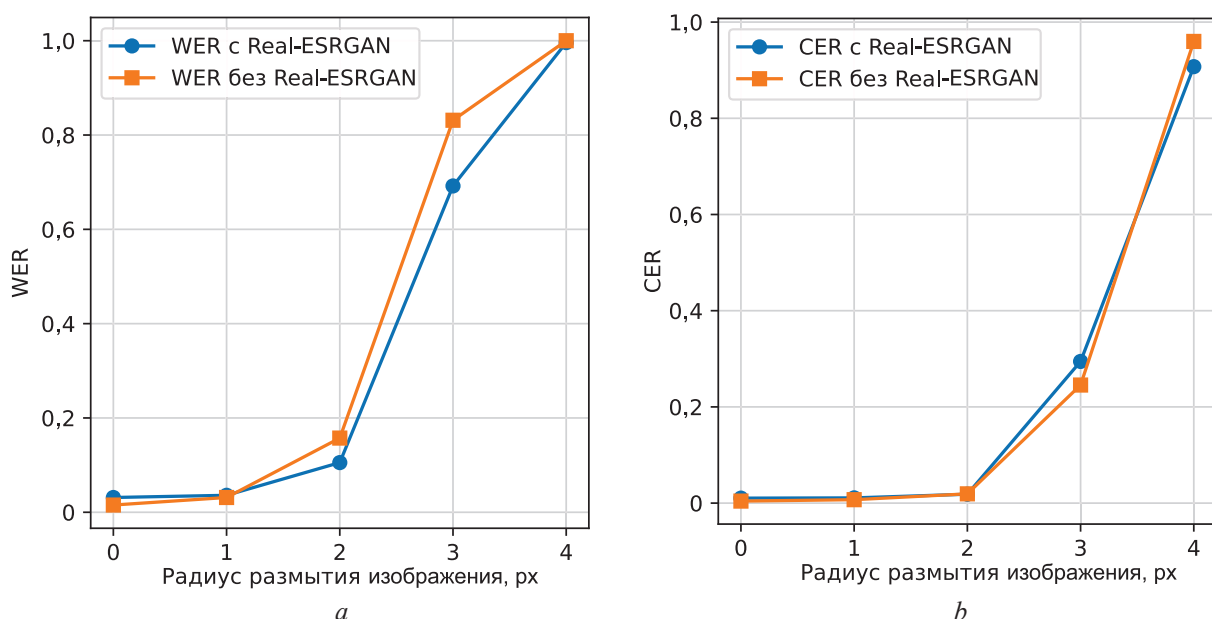


Рис. 6. Влияние радиуса размытия изображения на точность распознавания текста по метрикам:
a – WER; *b* – CER

Fig. 6. The influence of image blur radius on text recognition accuracy using metrics: *a* – WER; *b* – CER

Для оценки точности использовались метрики CER, WER. Можно сделать вывод, что Real-ESRGAN позволяет получить более точные результаты на синтетическом датасете только при радиусе размытия изображения более 2 px.

Однако без применения увеличения разрешения и разделения строк данные для любого типа анализа демонстрировали значительные потери точности при распознавании. Использование вышеуказанных методов позволило повысить точность распознавания параметров биохимического анализа и СМАД. Вероятно, это связано с наличием на фотографиях артефактов, таких как шум высокого уровня, артефакты сжатия изображения, размытость движения и неравномерное освещение, которые Real-ESRGAN способен эффективно устранять. Можно сделать вывод, что синтетический датасет не в полной мере моделирует эти сложные и случайные эффекты, что приводит к различиям в качестве распознавания.

Фрагмент результатов распознавания параметров СМАД представлен на рис. 7. Некорректное распознавание или отклонения значений от нормы легче идентифицировать благодаря цветовой кодировке (зеленый – в норме, красный – выше нормы). Однако в данном случае расхождений не наблюдается, поскольку измеренные значения действительно соответствуют повышенным параметрам давления.

Num	Time	Sys/Dia (mmHg)	HR (BPM)	MAP (mmHg)	PP (mmHg)
1+	11:11	149/102	91	112	47
2	11:20	158/102	89	115	56
3	11:30	151/101	87	112	50
4	11:47	138/ 96	87	107	42
5	11:57	141/ 93	84	104	48
6	12:14	161/112	80	123	49
7	12:29	164/102	93	114	62
9	13:05	136/ 92	89	103	44
10	13:22	132/ 94	94	102	38
11	13:32	142/ 98	89	109	44
12	13:48	153/ 95	86	107	58
13	14:05	138/ 88	88	99	50
14	14:18	139/ 93	86	104	46
15	14:37	138/ 86	92	95	52

a

	Time	Sys/Dia	HR	MAP	PP
1	11:11	149/102	91	112	47
2	11:20	158/102	89	115	56
3	11:30	151/101	87	112	50
4	11:47	141/93	87	107	42
5	12:14	161/112	80	123	49
6	12:29	164/102	93	114	62
7	13:05	136/92	89	103	44
8	13:22	132/94	94	102	38
9	13:32	142/98	89	109	44
10	13:48	153/95	86	107	58
11	14:05	138/88	88	99	50
12	14:18	139/93	86	104	46
13	14:37	138/86	92	95	52
14	14:48	135/102	93	107	33
15	14:58	135/99	86	102	36

b

Рис. 7. Пример работы модуля: *a* – фрагмент изначального изображения; *b* – результат обработки
Fig. 7. Example of the module's operation: *a* – fragment of the original image; *b* – result of processing

Заключение

1. Представленный модуль – важный шаг в сторону автоматизации медицинской диагностики и анализа данных. Тестирование показало высокую точность обработки фотографий медицинских данных. Однако для достижения оптимальной производительности в реальных условиях требуется дальнейшая доработка. Новизна предложенного метода – в интеграции суперразрешения изображений (Real-ESRGAN) и оптического распознавания текста (EasyOCR) в единый сквозной конвейер для медицинских документов: суперразрешение выступает обязательным этапом предобработки, а модель распознавания целенаправленно обучена на данных, получаемых после этого этапа, включая специально сформированный синтетический датасет на русском языке с долей изображений, прошедших суперразрешение. Дополнительно требуется адаптация GAN-моделей суперразрешения к текстовым паттернам (структуре глифов, непрерывности штрихов и локальному контрасту), что снижает артефакты и повышает устойчивость OCR.

2. Научная значимость исследования состоит в методике согласования этапов предобработки и распознавания через специализированный датасет, учитывающий реальные артефакты сканов и фотографий, а также характерные искажения, возникающие при применении суперразрешения на базе GAN. Такой подход сегодня не является общепринятым стандартом промышленной практики и задает основу для дальнейших исследований и внедрений. Практическая значимость заключается в возможности использования разработанного модуля как промежуточного звена с целью автоматизации ввода данных, что снижает нагрузку на медицинский персонал. Модуль

планируется применять для оптимизации процесса создания датасетов из имеющихся изображений, сканов для последующего обучения различных моделей в сфере кардиологии.

3. В числе приоритетных направлений будущих исследований предлагается адаптировать модели увеличения разрешения на базе генеративно-сопоставительных сетей к текстовым паттернам и согласованно дообучать их совместно с OCR, что может снизить артефакты и повысить устойчивость распознавания. Для улучшения адаптации системы к практическим задачам следует провести сравнение эффективности DE-GAN и Real-ESRGAN и разработку датасетов, более точно соответствующих реальным условиям получения изображений.

Список литературы

1. Kjeldsen, S. E. Hypertension and Cardiovascular Risk: General Aspects / S. E. Kjeldsen // *Pharmacological Research*. 2018. Vol. 129. P. 95–99.
2. Hypertension Management in the High Cardiovascular Risk Population / I. Maraj [et al.] // *International Journal of Hypertension*. 2013. <https://doi.org/10.1155/2013/382802>.
3. Handler, J. Clinical Challenges in Diagnosing and Managing Adult Hypertension / J. Handler // *Cleveland Clinic Journal of Medicine*. 2015. Vol. 82, Iss. 2. P. S36–S41.
4. Автоматизация обработки медицинских данных с использованием компьютерного зрения: подходы и перспективы внедрения в кардиологии / Е. А. Курлюк [и др.] // Средства медицинской электроники и новые медицинские технологии: матер. XIV Междунар. науч.-техн. конф. «Медэлектроника–2024», Минск, 5–6 дек. 2024 г. Минск: Белор. гос. ун-т информ. и радиоэлек., 2024. С. 254–259.
5. Применение искусственного интеллекта в кардиологии и перспективы его дальнейшего внедрения / Н. А. Ларченко [и др.] // Средства медицинской электроники и новые медицинские технологии: матер. XIV Междунар. науч.-техн. конф. «Медэлектроника–2024», Минск, 5–6 дек. 2024 г. Минск: Белор. гос. ун-т информ. и радиоэлек., 2024. С. 12–16.
6. Cardiac Imaging: Working Towards Fully-Automated Machine Analysis & Interpretation / P. J. Slomka [et al.] // *Expert Review of Medical Devices*. 2017. Vol. 14, No 3. P. 197–212.
7. Artificial Intelligence as a Business Partner in Cardiovascular Precision Medicine: An Emerging Approach for Disease Detection and Treatment Optimization / V. Visco [et al.] // *Current Medicinal Chemistry*. 2021. Vol. 28. P. 6569–6590.
8. Highly Precise Risk Prediction Model for New-Onset Hypertension Using Artificial Intelligence Techniques / H. Kanegae [et al.] // *The Journal of Clinical Hypertension*. 2020. Vol. 22. P. 445–450.
9. An Application of Machine Learning to Etiological Diagnosis of Secondary Hypertension: Retrospective Study Using Electronic Medical Records / X. Diao [et al.] // *JMIR Medical Informatics*. 2021. Vol. 9. <https://doi.org/10.2196/19739>.
10. Li, Y. Improving Tabular Data Extraction in Scanned Laboratory Reports Using Deep Learning Models / Y. Li, Q. Wei // *Journal of Biomedical Informatics*. 2024. Vol. 159. P. 1–13.
11. IRE: Improved Image Super-Resolution Based on Real-ESRGAN / Z. Zhu [et al.] // *IEEE Access*. 2023. Vol. 11. P. 45334–45348.
12. De-Las-Heras, G. Advanced Driver Assistance Systems (ADAS) Based on Machine Learning Techniques for the Detection and Transcription of Variable Message Signs on Roads / G. De-Las-Heras, J. Sánchez-Soriano, E. Puertas // *Sensors*. 2021. Vol. 21, No 17. <https://doi.org/10.3390/s21175866>.

Поступила 14.07.2025

Принята в печать 30.08.2025

Доступна на сайте 12.01.2026

References

1. Kjeldsen S. E. (2018) Hypertension and Cardiovascular Risk: General Aspects. *Pharmacological Research*. 129, 95–99.
2. Maraj I., Makaryus J. N., Ashkar A., McFarlane S. I., Makaryus A. N. (2013) Hypertension Management in the High Cardiovascular Risk Population. *International Journal of Hypertension*. 2013. <https://doi.org/10.1155/2013/382802>.
3. Handler J. (2015) Clinical Challenges in Diagnosing and Managing Adult Hypertension. *Cleveland Clinic Journal of Medicine*. 82 (2), S36–S41.
4. Kurlyuk E. A., Larchenko N. A., Davydov M. V., Kurlyanskaya E. K. (2024) Automation of Medical Data Processing Using Computer Vision: Approaches and Implementation Prospects in Cardiology. *Proceedings of the XIV International Scientific and Technical Conference “Medelectronics–2024”, Minsk, Dec. 5–6. Minsk, Belarusian State University of Informatics and Radioelectronics*. 254–259 (in Russian).

5. Larchenko N. A., Kurlyuk E. A., Davydov M. V., Kurlyanskaya E. K. (2024) Application of Artificial Intelligence in Cardiology and Prospects for Its Implementation. *Proceedings of the XIV International Scientific and Technical Conference "Medelectronics-2024", Minsk, Dec. 5–6*. Minsk, Belarusian State University of Informatics and Radioelectronics. 12–16 (in Russian).
6. Slomka P. J., Dey D., Sitek A., Motwani M., Berman D. S., Germano G. (2017) Cardiac Imaging: Working Towards Fully-Automated Machine Analysis & Interpretation. *Expert Review of Medical Devices*. 14 (3), 197–212.
7. Visco V., Ferruzzi G. J., Nicastro F., Virtuoso N., Carrizzo A., Galasso G., et al. (2021) Artificial Intelligence as a Business Partner in Cardiovascular Precision Medicine: An Emerging Approach for Disease Detection and Treatment Optimization. *Current Medicinal Chemistry*. 28, 6569–6590.
8. Kanegae H., Suzuki K., Fukatani K., Ito T., Harada N., Kario K. (2020) Highly Precise Risk Prediction Model for New-Onset Hypertension Using Artificial Intelligence Techniques. *The Journal of Clinical Hypertension*. 22, 445–450.
9. Diao X., Huo Y., Zhanzheng Y., Wang H., Yuan J., Wang Y., et al. (2021) An Application of Machine Learning to Etiological Diagnosis of Secondary Hypertension: Retrospective Study Using Electronic Medical Records. *JMIR Medical Informatics*. 9. <https://doi.org/10.2196/19739>.
10. Li Y., Wei Q. (2024) Improving Tabular Data Extraction in Scanned Laboratory Reports Using Deep Learning Models. *Journal of Biomedical Informatics*. 159, 1–13.
11. Zhu Z., Lei Y., Qin Y., Zhu C., Zhu Y. (2023) IRE: Improved Image Super-Resolution Based on Real-ESRGAN. *IEEE Access*. 11, 45334–45348.
12. De-Las-Heras G., Sánchez-Soriano J., Puertas E. (2021) Advanced Driver Assistance Systems (ADAS) Based on Machine Learning Techniques for the Detection and Transcription of Variable Message Signs on Roads. *Sensors*. 21 (17). <https://doi.org/10.3390/s21175866>.

Received: 14 July 2025

Accepted: 30 August 2025

Available on the website: 12 January 2026

Вклад авторов / Authors' contribution

Авторы внесли равный вклад в написание статьи / The authors contributed equally to the writing of the article.

Сведения об авторах

Курлюк Е. А., оператор ПЭВМ науч.-исслед. лаб. ультразвуковых технологий и оборудования, Белорусский государственный университет информатики и радиоэлектроники (БГУИР)

Ларченко Н. А., студент, БГУИР

Давыдов М. В., канд. техн. наук, доц., первый проректор, БГУИР

Курлянская Е. К., д-р мед. наук, проф., зам. дир. по терапевтической помощи, Республиканский научно-практический центр «Кардиология»

Адрес для корреспонденции

220013, Республика Беларусь,
Минск, ул. П. Бровки, 6
Белорусский государственный университет
информатики и радиоэлектроники
Тел.: +379 29 794-86-00
E-mail: kurluke750@gmail.com
Курлюк Евгений Александрович

Information about the authors

Kurliuk Y. A., PC Operator of the Research Laboratory of Ultrasound Technologies and Equipment, Belarusian State University of Informatics and Radioelectronics (BSUIR)

Larchenko N. A., Student, BSUIR

Davydov M. V., Cand. Sci. (Tech.), Associate Professor, First Vice-Rector, BSUIR

Kurlyanskaya E. K., Dr. Sci. (Med.), Professor, Deputy Director for Therapeutic Care, Scientific and Practical Centre "Cardiology"

Address for correspondence

220013, Republic of Belarus,
Minsk, P. Brovki St., 6
Belarusian State University
of Informatics and Radioelectronics
Tel.: +379 29 794-86-00
E-mail: kurluke750@gmail.com
Kurliuk Yauheni Aleksandrovich