

Минкин Александр Владимирович
Казанский (Приволжский) федеральный университет» (филиал в г. Елабуга)
Мифтахова Айгуль Рустамовна
Казанский (Приволжский) федеральный университет» (филиал в г. Елабуга)

**Оценка экономической эффективности и управленческого потенциала при
оптимизация диагностики лейкоза с помощью глубокого обучения**

Аннотация. Исследование посвящено разработке и комплексной оценке алгоритма глубокого обучения для автоматизации ключевого этапа диагностики острого лимфобластного лейкоза (ОЛЛ) — морфологического анализа клеток крови. Цель работы — преодолеть разрыв между технической валидацией ИИ и оценкой его экономико-управленческого потенциала. На репрезентативном клиническом датасете (15 135 изображений) модель EfficientNetB3 достигла точности 97.5%, чувствительности 96.2% и специфичности 97.8% (AUC-ROC = 0.987). Ключевым результатом является количественная оценка операционного эффекта: экономико-временная симуляция показала, что использование алгоритма в качестве системы предварительного отбора способно сократить время рутинного скрининга специалистом на 70–85%. Это высвобождает самый ценный ресурс — время эксперта — для решения сложных задач. Делается вывод, что внедрение подобных решений ведет к трем основным результатам: повышению операционной эффективности лаборатории, стандартизации качества диагностики и трансформации труда специалиста в сторону более высокой добавленной стоимости. Таким образом, работа демонстрирует, что технологии ИИ представляют собой не просто инструмент повышения точности, а стратегическую инвестицию в создание более устойчивой и экономически эффективной системы здравоохранения.

Ключевые слова: искусственный интеллект, глубокое обучение, диагностика, экономика здравоохранения острый лимфобластный лейкоз, операционная эффективность.

Minkin Alexander Vladimirovich
Kazan (Volga Region) Federal University Branch in Yelabuga
Miftakhova Aigul Rustamovna
Kazan (Volga Region) Federal University Branch in Yelabuga

**Optimizing the diagnosis of leukemia through deep learning: assessment of
economic efficiency and management potential**

Annotation. The research is devoted to the development and comprehensive evaluation of a deep learning algorithm for automating a key stage in the diagnosis of acute lymphoblastic leukemia (ALL) — morphological analysis of blood cells. The aim of the work is to bridge the gap between the technical validation of AI and the assessment of its economic and managerial potential. Based on a representative clinical dataset (15,135 images), the EfficientNetB3 model achieved 97.5% accuracy, 96.2% sensitivity, and 97.8% specificity (AUC-ROC = 0.987). The key result is a quantitative assessment of the operational effect: economic and temporal simulation has shown that using the algorithm as a pre-selection system can reduce the time of routine screening by a specialist by 70-85%. This frees up the most valuable resource — the expert's time — to solve complex problems. It is concluded that the implementation of such solutions leads to three main results: improving the operational efficiency of the laboratory, standardizing the quality of diagnostics, and transforming the specialist's work towards higher added value. Thus, the work

demonstrates that AI technologies are not just a tool for improving accuracy, but a strategic investment in creating a more sustainable and cost-effective healthcare system.

Keywords: artificial intelligence, deep learning, diagnostics, healthcare economics, acute lymphoblastic leukemia, operational efficiency.

Введение. Острый лимфобластный лейкоз (ОЛЛ) остается не только наиболее распространенным онкологическим заболеванием в педиатрической практике, но и источником значительного экономического бремени для систем здравоохранения во всем мире. Высокая интенсивность лечения, длительные госпитализации и необходимость применения дорогостоящих таргетных препаратов и клеточных терапий формируют сложный финансовый профиль каждого клинического случая. При этом отправной точкой всего терапевтического пути и ключевым фактором, определяющим как клинический прогноз, так и структуру будущих затрат, является точная и своевременная диагностика. Её краеугольным камнем традиционно выступает морфологический анализ мазка периферической крови и костного мозга — рутинная, но критически важная процедура, требующая высокой квалификации врача-лаборанта (морфолога) и значительных временных затрат.

В условиях растущего давления на бюджеты здравоохранения и хронического дефицита узких специалистов, особенно в регионах, управленческая парадигма смещается в сторону поиска решений, способных одновременно повышать эффективность, стандартизировать качество и контролировать издержки. Современные технологии искусственного интеллекта, в частности, глубокое обучение для компьютерного зрения, предлагают принципиально новый подход к оптимизации таких высококвалифицированных, но рутинных диагностических процессов [1, 4]. Они позволяют автоматизировать первичный анализ, минимизировать субъективность и высвободить самый ценный ресурс — время эксперта — для интерпретации сложных случаев и принятия стратегических клинических решений. Однако, несмотря на обширные исследования, доказывающие техническую осуществимость автоматической классификации клеток [5], в академической литературе сохраняется существенный пробел в области изучения прямых экономических и операционных последствий внедрения таких систем.

Существующие работы, публикуемые в технологических и клинических журналах, фокусируются преимущественно на достижении максимальных метрик точности (Accuracy, AUC-ROC), часто на идеализированных или небольших наборах данных. В то же время в изданиях, посвященных экономике и менеджменту здравоохранения, подобные технологические инновации рассматриваются, как правило, на макроуровне, без глубокого погружения в технические детали, определяющие их реальную применимость и экономику. Недостаточно изученным остается вопрос о том, как именно алгоритмическая точность трансформируется в конкретные управленческие показатели: сокращение времени диагностического цикла, изменение производительности лаборатории, перераспределение трудовых функций и, в конечном итоге, влияние на структуру затрат на пациента.

Целью данной статьи является преодоление этого междисциплинарного разрыва. Мы представляем не просто еще одно исследование по классификации изображений клеток, а целостный экономико-технологический фреймворк для оценки подобных решений. В статье решаются три взаимосвязанные задачи:

1. Разработка и строгая валидация модели глубокого обучения для бинарной классификации клеток крови (нормальные клетки / лейкоэмические бласты) на масштабном, клинически репрезентативном наборе данных, аннотированном экспертом.

2. Количественная оценка, с помощью дискретно-событийной симуляции, потенциала внедрения данной модели для оптимизации рабочего процесса в гематологической лаборатории, с акцентом на высвобождение времени специалистов.

3. Формулировка конкретных выводов и рекомендаций для руководителей медицинских учреждений, страховых компаний и регуляторов о потенциальной роли ИИ-инструментов в повышении операционной эффективности, стандартизации качества диагностики и построении более устойчивых финансовых моделей в высокотратных областях медицины, таких как онкогематология.

Таким образом, настоящая статья вносит вклад как в прикладную науку о данных, демонстрируя надежный методологический подход для клинически значимой задачи, так и в экономику здравоохранения, предлагая модель для расчета окупаемости и управленческой ценности технологий искусственного интеллекта на микроуровне отдельной диагностической службы [6,9].

Методы исследования. Основу данного исследования составляет разработка и валидирование алгоритма глубокого обучения для автоматизированной морфологической классификации клеток периферической крови при остром лимфобластном лейкозе (ОЛЛ). Ключевой методологической целью являлось создание не просто точной модели, но инструмента, способного оптимизировать рабочий процесс лабораторной диагностики, что имеет прямые последствия для операционной эффективности и распределения ресурсов в системе здравоохранения. Исследование построено на задаче бинарной классификации сегментированных изображений клеток на два класса: нормальные клетки и лейкоэмические бласты.

Используемый датасет включает 15 135 уникальных изображений клеток, полученных от 118 пациентов с ОЛЛ [3]. Критически важным аспектом для обеспечения клинической релевантности и последующей экономической интерпретации является происхождение данных. Все изображения являются репрезентативными для рутинной клинической практики: они содержат артефакты, возможные при стандартном окрашивании по Романовскому-Гимзе, а также незначительные вариации в освещении. Это свидетельствует о том, что модель обучалась и тестировалась на данных, максимально приближенных к реальным условиям работы гематологической лаборатории, а не на идеализированных изображениях. Золотым стандартом для разметки данных послужила экспертиза врача-онколога, который вручную аннотировал каждую клетку, что обеспечивает высокую надежность эталонных меток для обучения модели.

Для решения задачи классификации был применен метод трансферного обучения — современный подход, позволяющий использовать предобученные на обширных наборах изображений (например, ImageNet) нейронные сети и дообучать их на специфичной медицинской задаче [1]. Это эффективно с точки зрения вычислительных ресурсов и времени, что напрямую соотносится с экономией затрат на разработку. В качестве архитектур-кандидатов были выбраны сверточные нейронные сети (Convolutional Neural Networks, CNN), показавшие выдающиеся результаты в компьютерном зрении, а именно модели ResNet50, EfficientNetB3 и DenseNet121. Выбор именно этих архитектур обусловлен их компромиссом между точностью, скоростью вывода и числом параметров, что является практическим вопросом для потенциального внедрения в условиях ограниченных вычислительных мощностей лабораторий.

Перед обучением все изображения прошли этап стандартной предобработки: масштабирование до фиксированного размера, нормализация значений пикселей и применение техник аугментации данных (data augmentation) [4]. Аугментация, включающая случайные повороты, отражения и небольшие изменения в цветопередаче, искусственно увеличивает разнообразие обучающей выборки, что является ключевым методом борьбы с переобучением и повышения способности модели к обобщению на новые данные от разных пациентов и из разных лабораторий.

Для корректной оценки обобщающей способности модели и избежания оптимистичной предвзятости был применен строгий протокол валидации, ориентированный на пациента. Вместо случайного разделения всех 15 тысяч изображений, данные были разделены на обучающую и тестовую выборки на уровне пациентов. Это

означает, что все изображения от конкретного пациента попадали либо только в обучающую, либо только в тестовую выборку. Такой подход имитирует реальную ситуацию, когда модель, обученная на данных одних пациентов, должна корректно работать с данными совершенно новых, ранее не виденных пациентов. Он является более консервативным и клинически достоверным, чем случайное разделение. В рамках обучающей выборки далее использовалась 5-кратная перекрестная проверка для тонкой настройки гиперпараметров моделей.

Оценка производительности модели проводилась на изолированной тестовой выборке с использованием набора метрик, учитывающих экономику ошибок в контексте медицины. Помимо общей точности (Accuracy), мы фокусировались на чувствительности (Sensitivity, или Recall) для класса «лейкемический бласт» и специфичности (Specificity). В диагностическом сценарии ложноположительный результат (нормальная клетка, классифицированная как бласт) ведет к дополнительным затратам времени эксперта на перепроверку, а ложноотрицательный результат (пропущенный бласт) несет в себе высокие клинические и, как следствие, финансовые риски, связанные с задержкой постановки диагноза и начала лечения. Для интегральной оценки использовалась площадь под ROC-кривой (AUC-ROC). Дополнительно, для интерпретации решений модели и повышения доверия со стороны врачей, применялись методы визуализации областей внимания (например, Grad-CAM), которые выделяют на исходном изображении участки, наиболее повлиявшие на решение нейронной сети [2].

Финальным методологическим компонентом является экономико-временная симуляция. На основе полученных метрик (время обработки одного изображения моделью, точность) была построена упрощенная модель рабочего процесса лаборанта-морфолога. В этой симуляции сравнивалось время, затрачиваемое на рутинный микроскопический анализ мазка крови с гипотетическим сценарием, где модель выступает в роли системы предварительного отбора и классификации, выделяя для врача только те клетки, которые с высокой вероятностью являются атипичными. Целью симуляции была количественная оценка потенциального высвобождения времени высококвалифицированного персонала, которое может быть перенаправлено на более сложные диагностические случаи или консультативную деятельность, что является прямым управленческим и экономическим результатом внедрения технологии [7].

Результаты. Разработанная модель глубокого обучения продемонстрировала высокую эффективность в автоматизированной классификации клеток. На изолированной тестовой выборке, состоящей из изображений от пациентов, не участвовавших в обучении, модель на архитектуре EfficientNetB3 показала наилучший результат. Ключевой метрикой в диагностическом контексте — площадь под ROC-кривой (AUC-ROC) — составила 0.987, что свидетельствует о выдающейся способности модели дискриминировать два класса.

Более детальный анализ метрик, имеющих прямое значение для клинического workflow, выявил следующие результаты: чувствительность (Sensitivity) модели для детекции лейкемических бластов достигла 96.2%, а специфичность (Specificity) — 97.8%. Это означает, что модель пропускает менее 4% аномальных клеток и лишь около 2% нормальных клеток маркирует ошибочно как подозрительные. Средняя точность (Accuracy) по всем классам составила 97.5%. Принципиально важным является анализ ошибок: большинство ложноотрицательных случаев (пропущенных бластов) были связаны с клетками, имеющими атипичную, «стертую» морфологию, в то время как ложноположительные — с реактивными лимфоцитами определенных стадий активации.

Визуализация областей внимания с помощью метода Grad-CAM подтвердила, что модель фокусируется на клинически релевантных морфологических признаках, таких как структура ядра, соотношение ядра и цитоплазмы и наличие нуклеол, а не на артефактах окрашивания [2]. Это повышает доверие к модели как к инструменту, способному воспроизводить логику эксперта.

Результаты экономико-временной симуляции показали наиболее значимый с точки зрения управления потенциал технологии. Традиционный микроскопический анализ мазка крови опытным лаборантом занимает в среднем 15-20 минут на образец. Модель, развернутая на стандартной рабочей станции с графическим ускорителем, способна предварительно проанализировать и аннотировать цифровой скан того же мазка за 2-3 минуты, выделив для последующей верификации врачом лишь 10-15% от общего числа клеток — те, что были классифицированы как «подозрительные» с вероятностью выше порогового значения. Таким образом, симуляция демонстрирует потенциальное сокращение времени, затрачиваемого специалистом на рутинный скрининг, на 70-85%. Это высвобождаемое время может быть перенаправлено на консультации сложных случаев, междисциплинарное обсуждение или увеличение пропускной способности лаборатории без расширения штата [7, 10].

Обсуждение. Полученные результаты подтверждают, что технологии машинного обучения, в частности глубокое обучение для компьютерного зрения, достигли уровня зрелости, достаточного для решения высокоточных задач медицинской диагностики, таких как морфологическая классификация клеток крови [5, 6]. Однако главный вклад данного исследования лежит не в области компьютерных наук, а в плоскости экономики здравоохранения и операционного менеджмента. Мы обсуждаем наши выводы через призму трех ключевых аспектов: эффективность, риск и трансформация труда.

Основной управленческий вывод заключается в возможности радикальной оптимизации рабочего процесса в клиничко-диагностической лаборатории. Модель выступает не как замена эксперта, а как мощный инструмент интеллектуальной предварительной сортировки (triage). Сокращение времени анализа на 70-85%, продемонстрированное в симуляции, трансформируется в прямые и косвенные экономические выгоды. Прямые — это возможность обслуживать больший объем исследований при тех же трудозатратах или снижение затрат на оплату сверхурочных работ в условиях пиковой нагрузки. Косвенные — это ускорение постановки диагноза, что сокращает время до начала целевой терапии, потенциально улучшая клинические исходы и снижая общую стоимость лечения за счет предотвращения осложнений [9]. Для руководства медицинских учреждений такая технология представляет собой инструмент для «умного» масштабирования услуг без пропорционального роста крупнейшей статьи расходов — фонда оплаты труда высококвалифицированного персонала [7].

Человеческая диагностика, несмотря на высокую квалификацию, подвержена влиянию усталости, субъективности и дефицита узких специалистов в регионах. Алгоритм, однажды обученный, работает с постоянным, воспроизводимым уровнем точности 24/7. Внедрение такой системы снижает дисперсию в качестве диагностики между разными специалистами, сменами и учреждениями. Это минимизирует риски, связанные с «человеческим фактором» — как клинические (пропуск заболевания), так и репутационно-юридические. Для страховых компаний и органов контроля качества это открывает путь к созданию новых стандартов, где алгоритмическая проверка становится частью протокола обеспечения качества. Высокая чувствительность модели (96.2%) делает ее эффективным «страховочным сетом», практически исключая грубые диагностические ошибки [6].

Внедрение ИИ не ведет к устранению врача или лаборанта, но закономерно меняет их роль от «сканеров» к «валидаторам и интерпретаторам». Это требует пересмотра образовательных программ и системы оплаты труда. Экономическая ценность труда специалиста смещается от скорости рутинного поиска к способности осуществлять окончательную клиническую интерпретацию сложных случаев, выявленных алгоритмом, и принимать управленческие решения на их основе. Таким образом, технология способствует повышению «удельной стоимости» рабочего времени специалиста, переводя его деятельность в категорию более интеллектуально насыщенного и высокооплачиваемого труда [8]. Для системы здравоохранения в целом это создает предпосылки для более

рационального и экономного использования самого дефицитного ресурса — экспертного человеческого капитала [7, 10].

Настоящее исследование имеет ряд ограничений. Модель была обучена и валидирована на данных от пациентов с ОЛЛ. Ее производительность на клетках при других онкогематологических заболеваниях (например, ОМЛ, МДС) требует отдельного изучения. Кроме того, экономическая симуляция оценивает потенциальный выигрыш во времени, в то время как полный анализ экономической эффективности (cost-effectiveness analysis) должен включать капитальные затраты на оцифровку мазков, ИТ-инфраструктуру, обслуживание и периодическое дообучение модели. Будущие исследования должны быть сфокусированы на проспективных клинико-экономических испытаниях, где внедрение алгоритма в реальный рабочий процесс лаборатории будет оценено не только по техническим метрикам, но и по конечным показателям: времени постановки диагноза, удовлетворенности персонала, сокращению операционных издержек и, в конечном счете, влиянию на затраты на лечение пациента [9].

Заключение

Разработанное программное приложение «Leukemia», основанное на технологии глубокого обучения, доказало свою высокую диагностическую точность в задаче идентификации лейкоцитарных бластов. Его ключевая ценность для экономики и управления здравоохранением заключается в потенциале кардинального повышения операционной эффективности лабораторной службы, стандартизации качества диагностики и трансформации труда специалистов в сторону более сложных, высокоценных задач. Внедрение подобных решений представляет собой не технологическую роскошь, а стратегическую инвестицию в создание более устойчивой, производительной и качественной системы оказания медицинской помощи, что является прямой целью рациональной экономической политики в здравоохранении.

Список источников

1. Balasamy, K. Medical Image Analysis Through Deep Learning Techniques: A Comprehensive Survey / K. Balasamy, V. Seethalakshmi, S. Suganyadevi // *Wireless Personal Communications*. – 2024. – Vol. 137, No. 3. – P. 1685-1714. – DOI 10.1007/s11277-024-11428-1. – EDN NTWQIE.
2. CerConvNet: Cervical Cancer Cells Prediction Using Convolutional Neural Networks / P. M, S. Patil, M. M V [et al.] // *Informatika (Ljubljana)*. – 2024. – Vol. 48, No. 3. – DOI 10.31449/inf.v48i3.5905. – EDN AGZDTD.
3. Gupta A., Gupta R. ALL Challenge dataset of ISBI 2019 [Электронный ресурс] : [набор данных] / A. Gupta, R. Gupta. — *The Cancer Imaging Archive*, 2019. — Режим доступа: <https://doi.org/10.7937/tcia.2019.dc64i46r> (дата обращения: 20.12.2025).
4. Simulation of computer image recognition technology based on image feature extraction / W. Ying, L. Zhang, Sh. Luo [et al.] // *Soft Computing - A Fusion of Foundations, Methodologies and Applications*. – 2023. – Vol. 27, No. 14. – P. 10167-10176. – DOI 10.1007/s00500-023-08246-1. – EDN LIKRVQ.
5. Tens of images can suffice to train neural networks for malignant leukocyte detection / J. P. E. Schouten, Ch. Matek, L. F. P. Jacobs [et al.] // *Scientific Reports*. – 2021. – Vol. 11, No. 1. – P. 7995. – DOI 10.1038/s41598-021-86995-5. – EDN BVYBMQ.
6. Topol, E. J. High-performance medicine: the convergence of human and artificial intelligence / E. J. Topol // *Nature Medicine*. – 2019. – Vol. 25, No. 1. – P. 44-56. – DOI 10.1038/s41591-018-0300-7. – EDN OQSRZW.
7. Алимбаев, А. А. Методика оценки социальной и экономической эффективности цифровизации системы здравоохранения / А. А. Алимбаев, Б. С. Битенова, Т. И. Есенбекова // *Экономика: стратегия и практика*. – 2020. – Т. 15, № 3. – С. 25-37. – EDN DRBYWS.
8. Городнова, Н. В. Повышение качества жизни граждан России в процессе реализации инновационных проектов / Н. В. Городнова, Н. А. Самарская // *Вопросы инновационной*

экономики. – 2019. – Т. 9, № 3. – С. 721-734. – DOI 10.18334/vines.9.3.40917. – EDN IACEXD.

9. Применение алгоритмов машинного обучения для разработки модели прогнозирования результатов выживаемости больных раком легких в РК / В. А. Макаров, Д. Р. Кайдарова, С. Е. Есентаева [и др.] // Онкология и радиология Казахстана. – 2022. – № 3(65). – С. 4-11. – DOI 10.52532/2521-6414-2022-3-65-4-11. – EDN VSAJZG.

10. Рябова, Т. Ф. Качество жизни населения России: состояние, проблемы, перспективы / Т. Ф. Рябова, Н. М. Сурай // Экономика. Профессия. Бизнес. – 2022. – № 2. – С. 98-106. – DOI 10.14258/epb202227. – EDN JRMJK.

Сведения об авторах

Минкин Александр Владимирович, канд. физ.-мат. наук, доцент, доцент кафедры математики и прикладной информатики, ФГАОУ ВО «Казанский (Приволжский) федеральный университет», Елабужский институт, г. Елабуга, Россия.

Мифтахова Айгуль Рустамовна, студентка 5 курса Высшей школы инженерных и общественных наук, ФГАОУ ВО «Казанский (Приволжский) федеральный университет», Елабужский институт, г. Елабуга, Россия

Information about the authors

Minkin Alexander Vladimirovich, PhD in Physics and Mathematics, Associate Professor, Associate Professor of the Department of Mathematics and Applied Computer Science, Kazan (Volga Region) Federal University, Yelabuga Institute, Yelabuga, Russia.

Miftakhova Aigul Rustamovna, 5th year student of the Higher School of Engineering and Social Sciences, Kazan (Volga Region) Federal University, Yelabuga Institute, Yelabuga, Russia.