

В. В. Афанасьев¹, М. Ю. Ревтович¹, О. Б. Зельманский²

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ДИАГНОСТИКИ НОВООБРАЗОВАНИЙ КОЖИ

УО «Белорусский государственный медицинский университет»,
Минск, Республика Беларусь,¹

УО «Белорусский государственный университет информатики
и радиоэлектроники», г. Минск, Республика Беларусь²

Увеличение количества случаев опухолей кожи и субъективность визуального осмотра и дерматоскопии обуславливают необходимость применения технологий машинного обучения с целью внедрения массового скрининга на первичном врачебном звене для данной нозологической группы. В статье проведён обзор используемых и перспективных технологий искусственного интеллекта для диагностики новообразований кожи, а также отражены проблемы их применения.

Ключевые слова: рак кожи, меланома, искусственный интеллект, сверточные нейронные сети.

V. V. Afanasyev¹, M. Y. Reutovich¹, O. B. Zelmansky²

THE USE OF ARTIFICIAL INTELLIGENCE IN THE DIAGNOSIS OF SKIN NEOPLASMS

Belarusian State Medical University, Minsk, Republic of Belarus,¹

Belarusian State University of Informatics and Radioelectronics,
Minsk, Republic of Belarus²

An increase in the incidence of skin tumors and the subjectivity of visual examination and dermoscopy necessitate the application of machine learning technologies to introduce mass screening for this disease group in primary medical care. The article reviews current and promising artificial intelligence technologies for the diagnosis of skin neoplasms and highlights the challenges of their application.

Key words: skin cancer, melanoma, artificial intelligence, convolutional neural networks.

Заболееваемость злокачественными новообразованиями кожи демонстрирует устойчивую тенденцию к росту во всем мире, что обусловлено как улучшением диагностики, так и реальным увеличением числа случаев. Согласно данным Всемирной организации здравоохранения, меланома кожи занимает одно из лидирующих мест среди онкологических заболеваний по темпам прироста, при этом пятилетняя выживаемость при раннем выявлении превышает 95 %, тогда как на поздних стадиях этот показатель драматически снижается. Традиционные методы диагностики, такие как дерматоскопия и последующая гистологическая верификация, остаются «золотым стандартом», однако они субъективны и критически зависят от квалификации врача, что создает объективную потребность в автоматизированных, воспроизводимых и высокочувствительных решениях.

Технологии искусственного интеллекта (ИИ), прежде всего сверточные нейронные сети и трансформеры, демонстрируют впечатляющие результаты в задачах классификации и сегментации дерматоскопических изображений, достигая значений AUC (площади под ROC-кривой)

свыше 90 %. Тем не менее, путь от экспериментальных разработок к клинической практике осложнен рядом системных проблем: дефицитом стандартизированных и репрезентативных наборов данных, непрозрачностью принятия решений моделями (феномен «черного ящика»), отсутствием унифицированных протоколов валидации и нерешенными регуляторными барьерами. Эти ограничения напрямую препятствуют интеграции ИИ в повседневную работу дерматолога и онколога, несмотря на очевидный потенциал технологий в снижении диагностических ошибок и оптимизации скрининга. Более того, перекося классов в обучающих выборках и низкая обобщаемость моделей на популяции с различными фототипами кожи ставят под сомнение универсальность полученных метрик точности. Таким образом, возникает острая необходимость в систематизации существующих данных, чтобы отделить реальный прогресс от временных успехов на небольших выборках пациентов.

Цель настоящего литературного обзора – провести систематический анализ современных методов ИИ для диагностики злокачественных новообразований кожи.

Современные ИИ-модели диагностики

1.1. Эволюция подходов к диагностике рака кожи: от традиционных методов к ИИ

Традиционные методы диагностики злокачественных новообразований кожи, включающие дерматоскопию и гистологическое исследование, на протяжении десятилетий оставались «золотым стандартом» клинической практики. Однако данные подходы в значительной степени зависят от субъективного опыта и квалификации врача, что неизбежно приводит к вариативности интерпретации результатов. Даже при соблюдении стандартизированных протоколов дерматоскопического осмотра, согласованность заключений между разными специалистами может быть недостаточно высокой, особенно в сложных для интерпретации случаях. Подобная неоднозначность создает риски как гипердиагностики, так и, наоборот, гиподиагностики ранних стадий злокачественных новообразований кожи.

Первым шагом на пути к автоматизации диагностики стало внедрение систем компьютерного зрения и классических алгоритмов машинного обучения, которые позволили формализовать первичный анализ дерматоскопических изображений. В отличие от человека, такие системы лишены утомляемости и индивидуальных особенностей восприятия, что обеспечивает единообразие обработки визуальных данных. Тем не менее, эффективность ранних алгоритмов была ограничена их способностью извлекать лишь заранее заданные признаки, такие как асимметрия, границы, цвет и диаметр (ABCD-правило), что не всегда отражало всю сложность морфологии опухоли. Несмотря на повышение воспроизводимости результатов, по точности классификации они зачастую уступали опытным дерматологам, что замедляло их широкое внедрение в клиническую практику.

Качественный скачок в диагностике новообразований кожи произошел с переходом к методам глубинного обучения, в частности, к сверточным нейронным сетям (CNN), которые способны самостоятельно выявлять иерархические паттерны на изображениях. Как отмечается в литературе, «в последнее десятилетие произошел значительный прогресс в сфере компьютерного анализа изображений и их распознавания, причем современные алгоритмы компьютерной диагностики не только догоняют, но и во многих аспектах превосходят человеческие способности. В основе этого прогресса лежит развитие глубоких сверточных нейронных сетей, которые дали новый импульс медицинской диагностике, в частности, онкологических заболеваний кожи» [1]. Данная архитектура позволила анализировать изображение целостно, без необходимости ручного выделения диагностических признаков, что кардинально повысило чувствительность и специфичность выявления злокачественных новообразований кожи. Сравнение с классическими алгоритмами машинного обучения демонстрирует значительное превосходство CNN в задачах дерматоскопической классификации, что подтверждается многочисленными исследованиями [2–6]. Глубокие нейронные сети способны улавливать тонкие текстурные и цветовые нюансы, недоступные для традиционных методов обработки изображений, так называемые вариации пигментной сети (например, атипичная или иррегулярная пигментная сеть, лучистые полосы (radial

streaming), псевдоподии (pseudopods) и т. д.). Благодаря обучению на тысячах размеченных изображений, CNN достигают показателей точности, сопоставимых или превышающих результаты сертифицированных дерматологов, особенно в задачах бинарной классификации («доброкачественное – злокачественное»). Таким образом, внедрение глубинного обучения ознаменовало переход от вспомогательных инструментов к полноценным системам поддержки принятия врачебных решений.

1.2. Сверточные нейронные сети (CNN) в дерматоскопическом анализе: архитектуры и особенности применения

Сверточные нейронные сети (CNN) стали основой многих современных систем анализа дерматоскопических изображений благодаря способности автоматически выделять иерархические признаки, начиная от простых текстур и границ до сложных морфологических паттернов, характерных для злокачественных новообразований кожи. Среди наиболее часто адаптируемых архитектур для данной задачи выделяются ResNet, Inception и EfficientNet, каждая из которых предлагает уникальные механизмы для повышения эффективности обучения при ограниченном размере медицинских наборов данных. В частности, архитектура Inception.v3, как отмечается в исследованиях, использует технику пакетной нормализации (Batch normalization), которая «позволяет существенно ускорить процесс обучения нейронной сети за счет использования более высокого значения параметра скорости обучения (learning rate), а также снизить переобучение» [7]. Такие архитектурные решения критически важны для задач дерматоскопии, где вариативность изображений и риск переобучения на специфических признаках особенно высоки. Применение предобученных моделей, таких как EfficientNet, позволяет достичь высокой точности классификации даже при относительно небольшом количестве дерматоскопических снимков, что является частым ограничением в клинической практике. Глубокие архитектуры, подобные ResNet, используют остаточные связи (skip connections), которые облегчают градиентный поток и позволяют обучать сети с сотнями слоев, необходимых для захвата тонких отличий между доброкачественными и злокачественными поражениями. Адаптация этих архитектур под специфику дерматоскопии часто включает модификацию последних слоев классификатора и тонкую настройку (fine-tuning) значимых параметров на специализированных базах данных, что обеспечивает баланс между глубиной модели и ее способностью к генерализации на новых данных.

Особенностью применения CNN в дерматоскопии является обязательная предварительная обработка изображений, направленная на минимизацию влияния внешних факторов, таких как неравномерность освещения, наличие волос или артефактов, а также различие в разрешении снимков. Этап нормализации, включающий масштабирование интенсивности пикселей и центрирование данных, обеспечивает стабильность градиентов в процессе обучения и сокращает время сходимости сети. Критическую роль играет аугментация данных – методы искусственного расширения обучающей выборки путем случайных геометрических и цветовых преобразований (повороты, отражения, измене-

ние яркости), что напрямую борется с несбалансированностью классов, поскольку случаи злокачественных новообразований в большинстве использованных к настоящему времени для создания CNN баз данных часто представлены гораздо реже в сравнении с другой патологией, в том числе доброкачественными новообразованиями кожи.

Для повышения доверия к результатам CNN и понимания их диагностической логики используются методы интерпретации, среди которых наибольшее распространение получили карты активации, в частности метод Grad-CAM (Gradient-weighted Class Activation Mapping) или метод объяснимого искусственного интеллекта (XAI) [6]. Данный подход позволяет визуализировать области исходного дерматоскопического изображения, которые оказали наибольшее влияние на итоговое решение сети (например, зона пигментной сети или атипичные сосуды). Это превращает «черный ящик» нейронной сети в инструмент, способный подтвердить или поставить под сомнение собственное заключение, что особенно важно для клинической верификации диагноза и обучения врачей работе с ИИ-ассистентами.

1.3. Применение трансформеров и других передовых архитектур для анализа медицинских изображений

В отличие от сверточных нейронных сетей, ориентированных на локальные паттерны, архитектуры на основе трансформеров, в частности Vision Transformer (ViT), способны моделировать глобальные контекстные зависимости в изображении. Данный подход позволяет учитывать взаимосвязи между удаленными участками дерматоскопического снимка, что принципиально расширяет аналитические возможности модели. Благодаря механизму самовнимания трансформеры могут выделять семантически значимые области без жестких ограничений рецептивного поля. Потенциальное превосходство трансформеров над CNN заключается в более полном учете пространственной структуры новообразования и его окружения. Исследования показывают, что ViT способны достигать сопоставимой или более высокой точности классификации при достаточном объеме обучающих данных. Тем не менее, применение трансформеров в медицинской визуализации сопряжено с высокими вычислительными затратами и требует больших размеченных наборов данных.

Гибридные модели, сочетающие CNN и трансформеры, демонстрируют синергетический эффект, объединяя преимущества локального анализа признаков и глобального контекста для повышения точности диагностики. В таких архитектурах сверточные блоки отвечают за извлечение низкоуровневых текстурных и цветовых характеристик, а трансформеры обрабатывают полученные карты признаков для выявления долгосрочных зависимостей. Подобная комбинация позволяет компенсировать недостатки каждого подхода в отдельности и улучшает обобщающую способность модели на различных дерматоскопических наборах данных.

Перспективными направлениями являются использование генеративно-сопоставительных сетей (GAN) для синтеза обучающих данных и применение методов обучения с подкреплением для оптимизации диагностических стратегий.

Оценка эффективности и ограничения

2.1. Ключевые метрики оценки:

чувствительность, специфичность, AUC и их интерпретация в контексте диагностики злокачественных новообразований кожи

Оценка диагностической эффективности моделей искусственного интеллекта, применяемых в дерматоскопии, традиционно базируется на оценке чувствительности (sensitivity) и специфичности (specificity). Чувствительность отражает долю истинно положительных случаев, то есть способность модели правильно идентифицировать злокачественные новообразования среди всех пациентов с подтвержденным диагнозом. В контексте диагностики злокачественных новообразований кожи приоритетное значение имеет именно высокая чувствительность, поскольку гиподиагностика может иметь своим следствием неблагоприятные последствия для пациента. Специфичность, в свою очередь, характеризует долю истинно отрицательных результатов, то есть способность модели корректно исключать доброкачественные образования. Низкая специфичность ведет к увеличению числа ложноположительных заключений, что на практике оборачивается неоправданными биопсиями, дополнительными обследованиями и психологическим стрессом для пациентов. Оптимальный баланс между чувствительностью и специфичностью достигается путем выбора порога классификации, причем для задач скрининга часто сознательно жертвуют специфичностью в пользу максимальной чувствительности.

Интегральной метрикой, обобщающей дискриминационную способность модели при всех возможных порогах, является площадь под ROC-кривой (AUC). Значение AUC, близкое к 1,0, свидетельствует о высокой разделительной силе модели, однако его интерпретация в контексте рака кожи требует осторожности. Распространенность (prevalence) злокачественных новообразований в популяции, проходящей скрининг, как правило, невелика, и высокая AUC может достигаться за счет хорошей классификации доброкачественных случаев, тогда как чувствительность на клинически релевантном пороге может оказаться недостаточной. Клинические последствия ошибок первого рода (ложноположительных) и второго рода (ложноотрицательных) принципиально различны: гиподиагностика злокачественного новообразования (ошибка второго рода) несет непосредственную угрозу жизни, в то время как гипердиагностика ведет к избыточным инвазивным процедурам. Поэтому при оценке ИИ-моделей для диагностики рака кожи недостаточно опираться исключительно на AUC; необходимо анализировать полный набор метрик, включая положительную прогностическую ценность (PPV) и отрицательную прогностическую ценность (NPV), которые напрямую зависят от распространенности заболевания в конкретной популяции.

2.2. Проблема качества и репрезентативности данных: влияние на обобщающую способность моделей

Одним из наиболее критических аспектов, определяющих надежность ИИ-моделей в дерматоонкологии, является несбалансированность обучающих наборов данных. В большинстве открытых дерматоскопических баз, таких как HAM10000 или ISIC Archive, количество

изображений доброкачественных невусов значительно превосходит число образцов меланомы. Как отмечают исследователи, «модели, обученные на несбалансированных данных, демонстрируют высокую специфичность за счет склонности классифицировать большинство образований как доброкачественные, что приводит к низкой чувствительности и, как следствие, гиподиагностике злокачественных новообразований» [8]. Такое смещение является неприемлемым для онкологической диагностики, где приоритетной задачей является максимальное выявление всех случаев злокачественных новообразований кожи, даже ценой увеличения числа ложноположительных результатов, требующих дополнительного обследования.

Помимо количественного дисбаланса классов, ключевое значение для обобщающей способности моделей имеет репрезентативность данных по демографическим параметрам, включая фототип кожи, возраст и этническую принадлежность. Большинство существующих баз данных, используемых для обучения ИИ, собраны в клиниках Европы, США и Австралии, где преобладающим является население со светлыми фототипами кожи (I–III по классификации Фицпатрика). В результате модели демонстрируют значительно более высокую точность на светлой коже, тогда как для диагностики новообразований на коже с высоким содержанием меланина (фототипы IV–VI) их эффективность резко снижается. Исследования показывают, что «низкая пропорция фототипов IV–VI в обучающих выборках приводит к систематическим ошибкам и снижению чувствительности у темнокожих пациентов, что является серьезным этическим и клиническим ограничением» [9].

Для преодоления проблемы дисбаланса и недостаточной репрезентативности данных исследователи активно применяют методы аугментации, включая геометрические преобразования, изменения цветовой гаммы и вариации контрастности. Более сложным подходом является использование генеративно-состязательных сетей (GAN) для синтеза изображений редких классов, таких как акральная лентигинозная меланома, которая характерна для темнокожих пациентов. Эти методы позволяют частично сбалансировать наборы данных и повысить устойчивость модели к вариациям, однако, как отмечается в литературе, «синтетические изображения, хотя и расширяют обучающую выборку, не могут полностью воспроизвести спектр реальных клинических вариаций и текстурных особенностей, характерных для различных этнических групп» [10]. Ограниченность аугментации и синтеза данных приводит к тому, что модели, обученные на таких скорректированных базах данных, часто демонстрируют хорошие результаты на внутренних тестовых выборках, но показывают резкое падение производительности при применении в реальных клинических условиях с иным распределением признаков. Проблема «domain shift» (смещения предметной области) остается нерешенной: модель, обученная на изображениях из одного дерматоскопа или одной популяции, может быть неэффективна при использовании с другим оборудованием или в регионе с другим этническим составом. Это ограничивает глобальную применимость ИИ-диагностики рака кожи, делая невозможным создание универсальной модели без целенаправленного сбора репрезентативных многонациональных баз данных, включающих все разнообразие дерматоскопических проявлений заболеваний.

2.3. Опыт внедрения ИИ-систем в дерматологическую практику

В ряде российских медицинских центров были инициализированы пилотные проекты по интеграции нейросетевых алгоритмов в программы скрининга новообразований кожи [2]. В частности, в Российской Федерации предложено мобильное приложение «Про родинки» (свидетельство о регистрации программы RU 2020664964, заявл. 10.11.2020, опублик. 19.11.2020). Эти системы, основанные на сверточных нейронных сетях, прошли апробацию на дерматоскопических изображениях, полученных в условиях реальной клинической практики. Полученные результаты продемонстрировали, что чувствительность нейросетевых алгоритмов при анализе дерматоскопических изображений оказалась сопоставимой с аналогичными показателями, полученными при стандартном подходе к диагностике злокачественных новообразований кожи врачами-дерматологами экспертного класса.

Ретроспективные исследования, проведенные на крупных зарубежных базах данных, таких как ISIC и HAM10000, продемонстрировали высокую эффективность сверточных нейронных сетей (CNN) в задаче классификации злокачественных и доброкачественных поражений кожи. В этих работах модели достигали AUC (площади под ROC-кривой) более 0,9, что указывает на их отличную дискриминационную способность. Данные показатели сопоставимы с результатами, полученными экспертами-дерматологами при аналогичных условиях. Подобные результаты подтверждают потенциал глубокого обучения как инструмента скрининга. В частности, одна из бинарных моделей, обученная на этих наборах данных, показала точность 93 % и AUC выше 0,95, что свидетельствует о высокой надежности классификации. Однако исследователи отметили, что «самые большие трудности возникали при оценке различий между здоровой кожей и умеренно пораженной. Порядка 20 % умеренно выраженных изменений кожи были признаны как островоспалительные, в то время как в 5 % случаев здоровая кожа ошибочно была расценена как кожа с поражениями умеренной тяжести» [11].

Управление по санитарному надзору за качеством пищевых продуктов и медикаментов США (FDA – Food and Drug Administration) одобрила к применению на территории США и Канады устройство DermaSensor (<https://www.dermasensor.com>) со встроенным приложением на основе технологии искусственного интеллекта, продемонстрировавшее достаточно высокую чувствительность (96,6 %) и специфичность варьирующую от 21 % до 76,9 % [12].

Такие данные свидетельствуют о потенциале использования ИИ-систем в качестве системы поддержки принятия врачебных решений, иными словами дополнительного инструмента для повышения эффективности скрининга.

Перспективы, регуляторные аспекты, собственные разработки

3.1. Направления развития: объяснимый ИИ, мультимодальный анализ и интеграция с медицинским оборудованием

Одной из центральных проблем, сдерживающих широкое внедрение систем искусственного интеллекта в клиническую практику, является феномен «черного ящика», когда внутренние механизмы принятия реше-

ний нейросетью остаются непрозрачными для пользователя. Это порождает обоснованное недоверие со стороны врачей, которые, принимая ответственные медицинские решения, нуждаются в понимании логики, приведшей к тому или иному диагностическому выводу. В связи с этим возникло и активно развивается направление объяснимого искусственного интеллекта (XAI, eXplainable Artificial Intelligence), ставящее своей целью создание моделей, способных предоставлять интерпретируемые обоснования своих прогнозов. Реализация принципов XAI является не только фактором повышения доверия к технологиям, но и ключевым требованием для соответствия будущим регуляторным нормам в сфере медицинского программного обеспечения. Разработка методов объяснимого ИИ предполагает создание как моделей, изначально построенных на интерпретируемых алгоритмах, так и пост-хок методов, позволяющих визуализировать и анализировать решения уже обученных глубоких нейронных сетей. Например, использование карт активации (Grad-CAM) или методов анализа важности признаков (SHAP, LIME) позволяет выделить на дерматоскопическом изображении области, которые модель сочла наиболее значимыми для постановки диагноза. Такие инструменты дают врачу возможность сверить свои клинические наблюдения с «вниманием» алгоритма, что способствует формированию конструктивного диалога между человеком и ИИ. Как отмечается в одном из исследований, дальнейшие усилия авторов будут направлены, в частности, на «улучшение архитектуры глубоких нейронных сетей для повышения точности», что можно рассматривать в контексте разработки более интерпретируемых и эффективных моделей [8].

Следующим перспективным направлением, способным кардинально повысить диагностическую ценность ИИ-систем, является мультимодальный анализ, под которым понимается интеграция и совместная обработка данных, поступающих из различных источников. В контексте диагностики злокачественных новообразований кожи это предполагает объединение дерматоскопических изображений с клиническими данными (история болезни, жалобы, результаты пальпации), гистологическими заключениями, а в перспективе – и с геномными профилями опухолей. Такой подход позволяет модели формировать более полное и контекстуально обогащенное представление о состоянии пациента, что напрямую влияет на повышение точности, чувствительности и специфичности диагностики, особенно в сложных и неоднозначных случаях.

Важнейшим вектором развития является интеграция обученных ИИ-алгоритмов непосредственно в портативные диагностические устройства, что открывает возможности для массового скрининга и развития телемедицины. Размещение нейросетей в компактных дерматоскопах или в виде приложений для смартфонов позволяет вывести первичную диагностику за пределы специализированных клиник, делая её доступной в удаленных регионах или при самодиагностике. Как подчеркивается в литературе, разработчики ставят перед собой задачу «сделать эту модель доступной и пригодной для использования в виде приложения для мобильных устройств в автоматизированных диагностических системах телемедицины». Такая интеграция, однако, требует решения ряда сопутствующих проблем, включая стандартизацию качества получаемых изображений, обеспечение безопасности передачи данных и проведение тщательной клинической валидации на реальных популяциях.

3.2. Регуляторные барьеры и этические вопросы: стандартизация, валидация и безопасность применения ИИ в медицине

Несмотря на значительный прогресс в разработке и тестировании алгоритмов искусственного интеллекта для диагностики злокачественных новообразований кожи, их интеграция в рутинную клиническую практику сдерживается отсутствием унифицированных стандартов клинической валидации. Разрозненность требований со стороны ключевых мировых регуляторов, таких как Управление по контролю качества пищевых продуктов и лекарственных средств США (FDA) и Европейская система маркировки CE, создает существенные барьеры для выхода продуктов на рынок. Производители вынуждены адаптировать свои решения под различные, порой противоречивые, нормативные рамки, что замедляет инновации и увеличивает стоимость разработки. Как отмечается в литературе, «отсутствие стандартизации метрик оценки и протоколов испытаний препятствует объективному сравнению алгоритмов и их воспроизводимости в различных клинических условиях» [13, 14]. Формирование единых международных подходов к валидации могло бы не только ускорить процесс сертификации, но и повысить доверие врачебного сообщества к технологиям ИИ. Эффективным решением представляется проведение многоцентровых проспективных клинических исследований, результаты которых позволят объективно оценить работу алгоритмов поддержки принятия врачебных решений в условиях максимально приближенных к реальной клинической практике, а не только на ретроспективных наборах данных. Только через создание прозрачной и гармонизированной системы стандартов можно гарантировать безопасность и эффективность ИИ-систем до их широкого применения.

Помимо нормативных препятствий, на пути внедрения ИИ в дерматологию и онкодерматологию стоят серьезные этические риски, требующие пристального внимания. Одной из ключевых проблем является смещение (bias) в обучающих выборках: если данные для тренировки модели собраны преимущественно от пациентов одной демографической группы или с использованием только определенных типов дерматоскопов, алгоритм может демонстрировать низкую точность на других популяциях. Это напрямую угрожает равноправию пациентов в доступе к качественной диагностике. Не менее важен вопрос соблюдения конфиденциальности медицинских данных, используемых для обучения и работы ИИ, а также сохранения конечной ответственности за поставленный диагноз за врачом. Как подчеркивается в этических директивах, «алгоритмы должны выступать инструментом поддержки принятия решений, а не заменой клиническому суждению специалиста».

3.3. Собственная разработка – программно-аппаратный комплекс диагностики новообразований кожи

С целью повышения точности дооперационной диагностики злокачественных новообразований кожи путем разработки и применения системы поддержки принятия врачебных решений на основе технологии искусственного интеллекта разработан аппаратно-программный комплекс, состоящий из пользовательской и серверной частей. Пользовательская часть представляет собой веб-приложение с доступными версиями на 32 и 64 битные

системы ОС Windows. Также была создана мобильная версия на платформе Dart (кроссплатформенная программная среда Flutter, библиотека Foundation). Разработанное программное обеспечение может быть установлено на любое из мобильных устройств благодаря использованию упомянутой выше кроссплатформенной программной среды Flutter с языком программирования Dart без задействования нативных компонентов с прямой отрисовкой интерфейса, что уменьшает размер приложения, а также в совокупности с декларативным подходом способствует увеличению скорости работы UI приложения.

Программное обеспечение работает с подавляющим большинством версий систем: стабильная работа может быть обеспечена при версии Android 5.0–5.0.2 (Lollipop) Версия API/SDK 21 и выше; версии iPhone не менее 15.8.8 сборка 19H422 и модели не ниже iPhone SE, iPhone 6S, iPhone 6S Plus, iPhone 7, iPhone 7 Plus, iPad Air 2, iPad mini 4, iPod touch (7 поколения); ОС Windows не ниже 10. Возможности серверной части позволяют обрабатывать и нормализовывать фотографии сделанные на камеры мобильных устройств с разрешением 3 МП и выше.

Изложенное выше создаёт предпосылки для обеспечения широкого применения программного комплекса в условиях практического здравоохранения, что позволит повысить эффективность своевременной диагностики злокачественных новообразований кожи за счёт повышения точности диагностики и снижения числа ложноотрицательных случаев диагностики злокачественных новообразований кожи врачами общей лечебной сети и врачами-онкологами амбулаторного звена.

Проведенный обзор подтверждает, что современные технологии искусственного интеллекта, в особенности сверточные нейронные сети, демонстрируют высокую диагностическую точность (AUC более 90 % на стандартизированных наборах данных), что сопоставимо с квалифицированными дерматологами. Однако данная эффективность достигается в контролируемых условиях и не гарантирует воспроизводимости в гетерогенной клинической практике. Это ставит под сомнение возможность прямого переноса результатов, полученных в одноцентровых исследованиях на ограниченных по численности когортах пациентов, в повседневную медицинскую деятельность.

Ключевыми ограничениями, препятствующими широкому клиническому внедрению ИИ, являются дефицит стандартизированных и сбалансированных наборов данных. Низкая интерпретируемость моделей, известная как феномен «черного ящика», также вызывает обеспокоенность. Отсутствие унифицированных протоколов валидации дополнительно снижает доверие врачей и регуляторов.

Анализ литературы показывает успешную интеграцию ИИ-систем в клиническую практику. Они используются как вспомогательный инструмент скрининга, повышая выявляемость злокачественных новообразований на ранних стадиях. Однако такие системы требуют адаптации к локальным популяциям и используемому оборудованию.

Перспективными направлениями для преодоления существующих барьеров являются развитие объяснимого ИИ и создание многоцентровых валидационных исследований. Кроме того, необходима разработка еди-

ных регуляторных и этических стандартов. Это позволит безопасно и эффективно внедрять ИИ-технологии в повседневную дерматологическую практику.

Авторы заявляют об отсутствии конфликта интересов.

Литература

1. Самохин, С. О. Ранняя диагностика злокачественных новообразований кожи с помощью технологий искусственного интеллекта / С. О. Самохин, А. В. Патрушев, Ю. И. Акаева [и др.] // Вестн. дерматол. венерол. – 2024. – № 1. – С. 38–46.
2. Ускова, К. А. Искусственный интеллект как инструмент популяционного скрининга опухолей кожи / К. А. Ускова, О. Е. Гаранина, А. О. Ухаров [и др.] // Эффективная фармакотерапия. – 2024. – Т. 20, № 1. – С. 62–71.
3. Escalé-Besa, A. Using artificial intelligence as a diagnostic decision support tool in skin disease: protocol for an observational prospective cohort study / A. Escalé-Besa, A. Fuster-Casanovas, A. Börve, O. Yélamos // JMIR Res. Protoc. – 2022. – Vol. 11, № 8. – Art. e3753.
4. Jones, O. T. Artificial intelligence and machine learning algorithms for early detection of skin cancer in community and primary care settings: a systematic review / O. T. Jones, R. N. Matin, M. van der Schaar, K. Prathivadi Bhayankaram // Lancet Digit. Health. – 2022. – Vol. 4, № 6. – P. e466–e476.
5. Yap, J., Yolland W., Tschandl P. Multimodal skin lesion classification using deep learning / J. Yap, W. Yolland, P. Tschandl // Exp. Dermatol. – 2018. – Vol. 27, № 11. – P. 1261–1267.
6. Fayyaz, A. M. Grad-CAM (Gradient-weighted Class Activation Mapping): A systematic literature review / A. M. Fayyaz, S. J. Abdulkadir, N. Talpur [et al.] // Comput. Biol. Med. – 2025. – Vol. 198(Pt B). – Art. 111200. – doi: 10.1016/j.combiomed.2025.111200.
7. Мелерзанов, А. Диагностика меланомы кожи с помощью сверточных нейронных сетей глубокого обучения / А. Мелерзанов, Д. Гаврилов // Врач. – 2018. – Т. 29, № 6. – С. 31–33. – <https://doi.org/10.29296/25877305-2018-06-06>.
8. Щетинин, Е. Ю. Классификация повреждений кожи по данным дермаскопии с использованием методов глубокого обучения / Е. Ю. Щетинин, Л. А. Севастьянов, А. В. Демидова [и др.] // Математическая биология и биоинформатика. – 2020. – № 2. – С. 180–194.
9. Wen, D. Characteristics of publicly available skin cancer image datasets: a systematic review / D. Wen, S. M. Khan [et al.] // Lancet Digital Health. – 2022. – Vol. 4, № 1. – P. e64–e74.
10. Reddy, N. N., Agarwal Reddy P. A Smart AI-Driven diagnostic framework for early detection of skin cancer using hybrid vision transformers and cloud-enabled mhealth integration / N. N. Reddy, P. Agarwal Reddy // ICCSIT '25: Proceedings of the 2025 18th International Conference on Computer Science and Information Technology. – New York: ACM, 2026. – P. 176–188. – doi: 10.1145/3783862.3783885.
11. Рукша, Т. Г. Применение технологий на основе искусственного интеллекта в дерматологии / Т. Г. Рукша, Е. З. Лапкина // Российский журнал кожных и венерических болезней. – 2025. – Т. 28, № 4. – С. 429–436. – doi: 10.17816/dv678577.
12. Venkatesh, K. P. Learnings from the first AI-enabled skin cancer device for primary care authorized by FDA / K. P. Venkatesh, K. T. Kadakia, S. Gilbert // NPJ Digit Med. – 2024. – Vol. 7, № 1. – Art. 156. – doi: 10.1038/s41746-024-01161-1.
13. Сиводедова, Н. А. Ранняя диагностика злокачественных новообразований кожи с использованием программного продукта на основе искусственного интеллекта и его медико-экономический эффект / Н. А. Сиводедова, Н. Н. Карякин, И. А. Шлико // Менеджер здравоохранения. – 2024. – № 6. – С. 108–118.
14. Сиводедова, Н. А. Современные методы выявления злокачественных новообразований кожи, включая использование мобильных приложений и искусственного интеллекта: обзор литературы / Н. А. Сиводедова, Н. Н. Карякин, И. А. Шлико // Оргздрав: новости, мнения, обучения. Вестник ВШОУЗ. – 2024. – Т. 10, № 2. – С. 78–93.

References

1. Samohin, S. O. Rannaya diagnostika zlokachestvennykh novoobrazovaniy kozhi s pomoshch'yu tekhnologiy iskusstvennogo intellekta [Early diagnosis of malignant skin neoplasms using artificial intelligence technologies] / S. O. Samohin, A. V. Patrushev, Yu. I. Akaeva [et al.] // *Vestn. dermatol. venerol.* – 2024. – № 1. – S. 38–46 [In Russian].
2. Uskova, K. A. Iskusstvennyy intellekt kak instrument populyacionnogo skrininga opuholej kozhi [Artificial intelligence as a tool for population-based skin cancer screening] / K. A. Uskova, O. E. Garanina, A. O. Uharov [et al.] // *Effektivnaya farmakoterapiya.* – 2024. – T. 20, № 1. – S. 62–71. [In Russian]
3. Escalé-Besa, A. Using artificial intelligence as a diagnostic decision support tool in skin disease: protocol for an observational prospective cohort study / A. Escalé-Besa, A. Fuster-Casanovas, A. Börve, O. Yélamos // *JMIR Res. Protoc.* – 2022. – Vol. 11, № 8. – Art. e3753.
4. Jones, O. T. Artificial intelligence and machine learning algorithms for early detection of skin cancer in community and primary care settings: a systematic review / O. T. Jones, R. N. Matin, M. van der Schaar, K. Prathivadi Bhayankaram // *Lancet Digit. Health.* – 2022. – Vol. 4, № 6. – P. e466–e476.
5. Yap, J. Multimodal skin lesion classification using deep learning / J. Yap, W. Yolland, P. Tschandl // *Exp. Dermatol.* – 2018. – Vol. 27, № 11. – P. 1261–1267.
6. Fayyaz, A. M., Abdulkadir S. J., Talpur N., et al. Grad-CAM (Gradient-weighted Class Activation Mapping): A systematic literature review / A. M. Fayyaz, S. J. Abdulkadir, N. Talpur [et al.] // *Comput. Biol. Med.* – 2025. – Vol. 198(Pt B). – Art. 111200. – doi: 10.1016/j.compbiomed.2025.111200
7. Melerzanov, A. Diagnostika melanomy kozhi s pomoshch'yu svertochnykh nejronnykh setej glubokogo obucheniya [Diagnosis of cutaneous melanoma using deep learning convolutional neural networks] / A. Melerzanov, D. Gavrilov // *Vrach.* – 2018. – Vol. 29, № 6. – S. 31–33. – <https://doi.org/10.29296/25877305-2018-06-06> [In Russian].
8. Shchetinin, E. Yu. Klassifikatsiya povrezhdeniy kozhi po dannym dermaskopii s ispol'zovaniem metodov glubokogo obucheniya [Classification of skin lesions based on dermoscopy data using deep learning methods] / E. Yu. Shchetinin, L. A. Sevast'yanov, A. V. Demidova [et al.] // *Matematicheskaya biologiya i bioinformatika.* – 2020. – № 2. – S. 180–194 [In Russian].
9. Wen, D. Characteristics of publicly available skin cancer image datasets: a systematic review / D. Wen, S. M. Khan [et al.] // *Lancet Digital Health.* – 2022. – Vol. 4, № 1. – P. e64–e74.
10. Reddy, N. N. A Smart AI-Driven diagnostic framework for early detection of skin cancer using hybrid vision transformers and cloud-enabled mhealth integration / N. N. Reddy, P. Agarwal Reddy // *ICCSIT '25: Proceedings of the 2025 18th International Conference on Computer Science and Information Technology.* – New York: ACM, 2026. – P. 176–188. – doi: 10.1145/3783862.3783885.
11. Ruksha, T. G. Primenenie tekhnologiy na osnove iskusstvennogo intellekta v dermatologii [Application of artificial intelligence-based technologies in dermatology] / T. G. Ruksha, E. Z. Lapkina // *Rossiyskiy zhurnal kozhnykh i venericheskikh bolezney.* – 2025. – Vol. 28, № 4. – C. 429–436. – doi: 10.17816/dv678577 [In Russian].
12. Venkatesh, K. P. Learnings from the first AI-enabled skin cancer device for primary care authorized by FDA / K. P. Venkatesh, K. T. Kadakia, S. Gilbert // *NPJ Digit. Med.* – 2024. – Vol. 7, № 1. – Art. 156. – doi: 10.1038/s41746-024-01161-1.
13. Sivodedova, N. A. Rannaya diagnostika zlokachestvennykh novoobrazovaniy kozhi s ispol'zovaniem programmnogo produkta na osnove iskusstvennogo intellekta i ego mediko-ekonomicheskij effekt [Early diagnosis of malignant skin neoplasms using an artificial intelligence-based software product and its medical-economic impact] / N. A. Sivodedova, N. N. Karyakin, I. L. Shlivko // *Menedzher zdavoohraneniya.* – 2024. – № 6. – S. 108–118 [In Russian].
14. Sivodedova, N. A. Sovremennyye metody vyyavleniya zlokachestvennykh novoobrazovaniy kozhi, vkluyuchaya ispol'zovanie mobil'nykh prilozhenij i iskusstvennogo intellekta: obzor literatury [Modern methods for detecting malignant skin neoplasms, including the use of mobile applications and artificial intelligence: a literature review] / N. A. Sivodedova, N. N. Karyakin, I. L. Shlivko // *Orgzdrav: novosti, mneniya, obucheniya. Vestnik VSHOUZ.* – 2024. – T. 10, № 2. – S. 78–93 [In Russian].

Поступила 26.06.2026 г.