

КОЗАЧОК Е.С.,

ФГБУН ИСП РАН, г. Москва, Россия; e-mail: e.kozachok@ispras.ru

СЕРЕГИН С.С.,

к.м.н., БУЗ ОО Орловский онкологический диспансер, г. Орел, Россия;
e-mail: serega_s2004@mail.ru

КОЗАЧОК А.В.,

д.т.н., доцент, ФГБУН ИСП РАН, г. Москва, Россия; e-mail: a.kozachok@ispras.ru

ЕЛЕЦКИЙ К.В.,

к.т.н., доцент, ФГБУН ИСП РАН, г. Москва, Россия; e-mail: k.eletskiy@ispras.ru

САМОВАРОВ О.И.,

к.т.н., ФГБУН ИСП РАН, г. Москва, Россия; e-mail: samov@ispras.ru

МЕТОДИКА СКРИНИНГОВОГО ОБСЛЕДОВАНИЯ ДЛЯ РАННЕЙ ДИФФЕРЕНЦИАЛЬНОЙ ДИАГНОСТИКИ НОВООБРАЗОВАНИЙ КОЖИ С ИСПОЛЬЗОВАНИЕМ МОБИЛЬНОЙ ДЕРМАТОСКОПИИ

DOI: 10.25881/18110193_2025_3_50

Аннотация. Цель исследования: разработка методики скринингового обследования пациентов, направленной на раннюю дифференциальную диагностику злокачественных новообразований кожи посредством применения методов дерматоскопии совместно с оптоэлектронными средствами мобильной техники и алгоритмами классификации дерматоскопических изображений, основанных на методах машинного обучения.

Материалы и методы. Для реализации обнаружения злокачественных новообразований и отнесения их к соответствующей нозологической группе применяются методы и алгоритмы машинного обучения и оптического распознавания. Методы оптического распознавания используются в процессе анализа дерматоскопических снимков и обучения алгоритмов и моделей классификации. В качестве применяемых подходов машинного обучения выступают методы многоклассовой и бинарной каскадной двухэтапной классификации технологии машинного обучения, основанной на нейросетевой архитектуре и архитектуре визуальных трансформеров.

Результаты. В ходе экспериментальных оценок многоклассовой классификации (восемь типов злокачественных новообразований) определена наилучшая модель классификации с архитектурой визуального трансформера, характеризующего метриками Ассигасу 0,932 и F-мера 0,891 на сформированном наборе данных, включая ISIC-2019 и собственный набор, содержащий 657 изображений. Бинарная каскадная двухэтапная классификация на меланоцитарные и немеланоцитарные новообразования имеет значения Ассигасу и F-мера 0,954 и 0,948 (первый этап классификации) и на меланомы и невусы — 0,964 и 0,951 соответственно (второй этап классификации).

Заключение. Полученные количественные значения точности обнаружения злокачественных кожных новообразований разработанной методикой скринингового обследования позволяют рекомендовать внедрение многоклассовой классификации для первичного разделения большого объема дерматоскопических изображений пациентов по нозологическому признаку между профильными специалистами в процессе проведения массовый (выездных) профилактических осмотров, а внедрение каскадной бинарной классификации в условиях первичного приема с ограниченным доступом к профильным специалистам для дифференциации меланомы от других кожных новообразований. Разработанная методика скринингового обследования пациентов может быть внедрена в медицинскую практику в качестве системы поддержки принятия решений врача.

Ключевые слова: злокачественные новообразования кожи, диагностика, машинное обучение.

Для цитирования: Козачок Е.С., Серегин С.С., Козачок А.В., Елецкий К.В., Самоваров О.И. Методика скринингового обследования для ранней дифференциальной диагностики новообразований кожи с использованием мобильной дерматоскопии. *Врач и информационные технологии.* 2025; 3: 50-64. DOI: 10.25881/18110193_2025_3_50.

KOZACHOK E.S.,

FSBIS ISP RAS, Moscow, Russia; e-mail: e.kozachok@ispras.ru

SEREGIN S.S.,

PhD, BUZ Orlovskoi Oblasti OOD, Oryol, Russia;
e-mail: serega_s2004@mail.ru

KOZACHOK A.V.,

DSc, Associate Professor, FSBIS ISP RAS, Moscow, Russia; e-mail: a.kozachok@ispras.ru

ELECKIJ K.V.,

PhD, Associate Professor, FSBIS ISP RAS, Moscow, Russia; e-mail: k.eletskiy@ispras.ru

SAMOVAROV O.I.,

PhD, FSBIS ISP RAS, Moscow, Russia; e-mail: samov@ispras.ru

SCREENING EXAMINATION METHOD FOR EARLY DIFFERENTIAL DIAGNOSIS OF SKIN NEOPLASMS USING MOBILE DERMATOSCOPY

DOI: 10.25881/18110193_2025_3_50

Abstract. *The aim of the study: development of a screening method for patients aimed at early differential diagnosis of malignant skin neoplasms using dermatoscopy in combination with optoelectronic mobile equipment and algorithms for classifying dermatoscopic images based on machine learning methods.*

Materials and methods. To implement the detection of malignant neoplasms and classify them into the appropriate nosological group, machine learning methods, algorithms and optical recognition are used. The latter is used in the process of forming dermatoscopic images and training classification algorithms and models. The machine learning approaches are multi-class and binary cascade two-stage classification methods by classification algorithms based on the visual transformer architecture and neural network architecture.

Results. During the experimental evaluation of the results of multi-class classification (eight types of malignant neoplasms), the best classification model with the visual transformer architecture was determined, characterized by the metrics Accuracy of 0.932 and F-measure of 0.891 on the formed dataset, including ISIC-2019 and our own set containing 657 images. The binary cascade two-stage classification for melanocytic and non-melanocytic neoplasms has Accuracy and F-measure values — of 0.954 and 0.948 (the first stage of classification) and for melanomas and nevi — 0.964 and 0.951, respectively (the second stage of classification).

Conclusion. The obtained quantitative values of the malignant skin neoplasms detection accuracy by the developed screening examination method allow us to recommend the introduction of a multi-class classification for the primary division of a large volume of dermatoscopic images patients by nosological sign between medical specialists in the process of conducting mass (visiting) preventive examinations, and the introduction of a cascade binary classification in the an initial appointment conditions with limited access to specialized specialists to differentiate melanoma from other skin neoplasms. The developed screening examination method for patients can be introduced into medical practice as a system for supporting physician decision-making.

Keywords: malignant neoplasms of the skin, diagnostics, machine learning.

For citation: Kozachok E.S., Seregin S.S., Kozachok A.V., Eleckij K.V., Samovarov O.I. Screening examination method for early differential diagnosis of skin neoplasms using mobile dermatoscopy. *Medical doctor and information technology*. 2025; 3: 50-64. DOI: 10.25881/18110193_2025_3_50.

ВВЕДЕНИЕ

Злокачественные новообразования кожи представляют собой серьезную проблему для здравоохранения и являются одной из наиболее значимых причин смертности населения наряду с болезнями системы кровообращения во всем мире. По данным Московского научно-исследовательского онкологического института имени П.А. Герцена за последнее десятилетие наблюдается устойчивый рост числа новых случаев обнаружения злокачественных новообразований кожи [1]. Развитие средств ранней диагностики и лечения позволило снизить уровень смертности от злокачественных кожных новообразований почти на четверть (21%). При этом отдельные виды злокачественных новообразований кожи характеризуются высокой летальностью среди населения. Одними из таких кожных новообразований является меланома и рак кожи ввиду начального бессимптомного течения и быстрого прогрессирования, часто сопровождающиеся метастазированием, рецидивами и имеющие слабую ответную реакцию организма [2].

Согласно статистическим данным Международного агентства по исследованию рака за 2022 год в мире диагностировано 1566255 случаев выявления злокачественных новообразований кожи, включая немеланоцитарный рак и меланому кожи, из которых 28083 случаев приходится на показатель смертности [3]. Стоит отметить, что в Российской Федерации показатели заболеваемости злокачественными новообразованиями кожи населения характеризуются существенным ростом (порядка 34%) за период наблюдения с 2013 по 2023 годы. При этом врачами отмечается наличие положительной динамики лечения меланомы, выявленной на первой стадии, что требует совершенствования существующих и разработки новых методов ранней диагностики меланоцитарных новообразований кожи, в том числе меланом, на ранних стадиях течения болезни. Для решения проблемы по совершенствованию методов ранней диагностики злокачественных меланоцитарных новообразований кожи могут применяться скрининговые обследования кожных новообразований, основанные на мобильной дерматоскопии с использованием методов и алгоритмов машинного обучения. Скрининговые обследования кожных новообразований осуществляются посредством

разработанной методики, позволяющей снизить общую продолжительность обследования одного пациента и не требующей дополнительной аккредитации от врачей общей практики.

Применение скрининговых исследований, основанных на мобильной дерматоскопии с использованием методов и алгоритмов машинного обучения, может снизить продолжительность установления первичного диагноза ввиду того, что процесс диагностики традиционными методами включает в себя несколько длительных этапов продолжительностью от одного-двух дней (визуальный осмотр) до месяца (диагностические и гистологические исследования). Современные исследования [4–9] в области внедрения подходов мобильной дерматоскопии в методы телемедицины, в том числе применение дистанционных диагностических и терапевтических инструментов в медицинскую практику, позволяют повысить качество диагностики злокачественных новообразований кожи, включая меланоцитарные, до 95% при условии проведения осмотра врачом дерматологом или онкологом, и не более 70% в случае использования дерматоскопа врачами общей практики [10, 11].

МАТЕРИАЛЫ И МЕТОДЫ

Разработанная методика скринингового обследования для ранней дифференциальной диагностики злокачественных новообразований кожи основана на мобильной дерматоскопии и применении методов машинного обучения. Под мобильной дерматоскопией понимается применение оптического дерматоскопа в сочетании со смартфоном, обеспечивающим получение высококачественных дерматоскопических изображений с достаточной степенью детализации и освещенности, сопоставимой с визуализацией, доступной при стандартной дерматоскопии, осуществляемой врачом.

Для обеспечения достаточного качества визуализации при мобильной дерматоскопии рекомендуется использовать камеру смартфона с характеристиками, обеспечивающими четкое, резкое и равномерно освещенное изображение исследуемой области кожи. Практически достаточными считаются следующие параметры:

- разрешение камеры от 12 МП и выше;
- светосила объектива не ниже $f/2.0$;

– физический размер матрицы не менее 1/3.0 дюйма.

При этом ключевым критерием является качество сформированного изображения, сопоставимое по детализации с результатами, получаемыми при стандартной дерматоскопии. Допускается использование устройств с иными характеристиками, если они обеспечивают необходимую диагностическую информативность изображения при подключении к дерматоскопу.

В качестве используемых методов машинного обучения выступают алгоритмы многоклассовой и каскадной (двухэтапной) бинарной классификации дерматоскопических изображений кожных новообразований. Архитектура интеллектуальной системы скрининга кожных новообразований с использованием мобильной дерматоскопии, реализующей разработанную методику скринингового обследования для ранней дифференциальной диагностики злокачественных новообразований кожи, представлена на рисунке 1. Интеллектуальная система реализована как облачный веб-сервис,

включающий модуль приема изображений, предобработки, классификации на обученной модели, формирования отчета и API для интеграции в клинические информационные системы.

Разработанная методика включает следующие этапы:

1. Первичный осмотр пациента и выбор подозрительного кожного новообразования. Врач общей практики, фельдшер или иное уполномоченное медицинское лицо проводит визуальный осмотр пациента с целью выявления кожных образований, требующих обследования.

2. Получение дерматоскопического изображения с использованием средств мобильной дерматоскопии. В качестве средства мобильной дерматоскопии выступает оптический дерматоскоп, сопряженный со смартфоном [12]. Снимок выполняется с соблюдением условий освещенности и фокусировки, необходимых для получения высококачественного изображения, сопоставимого по детализации с традиционной клинической дерматоскопией (рис. 2). Из созданных




Рисунок 1 — Архитектура интеллектуальной системы скрининга кожных новообразований с использованием мобильной дерматоскопии.




Рисунок 2 — Примеры дерматоскопических изображений, полученных посредством мобильного дерматоскопа.

дерматоскопических изображений формируется набор данных дерматоскопических изображений, который в последующем используется в процессе обучения и тестирования алгоритмов классификации методов машинного обучения.

3. Передача дерматоскопического изображения в интеллектуальную систему, разработанную авторами и представленную в работе [13], для анализа. Полученное изображение передается в систему анализа, которая может быть выполнена в качестве защищенной облачной инфраструктуры или серверной компоненты (при реализации клиент-серверного взаимодействия), для осуществления предварительной обработки и последующей классификации за счет обученных алгоритмов классификации методов машинного обучения. Для построения классификаторов применяются архитектуры современных моделей машинного обучения, размещенные в открытых репозиториях Hugging Face [14], такие как vit-large-patch32-384, swinv2-tiny-patch4-window16-256, convnext-base-224 и др.

Указанные архитектуры используются в качестве основы для обучения собственных моделей классификации, которые обучаются авторским коллективом на клинически размеченных наборах дерматоскопических изображений (включая 25422 дерматоскопических изображений, из которых 24765 из набора ISIC-2019, и 657 изображений, собранных авторами работы).

4. Классификация дерматоскопического изображения в соответствии с заданными классами (критериями) и формирование предварительного врачебного заключения (предварительного диагноза). Разработанная система анализа позволяет проводить классификацию новообразований в одном из двух режимов:

- многоклассовая классификация злокачественных новообразований (отнесение к одной из диагностических категорий: доброкачественное образование, меланома, невус, базальноклеточная карцинома, актинический кератоз, дерматофиброма, сосудистые поражения кожи и плоскоклеточный рак) [13];
- бинарная каскадная двухэтапная классификация (на первом этапе: определение принадлежности к меланоцитарной/немеланоцитарной группе, на втором — дифференциация между меланомой и невусом).

Оба подхода — как многоклассовая классификация, так и каскадная двухэтапная бинарная классификация, обладают следующими преимуществами, которые позволяют применять каждый из них в клинической практике в зависимости от целей и условий применения:

- многоклассовая классификация, позволяющая идентифицировать различные типы кожных новообразований (8 типов нозологий), целесообразна при проведении массовых профилактических осмотров для установления первичного диагноза и перенаправления пациента к узконаправленным специалистам;
- каскадная бинарная классификация, осуществляющая идентификацию меланоцитарных новообразований кожи, предпочтительна в ситуациях, когда требуется максимальная точность при дифференциации меланомы и других новообразований, в том числе в условиях первичного приема с ограниченным доступом к профильным специалистам.

5. Интерпретация результатов и принятие клинического решения. Врач получает предварительное заключение с указанием класса и степени уверенности модели. В случае высокой вероятности злокачественности кожного новообразования пациент направляется к профильному специалисту (дерматологу, онкологу) для очной консультации и, при необходимости, гистологической верификации.

6. Регистрация и накопление данных для последующего анализа. Все обследования регистрируются в системе с возможностью накопления изображений, метаданных и заключений, что позволяет вести динамическое наблюдение за пациентами, формировать обучающие выборки и совершенствовать алгоритмы на практике.

РЕЗУЛЬТАТЫ

В процессе классификации дерматоскопических изображений применяются алгоритмы машинного обучения, в основу которых положены методы глубокого обучения, основанные на архитектуре сверточных нейронных сетей и трансформеров.

В качестве базовой модели для многоклассовой классификации дерматоскопических изображений была выбрана нейросетевая архитектура, основанная на трансформерном подходе

— Vision Transformer (ViT). В качестве набора данных для обучения и тестирования моделей классификации применяется модифицированный набор данных, включающий 25422 дерматоскопических изображений. В набор данных входят 24765 дерматоскопических изображений из набора данных ISIC-2019 [15] и 657 дерматоскопических изображений, содержащие клинически верифицированные случаи меланоцитарных и немеланоцитарных новообразований, собранных с учетом фототипов кожи, характерных для населения России, включая I–IV фототипы по классификации Фицпатрика, в том числе:

- невус: 353 изображения;
- себорейный кератоз: 116 изображений;
- базальноклеточная карцинома: 18 изображений;
- дерматофиброма: 19 изображений;
- сосудистые поражения: 61 изображение;
- плоскоклеточный рак: 15 изображений;
- меланома: 75 изображений.

Состав сформированного набора данных представлен в таблице 1.

В процессе обоснования применения модели с архитектурой Vision Transformer оценено 17 моделей машинного обучения, основанных на методах глубокого обучения и визуальных трансформеров, реализующие задачу распознавания изображений [16]. Стоит отметить, что архитектура Vision Transformer оперирует изображением как последовательностью патчей, между которыми трансформер моделирует глобальные взаимосвязи, что позволяет учитывать контекстные и пространственные зависимости в пределах всей дерматоскопической сцены [17, 18].

Технология визуальных трансформеров применялась авторским коллективом на всех этапах разработки и реализации методики скринингового обследования. Так, в работе [14] авторским коллективом обоснован выбор данной технологии и осуществлен сравнительный анализ существующих моделей машинного обучения для классификации кожных новообразований, который позволил обосновать возможность

применения данной архитектуры. Кроме того, были получены количественные значения точности классификации кожных новообразований, характеризующие значения метрик Accuracy и F-мера не превышавшие 0,89 и 0,69 соответственно. В рамках текущих исследований расширено число используемых моделей машинного обучения, включая модели SeyedAli/Melanoma-Classification, Heem2/Melanoma-Cancer-Image-classification и UnipaPolitoUnimore/vit-large-patch32-384-melanoma.

В ходе оценки результатов обучения и качества нейросетевых моделей использованы следующие метрики: взвешенное гармоническое среднее точности (Accuracy) и полнота (F-мера). Результаты точности обучения моделей при многоклассовой классификации представлены в таблице 2.

Несмотря на относительно высокие результаты, достигнутые в задаче многоклассовой классификации с использованием трансформерных архитектур (в частности, модели SeyedAli/Melanoma-Classification на базе ViT), данная постановка задачи обладает рядом ограничений при клиническом применении. В условиях реальной практики первостепенное значение имеет отделение клинически значимых (меланоцитарных) новообразований от доброкачественных и немеланоцитарных, а также последующая дифференциация меланомы от доброкачественных меланоцитарных образований, таких как невусы. Такая структура соответствует этапам принятия врачебного решения при дерматоскопической оценке: первичная триаж-оценка и последующее уточнение диагноза.

В связи наличием ограничений в использовании многоклассовой классификации предложена двухэтапная стратегия бинарной классификации на основе использования каскадной архитектуры моделей ViT. На первом этапе трансформерная модель выполняет бинарную классификацию всех поступающих изображений на меланоцитарные и немеланоцитарные новообразования. Эта задача позволяет выделить клинически

Таблица 1 — Распределение изображений в наборе данных

Невус	Себорейный кератоз	Базальноклеточная карцинома	Актинический кератоз	Дерматофиброма	Сосудистые поражения	Плоскоклеточный рак	Меланома
13228	2740	3341	867	258	314	77	4597

Таблица 2 — Точность обученных моделей при многоклассовой классификации кожных новообразований (меланом, невусов, карцином, кератозов, фибром, сосудистых поражений и плоскоклеточного рака)

Модель многоклассовой классификации	Кол-во эпох	Accuracy	F-мера
SeyedAli/Melanoma-Classification	100	0,932	0,891
microsoft/swinv2-tiny-patch4-window16-256	100	0,868	0,805
rizvandwiki/gender-classification	100	0,835	0,76
sanali209/nsfwfilter	100	0,84	0,752
Heem2/Melanoma-Cancer-Image-classification	100	0,825	0,731
UnipaPolitoUnimore/vit-large-patch32-384-melanoma	100	0,843	0,801
WinKawaks/vit-tiny-patch16-224	100	0,84	0,55
microsoft/beit-base-patch16-224-pt22k-ft22k	100	0,87	0,59
WinKawaks/vit-small-patch32-332	100	0,85	0,57
amunchet/rorshark-vit-base	100	0,87	0,59
Falconsai/nsfw_image_detection	100	0,85	0,58
sai17/cards-top_left_swin-tiny-patch4-window7-224-finetuned-v3_more_data	100	0,87	0,59
trpakov/vit-face-expression	100	0,87	0,59
sai17/cards_bottom_left_swin-tiny-patch4-window7-224-finetuned-dough_100_epochs	20	0,85	0,56
microsoft/beit-base-patch16-224-pt22k-ft22k	20	0,86	0,58
google/vit-base-patch16-224	20	0,86	0,57
microsoft/dit-base-finetuned-rvlcdip	20	0,789	0,47

Таблица 3 — Распределение нозологий на первом этапе бинарной классификации

Класс	Невус	Себорей- ный кератоз	Базальнокле- точная карци- нома	Актини- ческий кератоз	Дермато- фиброма	Сосудистые поражения	Мела- нома
Меланоцитарный	+						+
Немеланоцитарный		+	+	+	+	+	

приоритетную группу, требующую более детальной оценки. На втором этапе применяется отдельная модель ViT, обученная на подмножестве меланоцитарных образований и осуществляющая бинарную классификацию на меланому и невус. Такой подход позволяет сократить количество ложноположительных срабатываний, снизить диагностическую нагрузку и повысить чувствительность системы к выявлению меланом.

Архитектура Vision Transformer была выбрана для реализации данной схемы в связи с ее способностью моделировать глобальные взаимосвязи между участками изображения, что особенно критично для задач, где диагностически значимыми могут быть как мелкие морфологические элементы (например, сосудистые паттерны или точечные структуры), так и их пространственная организация. Ввиду того, что ViT

обрабатывает изображение как последовательность патчей, то к каждому из них применяется линейное отображение и позиционное кодирование, которые позволяют учесть контекст и форму кожного новообразования в целом.

Разделение изображений из анализируемых наборов данных на два класса осуществлено по принципу наличия и отсутствия клеток меланоцитов: меланоцитарный и немеланоцитарный класс (табл. 3) [19].

В качестве обучающей выборки выступает сформированный набор данных дерматоскопических изображений, основанный на ISIC-2019, характеризующийся увеличенным количеством изображений каждого класса в сравнении с набором ISIC-2018: немеланоцитарный класс — увеличилось в 2 раза (для всех групп изображений), меланоцитарный класс — увеличилось в

2 раза (для всех групп изображений) [20]. Итоговое разделение набора данных 20232 изображений (14575 — меланоцитарные и 5657 — немеланоцитарные) для обучения модели и 5190 изображений (3794 — меланоцитарные и 1396 — немеланоцитарные) для тестирования. Для возможности реализации обучения моделей машинного обучения исходный набор данных подверглся предварительной обработке, состоящей в уменьшении разрешения изображения, исходя от входа модели (224×224 для моделей `sai17/cards-top_left_swin-tiny-patch4-window7-224-finetuned-v3_more_datasanali209/nsfwfilter` и `microsoft/swinv2-tiny-patch4-window16-256`, 256×256 — `sanali209/nsfwfilterrizvandwiki/gender-classification` и т. д.), и нормализации полученных изображений, на основе требований, предъявляемых моделью классификации к анализируемым изображениям.

В ходе первичного отбора из 10 моделей с архитектурой трансформер для реализации бинарной классификации было отобрано 4 модели, относящихся к классу Vision Transformer, характеризующихся значением метрики F-мера более 0,93. Результаты тестирования моделей машинного обучения представлены в таблице 4.

Полученные результаты демонстрируют высокие значения точности в задаче бинарной классификации дерматоскопических изображений на меланоцитарные и немеланоцитарные образования на наборе данных ISIC-2019, что подтверждает применимость предложенных алгоритмов для повышения точности и объективности диагностики на этапе первичного триажа кожных новообразований в клинической практике. Использование моделей на основе архитектуры Vision Transformer позволяет эффективно учитывать как локальные морфологические признаки, так и глобальные структурные

взаимосвязи, что критически важно при анализе высоко вариативных дерматоскопических изображений.

Успешная реализация первого этапа бинарной классификации обусловила необходимость решения более узкой, но клинически значимой задачи — дифференциации внутри меланоцитарного класса, а именно — распознавания меланомы и невусов, которые требуют принципиально различной тактики ведения. Для этого была реализована вторая модель бинарной классификации, обученная на подмножестве меланоцитарных изображений, полученных на первом этапе. Модель ViT в данной конфигурации демонстрирует устойчивую способность к выявлению визуальных признаков, ассоциированных с меланомой, включая асимметрию, вариативность цвета и структуру, при сохранении высокой чувствительности к невусам.

Таким образом, каскадная стратегия бинарной классификации (меланоцитарные/немеланоцитарные → меланома/невус) обеспечивает клинически ориентированный подход, который может быть интегрирован в системы поддержки принятия решений врача с фокусом на раннюю онкологическую настороженность и снижение доли пропущенных случаев меланомы. Результаты оценки точности моделей второго этапа бинарной классификации представлены в таблице 5.

На втором этапе бинарной классификации, направленном на дифференциацию меланомы и невуса внутри меланоцитарного класса, были достигнуты высокие показатели точности Ассураса и F-меры, что свидетельствует о высокой диагностической ценности предложенных моделей. Лидирующей по качеству классификации стала модель `SeyedAli/Melanoma-Classification`, основанная на архитектуре Vision

Таблица 4 — Результаты оценки точности моделей первого этапа бинарной классификации (меланоцитарные, немеланоцитарные новообразования)

Модель бинарной классификации (1 этап)	Кол-во эпох	Размер серии	Accuracy	F-мера
<code>microsoft/swinv2-tiny-patch4-window16-256</code>	100	16	0,954	0,948
<code>sai17/cards-top_left_swin-tiny-patch4-window7-224-finetuned-v3_more_datasanali209/nsfwfilter</code>	100	16	0,938	0,933
<code>sanali209/nsfwfilterrizvandwiki/gender-classification</code>	100	32	0,95	0,938
<code>rizvandwiki/gender-classification</code>	100	16	0,942	0,933

Таблица 5 — Результаты оценки точности моделей второго этапа бинарной классификации (меланома, невус)

Модель бинарной классификации	Кол-во эпох	Размер серии	Accuracy	F-мера
SeyedAli/Melanoma-Classification	100	16	0,964	0,951
Oppoizer/Output-prova_melanoma	100	16	0,934	0,910
UnipaPolitoUnimore/vit-large-patch32-384-melanoma	100	16	0,943	0,924
microsoft/swinv2-tiny-patch4-window16-256	100	16	0,933	0,909

Transformer, которая при обучении в течение 100 эпох с размером серии 16 достигла значения показателя доли правильных ответов (Accuracy) 0,964 и F-меры 0,951, что подтверждает ее высокую чувствительность и сбалансированность по отношению к обоим классам.

Сравнимые показатели продемонстрировали также другие трансформерные модели, включая UnipaPolitoUnimore/vit-large-patch32-384-melanoma (Accuracy 0,943, F-мера 0,924) и Oppoizer/Output-prova_melanoma (Accuracy 0,934, F-мера 0,91). Эти результаты указывают на устойчивость трансформерных архитектур к вариативности визуальных признаков меланоцитарных образований, а также их способность извлекать клинически релевантные паттерны, значимые для дифференциации злокачественных и доброкачественных новообразований.

Таким образом, второй этап классификации демонстрирует, что модели, обученные на фокусированной выборке меланоцитарных изображений, способны обеспечить высокую точность автоматического распознавания меланом, что делает их потенциально полезными для внедрения в клинические системы скрининга и раннего выявления злокачественных кожных опухолей. На основе анализа результатов, представленных в таблицах 2–5, можно провести сравнительную оценку двух подходов к автоматической классификации дерматоскопических изображений: одноступенчатой многоклассовой классификации и двухэтапной бинарной классификации.

В задаче многоклассовой классификации кожных новообразований (табл. 2), наилучший результат был достигнут моделью SeyedAli/Melanoma-Classification: доля правильных ответов (Accuracy) — 0,932, F-мера — 0,891. Эта архитектура выполняет классификацию изображений сразу по всем классам (меланома, невус, кератоз, карцинома и др.) в один шаг, что делает

ее вычислительно эффективной и подходящей для сценариев, требующих высокой скорости принятия решения.

С другой стороны, двухэтапная стратегия бинарной классификации (табл. 4 и 5) показала более высокие значения точности. На первом этапе, где осуществляется разделение изображений на меланоцитарные и немеланоцитарные, лидирующая модель microsoft/swinv2-tiny-patch4 достигла Accuracy — 0,954, F-мера — 0,948. На втором этапе, в задаче дифференциации меланомы и невуса, модель SeyedAli/Melanoma-Classification продемонстрировала наивысшие показатели: доля правильных ответов (Accuracy) — 0,964, F-мера — 0,951.

Таким образом, двухэтапный каскадный подход обеспечивает прирост точности классификации в среднем на 2–3% по сравнению с многоклассовой схемой, особенно в критически важной подзадаче распознавания меланомы. Это связано с тем, что декомпозиция сложной задачи на более узкие подзадачи позволяет моделям фокусироваться на более однородных паттернах и минимизировать перекрестную ошибку между схожими классами. Однако, несмотря на преимущество в точности, двухэтапный подход требует большего времени на обработку, так как включает последовательную работу двух отдельных моделей. Напротив, многоклассовая классификация выполняется быстрее, что критично для сценариев массового скрининга и ограниченных вычислительных ресурсов.

ОБСУЖДЕНИЕ

Результаты экспериментальных оценок точности обнаружения кожных новообразований позволяют отнести разработанную методику скринингового обследования для ранней дифференциальной диагностики к исследованиям, имеющим практическую ценность.

Для обоснования актуальности полученных значений и валидации полученных результатов осуществлено построение функции потерь на этапах обучения и валидации с целью определения состояния «переобучения модели». На рисунке 3 представлены графики функции потерь при обучении и валидации модели SeyedAli/Melanoma-Classification, применяемой на втором этапе каскадной бинарной классификации, отсутствие дивергенции между функцией потерь при обучении и валидации после 80 эпохи подтверждает отсутствие переобучения.

Полученные значения позволяют сделать вывод об адекватности разработанной модели и отсутствии состояния переобучения модели.

В процессе сравнительного анализа разработанной методики осуществлен анализ текущих исследований в области обнаружения злокачественных новообразований кожи, включая меланому и рак кожи. Наиболее близкими аналогами являются работы Almufareh M.F. et al. [21] и Suleiman T.A. et al. [22].

В работе [21] для обнаружения меланоцитарных новообразований кожи используется подход, основанный на применении глубокого обучения посредством сверточной нейронной сети, обученной на наборах дерматоскопических изображений ISIC-2019, DermIS и DermQuest. Представленный подход характеризуется высокими значениями точности обнаружения меланомы Accurasy 0,970 и F-мера 0,987. Однако метод обеспечивает

только бинарную классификацию «меланома / не-меланома» и не решает задачу различения между другими типами кожных новообразований. Также авторы не приводят значения функции потерь и кривые обучения, что не позволяет оценить степень переобучения модели.

В работе [22] предложен двухэтапный подход иерархической бинарной классификации кожных новообразований. На первом этапе дерматоскопические изображения классифицируются на доброкачественные новообразования кожи и прочие случаи (объединенный класс, включающий меланому и себорейный кератоз). На втором этапе производится уточняющая классификация ранее выделенных случаев из класса «прочие» на меланому и себорейный кератоз. В качестве признаков используются векторы, извлеченные из предобученной сверточной нейронной сети DenseNet121, к которым применяется метод главных компонент (PCA) для уменьшения размерности. Для классификации в обоих этапах используется алгоритм случайного леса. При тестировании на датасете ISIC-2017 достигнуты значения метрик Accurasy: 0,8567 для первого этапа классификации и 0,9468 — для второго. Несмотря на высокие показатели, по точности классификации новообразований кожи предложенный авторами подход отличается по постановке задачи и уступает разработанной методике.

В рамках предложенной методики скринингового обследования для ранней




Рисунок 3 — Оценка функции потерь при обучении и валидации модели SeyedAli/Melanoma-Classification каскадной бинарной классификации.

дифференциальной диагностики меланоцитарных новообразований с использованием мобильной дерматоскопии, выбор конкретного алгоритмического режима осуществляется с учетом организационного контекста и поставленных задач:

- многоклассовая классификация целесообразна при необходимости быстрого первичного разделения на несколько классов большого количества дерматоскопических изображений пациентов, что особенно актуально на этапе массовых профилактических осмотров;
- каскадная бинарная классификация предпочтительна в ситуациях, когда требуется максимальная точность при дифференциации меланомы и других новообразований, в том числе в условиях первичного приема с ограниченным доступом к профильным специалистам.

Выбор подхода должен определяться конкретным клиническим сценарием, доступностью вычислительных ресурсов, а также требованиями к чувствительности и специфичности на этапе формирования предварительного заключения и маршрутизации пациента.

Ограничениями методики являются ограниченное количество изображений некоторых классов (например, дерматофиброма, плоскоклеточный рак), потенциальная зависимость качества классификации от условий освещенности при мобильной дерматоскопии.

ЗАКЛЮЧЕНИЕ

В рамках исследования предложена методика скринингового обследования, направленная на раннюю дифференциальную диагностику меланоцитарных новообразований кожи в условиях первичной медико-санитарной помощи, основанная на применении мобильной дерматоскопии и алгоритмов машинного обучения. Методика разработана с учетом требований клинической применимости, технической доступности, независимости от конкретного оборудования и минимизации субъективного фактора при интерпретации визуальных данных. Для реализации указанных требований в работе применяются методы искусственного интеллекта (машинного обучения), технологии и среды разработки с открытым исходным кодом, а также общедоступные наборы дерматоскопических изображений с клинически размеченными признаками.

Архитектуры моделей машинного обучения, размещенные в репозиториях Hugging Face, использованы в качестве базовых шаблонов, на основе которых авторским коллективом были самостоятельно обучены и валидированы модели классификации кожных новообразований. Обучение моделей проводилось на открытых датасетах (включая ISIC-2019 и собственный набор, включающий 657 изображений, собранных авторами работы).

Такой подход позволяет не только адаптировать интеллектуальную систему под потребности клинической практики, но и масштабировать ее за счет обучения на новых данных, а также интегрировать с различными типами медицинского оборудования. Использование открытых решений и собственное обучение моделей минимизирует субъективность интерпретации визуальных данных и снижает барьеры внедрения в практическое здравоохранение.

Преимуществом методики является ее приспособленность к условиям ограниченных технических ресурсов, технологическая независимость от конкретной модели дерматоскопа и возможность интеграции в существующие рабочие процессы учреждений первичного звена. Использование мобильной дерматоскопии в сочетании с облачной интеллектуальной системой (серверной компонентой в случае использования клиент-серверной архитектуры) обеспечивает высокую точность предварительного диагноза, способствует повышению онконастороженности врача и снижает долю необоснованных обращений в онкологические диспансеры, тем самым оптимизируя маршрутизацию пациентов.

При этом стоит отметить, что необходимость повышения точности обнаружения злокачественных новообразований и расширение текущих классов другими нозологическими единицами, а также формирование собственных наборов данных, учитывающих особенности фототипов кожи населения Российской Федерации и клинические значимые признаки кожных новообразований, является направлением дальнейших исследований.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

ЛИТЕРАТУРА/REFERENCES

1. Злокачественные новообразования в России в 2023 году (заболеваемость и смертность) / Под. ред. Каприна А.Д., Старинского В.В., Шахзадовой А.О. – М.: МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России, 2024. — С.276. [Zlokachestvennye novoobrazovaniya v Rossii v 2023 godu (zabolevaemost' i smernost'). Ed. by Kaprina A.D., Starinskogo V.V., Shahzadovoj A.O. Moscow: MNIIOI im. P.A. Gercena – filial FGBU «NMIC radiologii» Minzdrava Rossii: 2024, 276 p. (In Russ.)]
2. Крыловецкая М.А., Комаров И.Г., Карселадзе Д.А. Диагностика и лечение метастазов меланомы без выявленного первичного очага // Современная онкология. — 2018. — Т.20. — №3. — С.30-34. [Krylovetskaya M.A., Komarov I.G., Karseladze D.A. Diagnosis and treatment of metastatic melanoma of unknown primary. Sovremennaya onkologiya. 2018; 20(3): 30-34. (In Russ.)] doi: 10.26442/1815-1434_2018.3.30-34.
3. Cancer Today. International Agency for Research on Cancer. 2025. Available at: https://gco.iarc.fr/today/en/dataviz/pie?mode=population&group_populations=0. Accessed 11.07.2025.
4. Siegel RL, Miller KD, Jemal A. Cancer statistics, 2020. CA: a cancer journal for clinicians. 2020; 70: 7-30. doi: 10.3322/caac.21590.
5. Bakheet S, Al-Hamadi A. Computer-Aided Diagnosis of Malignant Melanoma Using Gabor-Based Entropic Features and Multilevel Neural Networks. Diagnostics. 2020; 10(10): 822. doi: 10.3390/diagnostics10100822.
6. Pratiwi RA, Nurmaini S, Rini DP. Deep ensemble learning for skin lesions classification with convolutional neural network. IAES International Journal of Artificial Intelligence. 2021; 10(3): 563-570. doi: 10.11591/ijai.v10.i3.pp563-570.
7. Popescu D, El-Khatib M, El-Khatib H, Ichim L. New Trends in Melanoma Detection Using Neural Networks: A Systematic Review. Sensors. 2022; 22: 496. doi: 10.3390/s22020496.
8. El-Khatib M, Teodor OM, Popescu D, Ichim L. Identification of Benign Tumor Masses Using Deep Learning Techniques Based on Semantic Segmentation. Advances in Computational Intelligence (IWANN 2023). 2023; 14134: 529-540. doi: 10.1007/978-3-031-43085-5.
9. Hermosilla P, Soto R, Vega E, Suazo C, Ponce J. Skin Cancer Detection and Classification Using Neural Network Algorithms: A Systematic Review. Diagnostics. 2024; 14: 454. doi: 10.3390/diagnostics14040454.
10. Mahmoud NM, Soliman AM. Early automated detection system for skin cancer diagnosis using artificial intelligent techniques. Scientific Reports. 2024; 14: 9749. doi: 10.1038/s41598-024-59783-0.
11. Козачок А.В., Спирин А.А., Козачок Е.С. Обзор методов раннего обнаружения меланомы // Труды ИСП РАН. — 2022. — Т.34. — №4. — С.241-250. [Kozachok AV, Spirin AA, Kozachok ES. Review of methods for early melanoma detection using computer vision methods. Trudy ISP RAN. 2022; 34(4): 241-250. (In Russ.)] doi: 10.15514/ISPRAS-2022-34(4)-17.
12. Хисматуллина З.Р., Чеботарев В.В., Бабенко Е.А. Современные аспекты и перспективы применения дерматоскопии в дерматоонкологии // Креативная хирургия и онкология. — 2020. — Т.10. — №3. — С.241-248. [Khismatullina ZR, Chebotaryov VV, Babenko EA. Dermatoscopy in Dermato Oncology: Current State and Perspectives. Kreativnaya hirurgiya i onkologiya. 2024; 10(3): 241-248. (In Russ.)] doi: 10.24060/2076-3093-2020-10-3-241-248.
13. Козачок А.В., Спирин А.А., Самоваров О.И., Козачок Е.С. Применение моделей машинного обучения для многоклассовой классификации дерматоскопических снимков новообразований кожи // Труды ИСП РАН. — 2024. — Т.36. — №5. — С.241-252. [Kozachok AV, Spirin AA, Samovarov OI, Kozachok ES. Application of machine learning models for multiclass classification of dermatoscopic images of skin neoplasms. Trudy ISP RAN. 2024; 36(5) 241-252. (In Russ.)] doi: 10.15514/ISPRAS-2024-36(5)-17.
14. The AI community building the future. Available at: https://huggingface.co/models?pipeline_tag=image-classification&sort=trending. Accessed 11.07.2025.
15. The International Skin Imaging Collaboration Available at: <https://www.isic-archive.com/>. Accessed 11.07.2025.
16. Kamrul H, Asif A, Choon HY, Guang Y. A survey, review, and future trends of skin lesion segmentation and classification. Computers in Biology and Medicine. 2023; 155: 1-36. doi: 10.1016/j.compbiomed.2023.106624.
17. Zhang Z, Lei Z, Omura M, Hasegawa H, Gao S. Dendritic Learning-Incorporated Vision Transformer for Image Recognition. Journal of Automatica Sinica. 2024; 11(2): 539-541. doi: 10.1109/JAS.2023.123978.
18. Han K, Wang Y, Chen H, Chen X, Guo J. A Survey on Vision Transformer. IEEE Transactions on Pattern Analysis and Machine Intelligence. 2022; 45(1): 87-110. doi: 10.1109/TPAMI.2022.3152247.
19. Бакулев А.Л., Конопацкова О.М., Станчина Ю.В. Дерматоскопия в диагностике пигментных невусов кожи // Вестник дерматологии и венерологии. — 2019. — №95(4). — С.48-56. [Bakulev AL, Konopatskova OM, Stanchina YV. Dermatoscopy in the diagnosis of pigmented nevi. Vestnik Dermatologii i Venerologii. 2019; 95(4): 48-56. (In Russ.)] doi: 10.25208/0042-4609-2019-95-4-48-56.
20. Codella N, Rotemberg V, Tschandl P, Celebi ME, et al. Skin lesion analysis toward melanoma detection 2018: A challenge hosted by the international skin imaging collaboration (ISIC). Computer Vision and Pattern Recognition. 2019. Available at: <https://doi.org/10.48550/arXiv.1902.03368>. Accessed 11.07.2025.
21. Almufareh MF, Tariq N, Humayun M, Khan FA. Melanoma identification and classification model based on fine-tuned convolutional neural network. Digital Health. 2024; 10: 1-29. doi: 10.1177/20552076241253757.
22. Suleiman TA, Anyimadu DT, Permana AD, Ngim HA, Scotto di Freca A. Two-step hierarchical binary classification of cancerous skin lesions using transfer learning and the random forest algorithm. Visual Computing for Industry, Biomedicine, and Art. 2024; 7(15): 1-17. doi: 10.1186/s42492-024-00166-7.