

Классификация дерматоскопических изображений с использованием сверточных нейронных сетей

Канд. физ.-мат. наук, доц. А. Ф. Смалюк¹⁾

¹⁾Белорусский национальный технический университет (Минск, Республика Беларусь)

Реферат. В работе изучается проблема диагностики меланомы кожи на основе дерматоскопических изображений с использованием современных компьютерных технологий. В частности, рассмотрена задача классификации дерматоскопических изображений с использованием сверточных нейронных сетей для получения предварительных диагнозов меланомы кожи. Описаны основные открытые источники, на основе которых могут создаваться наборы изображений для обучения сетей и их тестирования. Отмечены проблемы, возникающие при создании набора данных для обучения нейронной сети, пути решения проблем, связанных с несбалансированностью имеющихся наборов данных. Предложены два варианта архитектуры нейронной сети для решения задачи классификации дерматоскопических изображений: простая сверточная сеть и сеть, построенная на основе архитектуры Inception. Описаны основные метрики, используемые для проверки качества диагностики в медицинских задачах. Проведено сравнение результатов, полученных с помощью предложенных сетей, и обоснован выбор Inception как обеспечивающей большую чувствительность при определении меланомы. Выполнено тестирование созданных сетей с использованием собственной базы данных дерматоскопических изображений, проведен анализ возможных причин отличия результатов тестового и валидационного наборов изображений и обоснована необходимость дальнейшей аугментации данных при обучении. Предложены средства дополнительной аугментации данных, интегрированные в архитектуру сети на стадии обучения. Выполнено сравнение полученных с помощью аугментации результатов и показано значительное улучшение чувствительности сети при работе с тестовым набором изображений.

Ключевые слова: меланома, нейронные сети, сверточные нейронные сети, диагностика, классификация изображений

Для цитирования: Смалюк, А. Ф. Классификация дерматоскопических изображений с использованием сверточных нейронных сетей / А. Ф. Смалюк // *Наука и техника*. 2026. Т. 25, № 1. С. 5–13. <https://doi.org/10.21122/2227-1031-2026-25-1-5-13>

Dermatoscopy Image Classification Using Convolutional Neural Networks

A. F. Smaliuk¹⁾

¹⁾Belarusian National Technical University (Minsk, Republic of Belarus)

Abstract. This paper examines the problem of diagnosing skin melanoma based on dermatoscopy images using modern computer technologies. In particular, it considers the problem of classifying dermatoscopy images using convolutional neural networks to obtain preliminary melanoma diagnoses. The main open sources that can be used to create image datasets for network training and testing are described. The challenges encountered in creating a dataset for neural network training and solutions to problems associated with the imbalance in existing datasets are discussed. Two neural network architectures are

Адрес для переписки

Смалюк Антон Федорович
Белорусский национальный технический университет
пр. Независимости, 65,
220013, г. Минск, Республика Беларусь
Тел.: +375 17 293-93-22
dsmsm@bntu.by

Address for correspondence

Smaliuk Anton F.
Belarusian National Technical University
65, Nezavisimosty Ave.,
220013, Minsk, Republic of Belarus
Tel.: +375 17 293-93-22
dsmsm@bntu.by

proposed for solving the problem of dermatoscopy image classification: a simple convolutional network and a network built on the Inception architecture. The key metrics used to assess diagnostic quality in medical applications are described. The results obtained using the proposed networks are compared, and the choice of Inception is justified as providing greater sensitivity in melanoma detection. The developed networks were tested using our own database of dermatoscopy images. Possible causes of discrepancies between the test and validation image sets were analyzed, and the need for further data augmentation during training was substantiated. Tools for additional data augmentation were proposed and integrated into the network architecture during the training stage. A comparison of the results obtained through augmentation was performed, demonstrating a significant improvement in the network sensitivity when working with the test set of images.

Keywords: melanoma, neural networks, convolutional neural networks, diagnostics, image classification

For citation: Smaliuk A. F. (2026) Dermatoscopy Image Classification Using Convolutional Neural Networks. *Science and Technique*. 25 (1), 5–13. <https://doi.org/10.21122/2227-1031-2026-25-1-5-13> (in Russian)

Введение

Классификация дерматоскопических изображений является чрезвычайно важной задачей для получения предварительных диагнозов меланомы кожи, которая является наиболее опасной формой рака кожи с достаточно высоким процентом смертности, и в последние десятилетия наблюдается рост случаев этого заболевания [1]. Одно из важнейших условий, необходимых для ее успешного лечения, – своевременная диагностика. При этом, несмотря на наличие общепринятых методик диагностики меланомы, ряд исследований показывает, что даже высококвалифицированные медики устанавливают диагноз с точностью менее 77 % [2, 3].

Создание компьютерной системы, которая позволяет с высокой точностью выявлять опасные новообразования кожи, может существенно облегчить диагностику этого заболевания, повысить эффективность лечения.

В Республике Беларусь первая система автоматизированной диагностики меланомы кожи MelaSearch была разработана в 2015 г. в БНТУ в сотрудничестве с ОИПИ НАН Беларуси, РНПЦ ОМР имени Н. Н. Александрова и другими медицинскими и научными организациями страны [4]. В настоящее время эта система используется в ряде медицинских учреждений Беларуси для постановки предварительных диагнозов меланомы кожи.

Рассматриваемая в данной статье разработка является в значительной мере продолжением данного проекта, и ее целью является повышение точности получаемых с помощью системы диагнозов.

В настоящее время одной из самых эффективных и наиболее часто используемых технологий, позволяющих установить, что новооб-

разование кожи, присутствующее на дерматоскопическом изображении, оказывается меланомой, является технология нейронных сетей и, в частности, сверточных нейронных сетей.

Сверточные нейронные сети, с одной стороны, позволяют получить высокую точность распознавания изображений, с другой – обеспечивают достаточно высокую производительность, позволяющую использовать их не только на высокопроизводительных компьютерах, но и в мобильных устройствах и даже встраивать такие системы в веб-приложения [5]. Сверточные сети также могут использоваться в задачах как классификации, так и сегментации новообразований кожи [6, 7].

Обучающие данные

Качество получаемых с помощью нейронных сетей результатов напрямую зависит от объема и качества данных, используемых при обучении этих сетей, и только во вторую очередь от архитектуры и выбранных гиперпараметров самой сети.

Одним из лучших общедоступных наборов дерматоскопических изображений для обучения нейронных сетей является набор HAM10000 [8], собранный сотрудниками Венского медицинского университета в 2018 г., включающий в себя около 10 тыс. изображений. Данный обучающий набор использовался в третьем задании конкурса ISIC 2018 [9], и по сегодняшний день именно он используется в значительной части разработок систем диагностики рака кожи.

Набор включает в себя изображения не только меланомы и невусов (родинок), но и ряда других типов новообразований кожи, которые либо не являются опасными, либо значительно менее опасны, чем меланома кожи.

При этом многие меланомы плохо отличимы от невусов визуально, и именно это является самым распространенным источником ошибок при классификации. Поэтому в данной работе было решено ограничиться только классификацией меланом и невусов.

Набор изображений HAM10000 имеет ряд недостатков, главный из которых – несбалансированность. Он включает в себя около 6 тыс. изображений невусов и около 1 тыс. изображений меланом. Такая несбалансированность данных приводит к существенным затруднениям при обучении нейронных сетей и требует принятия специальных мер для получения результатов классификации с высокой точностью.

Чтобы сделать обучающий набор более сбалансированным, в ходе данной работы применена т. н. аугментация данных: на основе имеющихся изображений меланомы кожи были созданы новые, путем поворота изображения один или несколько раз на 90°. Полученные изображения включены в используемый обучающий набор наряду с исходными, и количество изображений меланом в наборе было увеличено до 3 тысяч. Таким образом, несбалансированность обучающего набора значительно уменьшена, хотя и не ликвидирована полностью. Оставшаяся несбалансированность компенсирована средствами самой нейронной сети.

Также набор HAM10000 имеет в своем составе изображения различных размеров, с разными соотношениями сторон. В ходе подготовки данных все изображения были преобразованы к квадратному виду путем обрезки.

Полученные в результате 9 тыс. изображений составили обучающий и валидационный наборы. Валидационный набор составил 0,2 от общего набора данных.

Из данных конкурса ISIC 2019 был взят тестовый набор (далее – тестовый набор 1), предназначенный для окончательной оценки качества обучения сети. Этот набор включает в себя 171 изображение меланом и 909 изображений невусов.

Кроме того, создан собственный тестовый набор. В ходе разработки системы MelaSearch и ее последующего совершенствования собрана база данных дерматоскопических изображений. Главное ее достоинство – диагнозы всех изображений в ней были подтверждены гистологи-

чески, что дает нам полную уверенность в абсолютной точности диагнозов. В результате был создан второй тестовый набор из 53 изображений меланом и 67 изображений невусов (далее – тестовый набор 2).

Изображения, собранные в этом тестовом наборе, имеют отличающуюся от HAM10000 яркость, существенно отличающиеся оттенки цветов кожи и самих новообразований. Одной из главных причин этого является использование разного оборудования при получении дерматоскопических снимков. Системы подсветки, используемые в дерматоскопах, могут отличаться температурой света и яркостью от производителя к производителю и даже от модели к модели, что может приводить к существенной цветовой разнице. Успешное тестирование работы сети на втором тестовом наборе должно продемонстрировать не только способность сети распознавать новообразования, отличные от тех, на которых ее обучали, но и корректно распознавать меланомы на снимках, сделанных на разном оборудовании в различных условиях.

Все последующие результаты обучения нейронных сетей будут оцениваться с помощью этих двух тестовых наборов.

Архитектура нейронной сети и параметры обучения

В ходе исследований рассмотрены две архитектуры нейронных сетей.

Первая – простая сверточная нейронная сеть, состоящая из девяти сверточных слоев, использующих активационную функцию *elu*. Первый слой имеет размер фильтра 5×5 и шаг 2. Семь слоев имеют размер фильтра 3×3 с шагом 1, с постепенным увеличением количества фильтров до 512. Расположенные между ними шесть пулинговых слоев сети уменьшают размер изображения от 128×128 до 1×1. Десятый сверточный слой имеет 512 фильтров размером 1×1. Выходной слой состоит из 2 нейронов с активационной функцией *softmax*, чьи выходы соответствуют вероятностям невуса и меланомы. Использование двух нейронов вместо одного обусловлено тем, что в дальнейшем планируется добавить идентификацию других типов новообразований.

Архитектура сети показана в табл. 1

Таблица 1

Архитектура сверточной сети для классификации дерматоскопических изображений

Convolutional network architecture for dermatoscopy image classification

№	Тип слоя	Размер данных на выходе слоя
1	Входное изображение	128×128×3
2	Conv2D	64×64×48
3	MaxPooling2D	32×23×48
4	Conv2D	32×32×32
5	MaxPooling2D	16×16×32
6	Conv2D	16×16×64
7	Conv2D	16×16×64
8	MaxPooling2D	8×8×64
9	Conv2D	8×8×128
10	Conv2D	8×8×128
11	MaxPooling2D	4×4×128
12	Conv2D	4×4×256
13	Conv2D	4×4×256
14	MaxPooling2D	2×2×256
15	Conv2D	2×2×512
16	MaxPooling2D	1×1×512
18	Flatten	512
19	Dense	2

Второй вариант архитектуры сети использует модули, аналогичные модулям сети Inception, предложенной сотрудниками компании Google [10], с некоторыми упрощениями.

Каждый такой модуль состоит из нескольких сверток разного размера, работающих параллельно. Структура типичного модуля, использовавшегося в данной работе, показана на рис. 1. Модуль состоит из сверток размером 5×5, 3×3 и 1×1, результаты которых склеиваются на выходе из модуля. Всего в созданной сети используются 8 таких модулей.

Главная идея использования таких модулей заключается в том, чтобы предоставить возможность алгоритму обучения автоматически выбирать размер свертки, дающий для данного слоя наилучшие результаты.

Как утверждается в [10], наиболее эффективными Inception блоки показывают себя в середине и второй половине сети, поэтому первыми слоями обычно выступают обычные сверточные слои. В используемой в данной работе архитектуре первым является простой сверточный слой с 64 ядрами размера 7×7.




Рис. 1. Структура модуля Inception

Fig. 1. Inception module structure

Выходными являются плотный слой из 512 нейронов и выходной плотный слой из двух нейронов с активационной функцией softmax. Общая архитектура сети показана в табл. 2.

Таблица 2

Архитектура сети с блоками Inception для классификации дерматоскопических изображений

Network architecture with Inception blocks for dermatoscopy image classification

№	Тип слоя	Размер данных на выходе слоя
1	Входное изображение	128×128×3
2	Conv2D	128×128×64
3	MaxPooling2D	64×64×64
4	Inception	64×64×64
	Inception	64×64×64
5	MaxPooling2D	32×32×64
6	Inception	32×32×96
	Inception	32×32×96
7	MaxPooling2D	16×16×96
8	Inception	16×16×128
	Inception	16×16×128
9	MaxPooling2D	8×8×128
10	Inception	8×8×256
11	Inception	8×8×256
12	MaxPooling2D	4×4×512
13	Conv2D	4×4×256
17	MaxPooling2D	1×1×512
18	Flatten	512
16	Dense	512
19	Dense	2

Обе рассмотренные архитектуры рассчитаны на входные изображения 128×128 точек с тремя цветовыми слоями.

Создание данных нейронных сетей выполнялась с использованием языка Python и библиотеки TensorFlow.

Обучение нейронных сетей производилось с использованием алгоритма Adam. В качестве функции потерь использовалась категориальная перекрестная энтропия. Как известно, эта функция потерь в своем чистом виде работает наилучшим образом при использовании для обучения сбалансированных данных. Так как используемый набор сбалансированным не является, были добавлены поправочные коэффициенты для компенсации дисбаланса. Для невусов использован коэффициент 0,66, для меланом 1,33.

Результаты обучения

Оценка результатов обучения будет выполняться по матрицам ошибок и метрик точности. Главными метриками точности результатов в медицинских задачах диагностики считаются коэффициенты чувствительности и специфичности. Для задачи диагностики меланомы формулы для их расчета будут иметь вид:

$$\text{Чувствительность} = \frac{\text{Количество правильно диагностированных меланом}}{\text{Общее количество меланом}}; \quad (1)$$

Специфичность =

$$= \frac{\text{Количество правильно диагностированных невусов}}{\text{Общее количество невусов}}. \quad (2)$$

В процессе обучения обе сети показывают близкие результаты. Для обучающего набора значение функции потерь стремится к 0, точность получаемых результатов стремится к 1. Для валидационного набора точность достигает 0,85, минимальное значение функции потерь 0,33. График обучения показан на рис. 2.

При том, что получены достаточно хорошие результаты, проверка работы сети с помощью тестовых наборов изображений показала существенно более низкую точность, чем для валидационного набора. Причем в отличие от валидационного набора результаты для тестовых наборов отличаются на разных архитектурах. Матрица ошибок тестового набора 1 показана в табл. 3, а тестового набора 2 – в табл. 4. Эти матрицы получены для сети первой простой сверточной архитектуры, обучение которой остановлено на минимальном значении функции потерь для валидационного набора, равном 0,34. Точность для валидационного набора при этом составляет 0,84. Матрицы ошибок для сети Inception показаны в табл. 5 и 6.




Рис. 2. График обучения сверточной нейронной сети

Fig. 2. Training curves of the convolutional neural network

Таблица 3

**Матрица ошибок тестового набора 1
для простой сверточной нейронной сети**
**Confusion matrix of test set 1 for the simple
convolutional neural network**

	Меланома	Невус
Меланома	130	41
Невус	190	719

Таблица 4

**Матрица ошибок тестового набора 2
для простой сверточной нейронной сети**
**Confusion matrix of test set 2 for the simple
convolutional neural network**

	Меланома	Невус
Меланома	35	18
Невус	6	61

Таблица 5

**Матрица ошибок тестового набора 1
для нейронной сети Inception**
**Confusion matrix of test set 1 for the Inception
neural network**

	Меланома	Невус
Меланома	153	18
Невус	245	664

Таблица 6

**Матрица ошибок тестового набора 2
для нейронной сети Inception**
**Confusion matrix of test set 2 for the Inception
neural network**

	Меланома	Невус
Меланома	38	15
Невус	5	62

Результаты расчета основных метрик качества обучения показаны в табл. 7.

Таблица 7

Метрики качества обучения сетей
Network training quality metrics

	Чувствительность	Специфичность	Общая точность
Тестовый набор 1. Сверточная сеть	0,76	0,79	0,78
Тестовый набор 2. Сверточная сеть	0,66	0,91	0,80
Тестовый набор 1. Сеть Inception	0,89	0,73	0,76
Тестовый набор 2. Сеть Inception	0,72	0,93	0,83

Из табл. 7 можно сделать вывод, что сеть, использующая архитектуру Inception, обеспечивает большую чувствительность. Это наблюдается на обоих тестовых наборах и означает, что она с большей вероятностью определяет наличие меланомы. А так как главная цель создаваемой нейронной сети – правильное определение меланом, параметр чувствительности является самым важным.

Так как сеть архитектуры Inception лучше выявляет меланомы, в дальнейшем будем использовать именно ее.

Несмотря на то что выбранная сеть демонстрирует лучшее значение чувствительности, для второго тестового набора это значение не является достаточно высоким, оно равно 0,72, что на 10 процентов ниже общей точности, равной 0,83.

Недостаточно высокую чувствительность, полученную для второго тестового набора, можно объяснить тем, что в процессе обучения сеть начала излишне точно учитывать конкретные оттенки цветов кожи и новообразований, используемых в обучающем наборе, и при применении второго тестового набора, оттенки цветов кожи и новообразований в котором существенно отличаются, сеть оказывается не в состоянии правильно классифицировать многие изображения.

Также в ходе исследования поведения полученных результатов установлено, что два изображения одного и того же новообразования могут давать существенно отличающиеся результаты, если новообразование находится в разных местах изображений.

Для решения данных проблем в архитектуру обеих сетей внесены некоторые изменения: перед первым сверточным слоем нейронной сети было добавлено несколько дополнительных слоев, выполняющих аугментацию обучающих данных прямо в процессе обучения. После обучения данные слои отключаются.

Были добавлены:

1) слой, случайным образом варьирующий цветовые оттенки изображений;

2) слой, случайным образом варьирующий яркость изображения;

3) слой, сдвигающий изображение на случайную величину.

Использование данных слоев значительно изменяет процесс обучения.

Обучение значительно замедляется – при той же скорости обучения для достижения аналогичных неаугментированным сетям уровней функции потерь и точности требуется в 2–3 раза больше эпох. Процесс обучения для первых 220 эпох показан на рис. 3.

Из полученных результатов можно сделать вывод, что наличие аугментационных слоев существенно улучшает результаты тестового набора 2 изображений. Значительно повышается количество правильно определенных меланом и, следовательно, вырастает показатель чувствительности. Матрица ошибок второго тестового набора на аугментированной сети архитектуры Inception показана в табл. 8.

При сравнении результатов из табл. 7 и 9 видно, что аугментационные слои позволили повысить чувствительность сети для тестового набора 2 изображений на 18 %. При этом специфичность упала на 10 %, но так как она – менее важный показатель и ее падение почти в два раза меньше, чем повышение чувстви-

тельности, и общая точность классификации выросла на 3 %, это можно считать приемлемым результатом. При этом общая точность классификации первого тестового набора практически не изменилась.

Таблица 8

Матрица ошибок тестового набора 2 данных для аугментированной нейронной сети

Confusion matrix of test dataset 2 for the augmented neural network

	Меланома	Невус
Меланома	48	5
Невус	12	55

Основные метрики качества обучения сети со слоями аугментации показаны в табл. 9.

Таблица 9

Метрики качества обучения сети со слоями аугментации

Training quality metrics for the network with augmentation layers

	Чувствительность	Специфичность	Общая точность
Тестовый набор 1	0,84	0,73	0,76
Тестовый набор 2	0,90	0,82	0,86




Рис. 3. График обучения аугментированной нейронной сети

Fig. 3. Training curves of the augmented neural network

ВЫВОДЫ

1. Использование предлагаемых сверточных нейронных сетей для классификации дерматоскопических изображений позволяет получить прогнозы злокачественности новообразований кожи с достаточно высокой точностью – с показателем чувствительности, превышающим 0,8. При этом прогнозы с применением архитектуры Inception получены с большим показателем чувствительности по сравнению с простой сверточной архитектурой. Поэтому сеть на основе архитектуры Inception выбрана для дальнейшей работы.

2. Проверка на тестовом наборе, созданном на основе имеющейся у нас собственной базы данных дерматоскопических изображений, установила, что нейронные сети, обученные на наборах, созданных на основе HAM10000, могут показывать существенно более низкую чувствительность при диагностике меланомы, если используемые снимки, сделанные на отличающемся оборудовании, имеют отличия в яркости, цветовой температуре, контрасте (разница значений показателя чувствительности превышает 10 %). Для компенсации этого явления предложено добавить в сеть на стадии обучения аугментационные слои, которые будут случайным образом варьировать яркость, контраст и цветовую температуру обучающих изображений.

3. Добавление в процессе обучения аугментационных слоев в начало нейронной сети позволило получить с ее помощью с хорошей точностью прогнозы для изображений нашего тестового набора, сделанных на различном оборудовании, с разными цветовыми параметрами подсветки, яркости и контрастности изображений. Рост показателя чувствительности при этом достигает 18 %.

4. Полученные результаты демонстрируют возможность использования разработанной и обученной в рамках данной работы нейронной сети в системе диагностики меланомы кожи MelaSearch.

ЛИТЕРАТУРА

1. Меланома кожи в Республике Беларусь: эпидемиология, диагностика и результаты лечения / А. Г. Жуковец, А. Е. Океанов, П. И. Моисеев, А. В. Прокошин // Онкологический журнал. 2017. Т. 11, № 1. С. 35–46.
2. Deep Neural Networks Are Superior to Dermatologists in Melanoma Image Classification / T. J. Brinker, A. Hekler, A. H. Enk [et al.] // European Journal of Cancer. 2019. Vol. 119. P. 11–17. <https://doi.org/10.1016/j.ejca.2019.05.023>.
3. AI Outperformed Every Dermatologist in Dermoscopic Melanoma Diagnosis, Using an Optimized Deep-CNN Architecture with Custom Mini-Batch Logic and Loss Function / T. C. Pham, C.-M. Luong, V.-D. Hoang, A. Doucet // Scientific Reports. 2021. Vol. 11, No 1. P. 17485. <https://doi.org/10.1038/s41598-021-96707-8>.
4. Экспертная система диагностики злокачественных опухолей кожи / А. Г. Жуковец, Н. М. Тризна, И. В. Белоцерковский [и др.] // Вторая белорусско-польская дерматологическая конференция: дерматология без границ: сб. материалов респ. науч.-практ. конф., Гродно, 8 мая 2015. Гродно, 2015. С. 62–66.
5. Смалюк, А. Ф. Особенности использования TensorFlow для разработки систем искусственного интеллекта / А. Ф. Смалюк // Бизнес. Образование. Экономика: VI Междунар. науч.-практ. конф., Минск, 3–4 апреля 2025 г.: сб. ст. Минск: Институт бизнеса БГУ, 2025. С. 319–322.
6. Смалюк, А. Ф. Использование нейронных сетей в задачах анализа дерматоскопических изображений / А. Ф. Смалюк // Бизнес. Образование. Экономика: Междунар. науч.-практ. конф., Минск, 4–5 апр. 2024 г.: сб. ст. / редкол.: Н. В. Манцуrowa [и др.]. Минск: Ин-т бизнеса БГУ, 2024. С. 300–305.
7. Смалюк, А. Ф. Сегментация дерматоскопических изображений новообразований кожи. Сравнение методик / А. Ф. Смалюк, М. С. Дешко, И. Д. Купчикова // Системный анализ и прикладная информатика. 2024. № 1. С. 50–58. <https://doi.org/10.21122/2309-4923-2024-1-50-58>.
8. Tschandl P. The HAM10000 Dataset, a Large Collection of Multi-Sources Dermatoscopic Images of Common Pigmented Skin Lesions / P. Tschandl, C. Rosendahl, H. Kittler // Scientific Data. 2018. Vol. 5, No 1. P. 180161. <https://doi.org/10.1038/sdata.2018.161>.
9. Skin Lesion Analysis toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (isic) / N. Codella, V. Rotemberg, P. Tschandl [et al.] // arXiv preprint. URL: <https://arxiv.org/abs/1902.03368>. <https://doi.org/10.48550/arXiv.1902.03368>.
10. Going Deeper with Convolutions / C. Szegedy, Wei Liu, Yangqing Jia [et al.] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA, 2015. P. 1–9. <https://doi.org/10.1109/cvpr.2015.7298594>.

Поступила 09.10.2025

Подписана в печать 29.12.2025

Опубликована онлайн 30.01.2026

REFERENCES

1. Zhukovets A. G., Okeanov A. E., Moiseev P. I., Prokoshin A. V. (2017) Skin Melanoma in the Republic of Belarus: Epidemiology, Diagnosis and Treatment Results. *Onkologicheskyy Zhurnal* [Oncological journal], 11 (1), 35–46 (in Russian).
2. Brinker T. J., Hekler A., Enk A. H., Berking C., Haferkamp S., Hauschild A., Weichenthal M., Klode J., Schadendorf D., Holland-Letz T., von Kalle C., Fröhling S., Schilling B., Utikal J. S. (2019) Deep neural Networks Are Superior to Dermatologists in Melanoma Image Classification. *European Journal of Cancer*, 119, 11–17. <https://doi.org/10.1016/j.ejca.2019.05.023>.
3. Pham T.-C., Luong C.-M., Hoang V.-D., Doucet A. (2021) AI outperformed Every Dermatologist in Dermoscopic Melanoma Diagnosis, Using an Optimized Deep-CNN Architecture with Custom Mini-Batch Logic and Loss Function. *Scientific Reports*, 11 (1), 17485. <https://doi.org/10.1038/s41598-021-96707-8>.
4. Zhukovets A. G., Trizna N. M., Belotserkovskii I. V., Barkalin V. V., Levchuk V. A., Kovalev V. A., Dolgaya Ya. V. (2015) Expert System for Diagnosing Malignant Skin Tumors. *Vtoraya belorussko-pol'skaya dermatologicheskaya kon-ferentsiya: dermatologiya bez granits: sb. materialov resp. nauch.-prakt. konf., Grodno, 8 maya 2015* [2nd Belarusian-Polish Dermatological Conference: Dermatology without Borders: Collection of Materials of the Republican Scientific and Practical Conference, Grodno, May 8, 2015]. Grodno, 62–66 (in Russian).
5. Smalyuk A. F. (2025) Features of Using TensorFlow.js for Developing Artificial Intelligence Systems. *Biznes. Obrazovanie. Ekonomika: Mezhdunar. nauch.-prakt. konf., Minsk, 4–5 apr. 2024 g.: sb. st.* [Business. Education. Economics: 6th International Scientific and Practical Conference, Minsk, April 3–4, 2025: Collection of Articles]. Minsk, Belarusian State University Institute of Business, 319–322 (in Russian).
6. Smalyuk A. F. (2024) Using Neural Networks in Dermatoscopy Image Analysis Tasks. *Biznes. Obrazovanie. Ekonomika: Mezhdunar. nauch.-prakt. konf., Minsk, 4–5 apr. 2024 g.: sb. st.* [Business. Education. Economics: International Scientific and Practical Conference, Minsk, April 4–5, 2024: Collection of Articles]. Minsk, Belarusian State University Institute of Business, 300–305 (in Russian).
7. Smalyuk A. F., Dzeshka M. S., Kupchykava I. D. (2024) Segmentation of Dermoscopic Images of Skin Lesions. Comparison of Methods. *Sistemny Analiz i Prikladnaya Informatika = System Analysis and Applied Information Science*, (1), 50–58. <https://doi.org/10.21122/2309-4923-2024-1-50-58> (in Russian).
8. Tschandl P., Rosendahl C., Kittler H. (2018) The HAM10000 Dataset, a Large Collection of Multi-Source Dermoscopic Images of Common Pigmented Skin Lesions. *Scientific Data*, 5 (1), 180161. <https://doi.org/10.1038/sdata.2018.161>.
9. Codella N., Rotemberg V., Tschandl P., Celebi M. E., Dusza S., Gutman D., Helba B., Kalloo A., Liopyris K., Marchetti M., Kittler H., Halpern A. (2018) *Skin Lesion Analysis toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (ISIC)*. arXiv preprint. Available at: <https://arxiv.org/abs/1902.03368>. <https://doi.org/10.48550/arXiv.1902.03368>.
10. Szegedy C., Wei Liu, Yangqing Jia, Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. (2015) Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1–9. <https://doi.org/10.1109/cvpr.2015.7298594>.

Received: 09.10.2025

Accepted: 29.12.2025

Published online: 30.01.2026