

Использование методов машинного обучения для повышения диагностики и классификации заболеваний кожи по дерматоскопическим снимкам

В.Г. Ляликова, М.М. Безрядин

Аннотация— Кожные заболевания являются наиболее распространенными во всем мире. В лучшем случае они вызывают физическое недомогание, а в тяжелых случаях приводит и к раку. Дерматоскопические изображения предлагают неинвазивный и экономически эффективный метод исследования кожных аномалий. Модели глубокого обучения показали многообещающие результаты в области компьютерной диагностики путем автоматического извлечения признаков из медицинских изображений. Тем не менее эффективность этих моделей в значительной степени зависит от качества и сбалансированности обучающего набора данных. Данное исследование демонстрирует возможность классификации дерматоскопических изображений кожных новообразований по 8 классам для дальнейшей постановки диагноза. Для решения поставленной задачи использовались предварительно обученные нейронные сети DenseNet201, MobileNetV2 и ResNet50. Набор данных проходил несколько этапов предварительной обработки, включая очистку данных, изменение размера изображений, балансировку классов. Описаны основные параметры архитектуры предложенных нейронных сетей. Проведен сравнительный анализ качества работы разработанных алгоритмов. Результаты исследования показывают, что применение глубоких нейронных сетей позволяет достичь точности 95,5%.

Ключевые слова— классификация изображений, новообразования кожи, сверточные нейронные сети, предобученные нейронные сети, машинное обучение, дерматоскопические изображения, матрица ошибок.

I. ВВЕДЕНИЕ

В последние годы наблюдается значительный рост интереса к применению методов машинного обучения в области дерматологии, особенно в диагностике кожных новообразований. Это обусловлено тем фактом, что злокачественные новообразования кожи занимают одно из ведущих мест в структуре онкологических заболеваний среди мужчин и женщин в Российской Федерации [1]. В общей статистике злокачественные новообразования в России в 2021 году у мужчин злокачественные новообразования составляли 9,8%, а с учетом меланомы кожи — 11,5%. У женщин показатели

соответственно — 13,4% и 15,5% [2]. Меланома кожи остается актуальной и глобальной проблемой в области здравоохранения.

Многочлассовая классификация дерматоскопических снимков представляет собой сложную задачу, требующую высокой точности и надежности моделей для правильной идентификации различных типов кожных образований. Технологии машинного обучения, в частности глубокие нейронные сети, продемонстрировали потенциал в автоматизации процесса диагностики, что способствует ускорению и повышению точности определения заболеваний кожи. В связи с этим обстоятельством актуальной является задача по рассмотрению современных подходов и моделей машинного обучения, которые можно использовать для задачи классификации злокачественных новообразований кожи. Цель исследования — определить наиболее эффективные алгоритмы для автоматической оценки дерматоскопических снимков с целью повышения качества диагностики и поддержки дерматологов в их профессиональной деятельности.

Задача внедрения технологий, которые позволят сократить сроки от подозрения на злокачественные новообразования кожи до постановки окончательного диагноза является очень актуальной.

В рамках, выполняемых на этом направлении исследований создаются новые методы и алгоритмы, предназначенные для решения задач диагностики и обнаружения новообразований кожи.

В [3] рассмотрена задача классификации 80 изображений на категории: обычные родинки, атипичные родинки и меланома. Предлагаемая автоматизированная система раннего выявления рака кожи дерматоскопических изображениях с использованием искусственного интеллекта реализована в среде Matlab. Рассмотрены алгоритмы нейронных сетей и опорных векторов. Показано преимущество использования нейросетевых алгоритмов с точностью 94%. Предлагаемая система ускоряет работу дерматологов и повышает эффективность диагностики.

В [4] рассмотрена задача классификации изображений в 2 категории: доброкачественные и злокачественные образования. Проведён сравнительный анализ

Статья получена 10 апреля 2026.

В.Г. Ляликова – Воронежский государственный университет (email: vikalg@yandex.ru)

М.М. Безрядин – Воронежский государственный университет (email: maickel@yandex.ru)

следующих нейронных сетей: VGG19, DenseNet121, ResNet50, ResNet101. Предложена модель, объединяющая сверточную нейронную сеть и алгоритм опорных векторов, достигающая точности классификации 99%. В рамках данного исследования использовалась модель сверточной нейронной сети (SLC-CNN) для извлечения признаков рака кожи, которая применялась как для выполнения классификации с помощью метода SVM, так и для сегментации с использованием XGBoost.

Ряд значимых результатов в области нейронных сетей благодаря росту вычислительных возможностей компьютеров, привел к значительному росту использования таких типов сетей как сверточные сети и сети глубокого обучения [5]. Эти методы демонстрируют высокие результаты при анализе и классификации новообразований кожи. Например, в работе [6] с использованием усовершенствованной архитектуры сверточной сети удалось добиться точности 97% при классификации в 2-х классах. В аналогичных исследованиях различные модели архитектур сверточных нейронных сетей позволяют добиться точности классификации для 2-х-3-х классов в диапазоне от 90% до 95% [7-11].

В некоторых исследованиях [12-13] сравнивалась диагностическая эффективность с использованием моделей искусственного интеллекта на основе оценок дерматологов. Использовались тестовый набор из 100 изображений. Независимо от опыта врачей, большинство дерматологов отдавало предпочтение методам искусственного интеллекта.

В [14] рассмотрена задача многоклассовой классификации изображений на 8 категорий. Проведен сравнительный анализ сверточных нейронных сетей и сетей трансформеров. Данные о производительности различных архитектур нейронных сетей, которые использовались для классификации дерматоскопических изображений, разделённых на 8 категорий, всё еще не давали достаточно высокие результаты. С использованием модели ResNet152 было получено максимальное значение метрики F1, равное 0,69. Однако, при этом данная модель демонстрировала оптимальный баланс между точностью (Precision) и полнотой (Recall), даже при ограниченном числе обучающих эпох. С другой стороны, с использованием модели на базе Vision Transformers (ViT), такие как google/vitbase-patch16-224, показывали высокие показатели точности в районе 0,86. Однако значения метрики F1 были ниже, что указывает на меньшую гармонию между точностью и полнотой. Средний показатель F1 по всем моделям составляет 0,63. В дальнейшем авторы планировали проведение экспериментов по бинарной классификации кожных поражений для углубления исследования.

В [15] рассмотрена классификация изображений кожных образований на 8 классов, полученная с помощью аппарата сверточных искусственных нейронных сетей. Был выполнен анализ производительности модели при использовании различных конфигураций архитектуры. Наилучшие показатели продемонстрировала восьмислойная

структура сети, достигающая точности классификации 77%

В [16-17] рассмотрены вопросы применения методов глубокого ансамблевого обучения на основе нейронных сетей для решения задачи классификации медицинских изображений. Результаты показали, что стекирование обеспечивает прирост производительности критерия F1 до 13%. Бэггинг продемонстрировал возможность стабильного улучшения F1 до 11%. Таким образом показано, что для классификации медицинских изображений большего прироста производительности позволяет достичь стекирование. А аугментация данных показала стабильные возможности улучшения на моделях без переобучения.

Исходя из представленных выше результатов исследований можно сделать вывод о том, что в настоящее время область автоматизированного анализа медицинских изображений переживает быстрый рост. Однако остаются актуальными вопросы, связанные с ограниченностью данных, недостаточной эффективностью процесса обучения и ограниченными возможностями моделей. В связи с этим обстоятельством задача определения кожных новообразований для раннего обнаружения рака продолжает оставаться важной.

II. ПОСТАНОВКА ЗАДАЧИ

В работе рассматривается задача по автоматической классификации медицинских изображений для диагностирования злокачественных образований кожи. Был выбран набор данных ISIC [18], который содержит 2357 изображений злокачественных и доброкачественных онкологических заболеваний, разделенных на 8 категорий (по типу происхождения кожного образования). Имеются следующие категории заболеваний:

- старческий кератоз (actinic keratosis, AK)
- базально-клеточная карцинома (basal cell carcinoma, BCC)
- фиброма кожи (dermatofibroma, DF)
- меланома (melanoma, M)
- родинка (nevus, NV)
- пигментный доброкачественный кератоз (pigmented benign keratosis, PBK)
- себорейный кератоз (seborrheic keratosis, SK)
- плоскоклеточный рак (squamous cell carcinoma, SCC)
- сосудистое поражение (vascular lesion, VL)




Рис. 1: Примеры изображений

Набор данных обладает некоторыми недостатками, которые заключаются в том, что имеется ограниченное количество изображений в некоторых классах и несбалансированное количество изображений в разных классах, что может затруднять корректную классификацию классификатором. Некоторые примеры изображений представлены на рисунке 1.

III. МЕТОДЫ ИССЛЕДОВАНИЙ И ПОСТРОЕНИЕ МОДЕЛЕЙ

С учетом изложенного выше, поставленная задача в общей постановке формулируется как задача многоклассовой классификации изображений для выявления кожных новообразований. Общая схема процесса классификации представлена на рисунке 2 и включает такие этапы, как первоначальная обработка изображений, использование методов аугментации данных и применение различных подходов к классификации.



Рис. 2: Классификации изображений

- Предварительная обработка – это преобразование изображения в более подходящую и удобную для использования форму. Оно включает в себя изменение размера изображений и перевод в тензоры с плавающей точкой, а затем нормализация из интервала от 0 до 255 к интервалу от 0 до 1.
- Аугментация данных – это искусственное расширение набора за счет смещения, поворота, увеличения т.д. изображений. С этой целью использовались случайные повороты, смещение изображений и по ширине и высоте, увеличение изображений, отзеркаливание по горизонтальной оси, сдвиг по часовой и против часовой стрелки.
- В ходе предварительных экспериментов были выбраны наиболее оптимальные архитектуры сверточных нейронных сетей для решения задачи классификации изображений, такие как DenseNet201, ResNet50, MobileNetV2. фиброма кожи (dermatofibroma, DF)

Для оценки точности в процессе контроля качества разрабатываемой модели, использовались метрики точности (precision), коэффициент детерминации R2, матрица ошибок. Коэффициент R2 показывает насколько хорошо модель описывает изменения в наблюдаемых данных. Матрица ошибок является одним из самых развернутых способов оценки качества в задаче многоклассовой классификации

Для обучения моделей использовался набор из 10240 размеченных файлов изображений с разными категориями новообразования, для тестирования 3200 файлов, для валидации 2560 файлов. Изображения представляли собой 8-битные цветные RGB-изображения с базовым разрешением 600x450 пикселей. Это достаточно большое разрешение, поэтому проводилось предварительное уменьшение разрешения изображений.

Предобученные модели нейронных сетей имели одинаковую структуру. Загружалась версия сети с размером входного изображения (96x96x3 для сетей ResNet51 и MobileNetV2, 75x100x3 для сети DenseNet201) с весами imagenet. Возможность изменения значений переменных предобученной модели блокировалась, обучался только последний слой. Добавлялся слой Dropout (чтобы избежать переобучения сети) и обычный слой с 512 нейронами, затем последний слой классификации, с количеством нейронов равных количеству необходимых классов и активационной функцией softmax. В процессе обучения применялся стохастический градиентный спуск с шагом 0.001.

Так как процесс обучения занимает значительное время, требуется выбрать оптимальное количество эпох. При этом была использована функция ReduceLROnPlateau, которая автоматически уменьшает шаг обучения при стагнации качества предсказания сети.

После выполнения процесса предварительной обработки изображений, моделирование состояло из разделения данных на обучающую и тестовую выборки; процесса выбора архитектуры модели; настройки ее параметров на обучающем наборе, а также в использовании обученной сети для классификации кожных новообразований из тестовых данных и оценки ее эффективности с помощью ранее указанных метрик. Иллюстрация архитектуры и функционирования нейросетевых моделей приведена на рисунке 3:



Рис. 3: Архитектура моделей

Общее количество изображений для каждого класса после процесса аугментации данных для последующего обучения и тестирования, а также количество настраиваемых параметров для каждой нейронных сети приведено в таблице 1.

Таблица 1: Количество настраиваемых параметров

Нейронная сеть	Количество изображений	Размер изображения	Количество обучаемых параметров
DenseNet201	20000	75x100x3	23 995 784
MobileNetV2	20000	96x96x3	8 126 728
ResNet50	20000	96x96x3	32 976 905

Процесс обучения моделей представлен на рисунке 4. На данных изображениях представлены два графика, демонстрирующих показатели точности и потерь при классификации модели на тестовой и обучающей выборках на каждом этапе обучения.




Рис. 4: Процесс обучения для нейронной сетей
а) DenseNet201, б) MobileNetV2, в) ResNet50

IV. ВЫЧИСЛИТЕЛЬНЫЙ ЭКСПЕРИМЕНТ

После обучения моделей получены результаты работы алгоритмов на тестовом наборе данных, которые приведены в таблице 2.

Таблица 2: Результаты работы

Алгоритм	Precision	R2
DenseNet201	0.955	0.893
MobileNetV2	0.920	0.853
ResNet50	0.898	0.796

Видим, что наиболее высокий процент обнаружения, а также и коэффициент детерминации R2 у нейронной сети DenseNet201, чем у сетей MobileNetV2 и ResNet50. Самые низкие показатели обнаружения показывает сеть ResNet50.

Матрица ошибок для каждой модели приведена на рисунке 5.

Можно отметить, что все нейросетевые алгоритмы сталкиваются с определёнными трудностями при классификации изображений Nevus и Actinic keratosis. В этом отношении лучше всего справляется нейронная сеть MobileNetV2, именно по распределению изображений по классам. Также наблюдаются некоторые сложности при определении новообразований, относящихся к классу меланомы. Следует обратить внимание, что у модели ResNet50 зафиксированы самые высокие ошибки при различении различных заболеваний. Можно предположить, что дальнейшая работа с расширением и уточнением набора данных поможет устранить эти проблемы.




Рис. 5: Матрица ошибок для нейронных сетей а) DenseNet201, б) MobileNetV2, в) Resnet50, которые представляют прогнозируемые значения для восьми классов

V. ЗАКЛЮЧЕНИЕ

Данная работа посвящена созданию метода автоматической классификации кожных новообразований по 8 классам, включающим как доброкачественные, так и злокачественные образования. В качестве базовых для решения задачи были использованы различные нейросетевые модели, такие как DenseNet201, MobileNetV2 и ResNet50. Все выбранные архитектуры показывают достаточно хорошие результаты в распознавании кожных новообразований, при этом максимальная точность на тестовом наборе данных достигла 95,5%.

Предполагается, что повышения точности используемых нейросетевых моделей можно добиться за счет их интеграции с другими архитектурами глубокого обучения. Кроме того, предполагается, что расширение набора данных, использование методов устранения дисбаланса классов и внедрение дополнительных техник по работе обработке изображений могут способствовать разработке более точных классификационных алгоритмов.

БИБЛИОГРАФИЯ

- [1] Сиводедова Н.А., Карякин Н.Н., Шлишко И.Л. Современные методы выявления злокачественных новообразований кожи, включая использование мобильных приложений и искусственного интеллекта: обзор литературы // Медицинская информатика: теория и практика, ОРГЗДРАВ: новости, мнения, обучение. Вестник ВШОУЗ. Том 10, № 2, 2024, с. 78-93, Сиводедова Н.А., Карякин Н.Н., Шлишко И.Л.
- [2] Чеботарев В.В., Хисматуллина З.Р., Закирова Ю.А. Некоторые аспекты эпидемиологии и диагностики злокачественных новообразований кожи // Креативная хирургия и онкология. 2020. Т. 10, № 1. С. 65–73
- [3] Злокачественные новообразования в России в 2021 году (заболеваемость и смертность) : сборник / под ред. А.Д. Каприна, В.В. Старинского, А.О. Шахзадовой. Москва : МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России, 2022. 252 с

- [4] Mahmoud, Nourelhoda & Soliman, Ahmed. (2024). Early automated detection system for skin cancer diagnosis using artificial intelligent techniques. *Scientific Reports*. 14. 10.1038/s41598-024-59783-0.
- [5] Sara, Umme & Das, Utpol & Sikder, Juel & Chowdhury, Sudipta. (2025). Automated Skin Cancer Classification and Detection Using Convolutional Neural Networks and Dermoscopy Images. *Procedia Computer Science*. 252. 108-117. 10.1016/j.procs.2024.12.012.
- [6] Philip, Felix & Ajesh, F. & Izdrui, Diana & Craciun, Maria-Daniela & Geman, Oana. (2022). Automated Detection of Nonmelanoma Skin Cancer Based on Deep Convolutional Neural Network. *Journal of Healthcare Engineering*. 2022. 1-15. 10.1155/2022/6952304.
- [7] Zhang, Long & Gao, Hong & Zhang, Jianhua & Badami, Benjamin. (2020). Optimization of the Convolutional Neural Networks for Automatic Detection of Skin Cancer. *Open Medicine*. 15. 27-37. 10.1515/med-2020-0006.
- [8] Öztürk, Şaban & Özkaya, Umut. (2020). Skin Lesion Segmentation with Improved Convolutional Neural Network. *Journal of Digital Imaging*. 33. 958-970. 10.1007/s10278-020-00343-z.
- [9] Yang, Cheng-Hong & Ren, Jai-Hong & Huang, Hsiu-Chen & Chuang, Li-Yeh & Chang, Po-Yin. (2021). Deep Hybrid Convolutional Neural Network for Segmentation of Melanoma Skin Lesion. *Computational Intelligence and Neuroscience*. 2021. 1-15. 10.1155/2021/9409508.
- [10] Sikandar, Shahbaz & Mahum, Rabbia & Ragab, Adham & Yildirim Yayilgan, Sule & Shaikh, Sarang. (2023). SCDet: A Robust Approach for the Detection of Skin Lesions. *Diagnostics*. 13. 10.3390/diagnostics13111824.
- [11] Afza, Farhat & Sharif, Muhammad & Khan, M. & Tariq, Usman & Yong, Hwan-Seung & Cha, Jaehyuk. (2022). Multiclass Skin Lesion Classification Using Hybrid Deep Features Selection and Extreme Learning Machine. *Sensors*. 22. 10.3390/s22030799.
- [12] Haenssle, Holger & Fink, Christine & Schneiderbauer, R & Toberer, Ferdinand & Buhl, Timo & Blum, A & Kalloo, A & Hassen, A & Thomas, Luc & Enk, A & Uhlmann, Lorenz. (2018). Man against Machine: Diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Annals of oncology : official journal of the European Society for Medical Oncology*. 29. 10.1093/annonc/mdy166.
- [13] Marchetti, Michael & Codella, Noel & Dusza, Stephen & Gutman, David & Helba, Brian & Kalloo, Aadi & Mishra, Nabin Kumar & Carrera, Cristina & Celebi, M. Emre & DeFazio, Jennifer & Jaimes, Natalia & Marghoob, Ashfaq & Quigley, Elizabeth & Scope, Alon & Yélamos, Oriol & Halpern, Allan. (2017). Results of the 2016 International Skin Imaging Collaboration International Symposium on Biomedical Imaging challenge: Comparison of the accuracy of computer algorithms to dermatologists for the diagnosis of melanoma from dermoscopic images. *Journal of the American Academy of Dermatology*. 78. 10.1016/j.jaad.2017.08.016.
- [14] Козачок А.В., Спирин А.А., Самоваров О.И., Козачок Е.С. Применение моделей машинного обучения для многоклассовой классификации дерматоскопических снимков новообразований кожи. *Труды Института системного программирования РАН*. 2024;36(5):241-252.
- [15] Михайлузов А. В. Использование сверточных нейронных сетей для диагностики рака кожи // *Вестник ВГТУ*. 2023, с.20-26
- [16] Iqbal, Talib & Wani, M.. (2023). Weighted ensemble model for image classification. *International Journal of Information Technology*. 15. 10.1007/s41870-022-01149-8.
- [17] Müller, Dominik & Soto-Rey, Iñaki & Kramer, Frank. (2022). An Analysis on Ensemble Learning optimized Medical Image Classification with Deep Convolutional Neural Networks. 10.48550/arXiv.2201.11440.
- [18] Skin Cancer ISIC. The skin cancer data Режим доступа - <https://www.kaggle.com/datasets/nodoubttome/skin-cancer9-classesisic> (дата обращения 15.11.2024).

Using Machine Learning Methods to Improve the Diagnosis and Classification of Skin Diseases from Dermatoscopic Images

V.G. Lialikova, M.M. Bezriadin

Abstract - Skin diseases are the most common diseases worldwide. At best, they cause physical discomfort, and in severe cases, they can lead to skin cancer. Dermatoscopy images offer a non-invasive and cost-effective method for investigating skin abnormalities. Deep learning models have shown promising results in computer-aided diagnosis by automatically extracting features from medical images. However, the performance of these models largely depends on the quality and balance of the training dataset. This study demonstrates the feasibility of classifying dermatoscopy images of skin lesions into eight classes for diagnosis. Pre-trained neural networks DenseNet201, MobileNetV2, and ResNet50 were used to solve this problem. The dataset underwent several preprocessing steps, including data cleaning, image resizing, and class balancing. The main architectural parameters of the proposed neural networks are described. A comparative analysis of the performance of the developed algorithms is conducted. The results of the study show that the use of deep neural networks allows achieving an accuracy of 95.5%.

Keywords - image classification, skin lesions, convolutional neural networks, pretrained neural networks, machine learning.

REFERENCES

- [1]Sivodedova N.A., Karyakin N.N., Shlivko I.L. Modern methods for detecting malignant skin neoplasms, including the use of mobile applications and artificial intelligence: a literature review // Medical informatics: theory and practice, ORGZDRAV: news, opinions, training. Bulletin of the Higher School of Medicine and Health. Vol. 10, No. 2, 2024, pp. 78-93.
- [2]Chebotarev V.V., Khismatullina Z.R., Zakirova Yu.A. Some aspects of the epidemiology and diagnostics of malignant skin neoplasms // Creative surgery and oncology. 2020. Vol. 10, No. 1. P. 65–73
- [3]Malignant neoplasms in Russia in 2021 (morbidity and mortality): collection / edited by A.D. Kaprin, V.V. Starinsky, A.O. Shakhzadova. Moscow: P.A. Herzen Medical Research Institute of Oncology – branch of the National Medical Research Center of Radiology of the Ministry of Health of the Russian Federation, 2022. 252 p.
- [4]Mahmoud, Nourelhoda & Soliman, Ahmed. (2024). Early automated detection system for skin cancer diagnosis using artificial intelligent techniques. Scientific Reports. 14. 10.1038/s41598-024-59783-0.
- [5]Sara, Umme & Das, Utpol & Sikder, Juel & Chowdhury, Sudipta. (2025). Automated Skin Cancer Classification and Detection Using Convolutional Neural Networks and Dermoscopy Images. Procedia Computer Science. 252. 108-117. 10.1016/j.procs.2024.12.012.
- [6]Philip, Felix & Ajesh, F. & Izdrui, Diana & Craciun, Maria-Daniela & Geman, Oana. (2022). Automated Detection of Nonmelanoma Skin Cancer Based on Deep Convolutional Neural Network. Journal of Healthcare Engineering. 2022. 1-15. 10.1155/2022/6952304.
- [7]Zhang, Long & Gao, Hong & Zhang, Jianhua & Badami, Benjamin. (2020). Optimization of the Convolutional Neural Networks for Automatic Detection of Skin Cancer. Open Medicine. 15. 27-37. 10.1515/med-2020-0006.
- [8]Öztürk, Şaban & Özkaya, Umut. (2020). Skin Lesion Segmentation with Improved Convolutional Neural Network. Journal of Digital Imaging. 33. 958-970. 10.1007/s10278-020-00343-z.
- [9]Yang, Cheng-Hong & Ren, Jai-Hong & Huang, Hsiu-Chen & Chuang, Li-Yeh & Chang, Po-Yin. (2021). Deep Hybrid Convolutional Neural Network for Segmentation of Melanoma Skin Lesion. Computational Intelligence and Neuroscience. 2021. 1-15. 10.1155/2021/9409508.
- [10] Sikandar, Shahbaz & Mahum, Rabbia & Ragab, Adham & Yildirim Yayilgan, Sule & Shaikh, Sarang. (2023). SCDet: A Robust Approach for the Detection of Skin Lesions. Diagnostics. 13. 10.3390/diagnostics13111824.
- [11] Afza, Farhat & Sharif, Muhammad & Khan, M. & Tariq, Usman & Yong, Hwan-Seung & Cha, Jaehyuk. (2022). Multiclass Skin Lesion Classification Using Hybrid Deep Features Selection and Extreme Learning Machine. Sensors. 22. 10.3390/s22030799.
- [12] Haenssle, Holger & Fink, Christine & Schneiderbauer, R & Toberer, Ferdinand & Buhl, Timo & Blum, A & Kalloo, A & Hassen, A & Thomas, Luc & Enk, A & Uhlmann, Lorenz. (2018). Man against Machine: Diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. Annals of oncology : official journal of the European Society for Medical Oncology. 29. 10.1093/annonc/mdy166.
- [13] Marchetti, Michael & Codella, Noel & Dusza, Stephen & Gutman, David & Helba, Brian & Kalloo, Aadi & Mishra, Nabin Kumar & Carrera, Cristina & Celebi, M. Emre & DeFazio, Jennifer & Jaimes, Natalia & Marghoob, Ashfaq & Quigley, Elizabeth & Scope, Alon & Yélamos, Oriol & Halpern, Allan. (2017). Results of the 2016 International Skin Imaging Collaboration International Symposium on Biomedical Imaging challenge: Comparison of the accuracy of computer algorithms to dermatologists for the diagnosis of melanoma from dermoscopic images. Journal of the American Academy of Dermatology. 78. 10.1016/j.jaad.2017.08.016.
- [14] Kozachok A.V., Spirin A.A., Samovarov O.I., Kozachok E.S. Application of machine learning models for multi-class classification of dermatoscopic images of skin neoplasms. Proceedings of the Institute for System Programming of the Russian Academy of Sciences. 2024;36(5):241-252.
- [15] Mikhailusov A. V. Using convolutional neural networks for skin cancer diagnostics // VSTU Bulletin. 2023, pp. 20-26.
- [16] Iqbal, Talib & Wani, M. (2023). Weighted ensemble model for image classification. International Journal of Information Technology. 15. 10.1007/s41870-022-01149-8.
- [17] Müller, Dominik & Soto-Rey, Iñaki & Kramer, Frank. (2022). An Analysis on Ensemble Learning optimized Medical Image Classification with Deep Convolutional Neural Networks. 10.48550/arXiv.2201.11440.
- [18] Skin Cancer ISIC. The skin cancer data Режим доступа - <https://www.kaggle.com/datasets/nodoubttome/skin-cancer9-classesisic>