

ГИБРИДНАЯ МУЛЬТИКЛАССОВАЯ КЛАССИФИКАЦИЯ ДЕРМАТОСКОПИЧЕСКИХ ИЗОБРАЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Е.С. Парфенова¹, И.А. Матвеева¹

¹Самарский университет, г. Самара
e-mail: katya.parfenova.2005@yandex.ru

Аннотация

В работе исследуется гибридный подход к мультиклассовой классификации дерматоскопических изображений, объединяющий ручные признаки ABCD и признаки, извлекаемые свёрточной нейронной сетью.

Ключевые слова: дерматоскопия, мультиклассовая классификация, свёрточные нейронные сети, гибридные модели, машинное обучение.

Введение

Рост заболеваемости и смертности от злокачественных новообразований кожи делает особенно важным развитие методов ранней диагностики. Дерматоскопия является доступным неинвазивным методом скрининга, однако визуальная интерпретация зависит от квалификации врача и остается субъективной. Поэтому актуально применение методов искусственного интеллекта и компьютерного зрения для автоматизации анализа и повышения его точности. В исследовании рассматривается задача мультиклассовой классификации дерматоскопических изображений с использованием открытого датасета HAM10000 [1] и клинического датасета СОКОД, полученного в Самарском областном клиническом онкологическом диспансере.

1. Автоматическое извлечение дерматоскопических признаков ABCD

Анализ дерматоскопических изображений основывается на правиле ABCD (Asymmetry, Border, Color, Dermoscopic structures) [2]. В рамках исследования был разработан программный модуль автоматического извлечения признаков ABCD и расчёта суммарного балла TDS. Асимметрия (A) оценивалась сравнением половин изображения относительно двух взаимно перпендикулярных осей. Для оценки границы (B) изображение разделялось на восемь секторов, в каждом анализировались четкость и регулярность контура. Балл цвета (C) включал наличие типичных для пигментных поражений цветов. Дерматоскопические структуры (D) оценивались путём детектирования границ оператором Кэнни и круглых элементов преобразованием Хафа, анализом однородности яркости, скелетизации для выявления ветвлений. На основе этого модуля был сформирован табличный датасет, где каждому изображению сопоставлялся вектор признаков ABCD, TDS и метка класса. Дополнительно для изображений из датасета СОКОД, которые были затемнены и имели выраженный зелёный оттенок, была применена цветокоррекция путём приведения гистограмм исходного изображения к средней гистограмме учебного датасета HAM10000. На

рисунке 1 представлен результат работы автоматизированного ABCD алгоритма с вычисленными признаками на маске образования.




Рисунок 1 – Результат автоматизированного ABCD алгоритма

2. Гибридная классификация на основе ABCD и CNN

Обучение стандартных моделей машинного обучения (логистическая регрессия, метод опорных векторов (SVM), метод k ближайших соседей (kNN), деревья решений, случайный лес, многослойный перцептрон (MLP)) на признаках ABCD показало низкое качество мультиклассовой классификации ($\text{macro-F1} \approx 0,25$), что связано с перекрытием признаков между различными нозологиями и ограниченной применимостью правила ABCD, изначально созданного для различения доброкачественных и злокачественных новообразований. Поэтому был выбран гибридный подход к мультиклассовой классификации, сочетающий ручные дерматоскопические признаки ABCD с признаками, автоматически извлекаемыми свёрточными нейронными сетями (CNN). Подобный подход применяется в работе Almaraz-Damian et al. [3], где разработан САД-алгоритм для диагностики меланом и невусов, в которой признаки, связанные с правилом ABCD, объединяются с глубокими признаками CNN, а наиболее информативные компоненты отбираются с помощью меры взаимной информации. В работе Zahid et al. [4] комбинируются дескрипторы HOG для границ и текстур с признаками глубоких нейронных сетей для мультиклассовой классификации. В работе Moura et al. [5] предложен метод, совмещающий ручные оцениваемые признаки ABCD с признаками предобученных CNN для диагностики меланомы.

В качестве свёрточных нейронных сетей для извлечения глубоких признаков изображения использовались модели DenseNet, MobileNet, ResNet и EfficientNet, предварительно обученные на ImageNet и затем дообученные на датасетах HAM10000 и СОКОД для задачи мультиклассовой классификации. В гибридном подходе ручные дерматоскопические признаки ABCD объединялись с признаками CNN тремя способами: с вектором предпоследнего слоя CNN (embeddings – высокоуровневое представление изображения), с вероятностями принадлежности к классам (probabilities – выход softmax), с логитами (logits – выход до softmax). На объединённых признаках обучались классификаторы SVM и MLP. Качество моделей оценивалось по метрикам

ассурасу и макро-F1. Выбор макро-F1 обусловлен несбалансированностью классов и необходимостью одинаково учитывать качество распознавания каждого из них. Лучшие результаты гибридизации для каждой модели и изменение значений метрик по сравнению с вариантом без ручных признаков представлены в таблице 1.

Таблица 1 – Метрики, полученные в результате классификации

Модель	Лучший гибрид	Accuracy	Macro-F1	Δ Accuracy	Δ Macro -F1
DenseNet	ABCD + Embedding + MLP	0,8369	0,7136	+0,0064	+0,0102
MobileNet	ABCD + Logits + MLP	0,8428	0,7163	+0,0279	+0,0212
ResNet	ABCD + Prob + MLP	0,8203	0,6997	+0,0054	+0,0046
EfficientNet	ABCD + Logits + MLP	0,8509	0,7339	+0	+0,0185

Проведённые эксперименты показали, что гибридный подход в большинстве случаев даёт прирост качества на 1-2%. Модели MobileNet и EfficientNet имеют наилучшие значения ассурасу и наибольший прирост по метрике макро-F1, при этом они являются наиболее легковесными и оптимизированными для работы на устройствах с ограниченными ресурсами. Это важно для практического применения, так как вычислительные возможности оборудования в клиниках могут существенно различаться.

Заключение

В работе реализованы алгоритм цветокоррекции клинического датасета СОКОД на основе сопоставления гистограмм, программный модуль автоматического извлечения дерматоскопических признаков ABCD и расчёта балла TDS, а также построены различные модели мультиклассовой классификации дерматоскопических изображений. Гибридный подход к мультиклассовой классификации дерматоскопических изображений, объединяющий классические методы диагностики и возможности глубокого обучения, обеспечивает прирост метрик качества на 1-2% относительно моделей, использующих только свёрточные нейронные сети. Эффективность гибридизации для легковесных моделей, таких как MobileNet и EfficientNet, указывает на возможность создания доступных систем диагностики в медицинских учреждениях с ограниченными вычислительными ресурсами. Таким образом, предложенный подход представляет собой перспективный инструмент поддержки принятия врачебных решений при скрининге новообразований кожи.

Список использованных источников

1. Skin Cancer MNIST: HAM10000. – URL: <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000> (дата обращения: 24.03.2026).
2. Early diagnosis of cutaneous melanoma: revisiting the ABCD criteria / N. R. Abbasi, H. M. Shaw, D. S. Rigel [et al.] // Jama. – 2004. – V. 292, № 22. – P. 2771–2776.

3. Melanoma and Nevus Skin Lesion Classification Using Handcraft and Deep Learning Feature Fusion via Mutual Information Measures / J.A. Almaraz-Damian, V. Ponomaryov, S. Sadovnychiy, H. Castillejos-Fernandez // Entropy. – 2022. – V. 22, № 4. – P. 484.

4. Zahid, M. Skin Lesion Classification Using Hybrid Feature Extraction Based on Classical and Deep Learning Methods / M. Zahid, M. Rziza, R. Alaoui // BioMedInformatics. – 2025. – V. 5, № 3. – P. 41.

5. ABCD rule and pre-trained CNNs for melanoma diagnosis / N. Moura, R. Veras, K. Aires [et al.] // Multimedia Tools and Applications. – 2019. – V. 78. – P. 6869–6888.

HYBRID MULTICLASS CLASSIFICATION OF DERMATOSCOPIC IMAGES USING CONVOLUTIONAL NEURAL NETWORKS

E.S. Parfenova¹, I.A. Matveeva¹

¹*Samara University, Samara*
e-mail: katya.parfenova.2005@yandex.ru

Abstract

This paper explores a hybrid approach to multiclass classification of dermoscopic images, combining handcrafted ABCD features with features extracted by a convolutional neural network.

Keywords: dermoscopy, multiclass classification, convolutional neural networks, hybrid models, machine learning.