

УДК 615.478.6

DOI: 10.22213/2410-9304-2024-3-10-16

Автоматизированная диагностика меланомы на основе алгоритма Штольца

Т. А. Коробкова, аспирант, Самарский национальный исследовательский университет имени академика С. П. Королева; СамГМУ Минздрава России, Самара, Россия

В статье рассматривается алгоритм автоматизации диагностирования меланомы с помощью компьютерного зрения и нейронного классификатора. Целью исследования является разработка алгоритма для эффективной классификации меланомы на изображениях, а также влияние дерматоскопических признаков на постановку диагноза. Выделены новообразования на изображениях. Проведен расчет параметров для формулы Штольца и расчет TDS (вычисление диагноза). На основе произведенных расчетов решена задача оптимизации для уточнения границ областей дифференциации новообразований и корректировки коэффициентов формулы Штольца и сгенерирован набор для обучения нейронной сети, в качестве классификатора выбран MLP. Средняя точность алгоритма на двух независимых наборах данных составляет 86 %. Дана классификация нейронной сетью двух наборов изображений по параметрам Штольца. По результатам поставлен диагноз. На основе алгоритма Штольца набор изображений с новообразованиями кожного покрова предварительно обрабатывается: новообразование выделяется, по изображению рассчитываются признаки ABCD и общий дерматоскопический балл. Предложенный алгоритм автоматизированной диагностики меланомы на основе дерматоскопического метода Штольца показал хорошие результаты на реальных наборах изображений. Пониженная точность модели на наборе HAM10000 обусловлена несбалансированностью классов (соотношение классов 1 к 9). Высокое значение F-меры указало на хороший баланс между чувствительностью и специфичностью модели, модель склонна лучше обнаруживать меланомы – истинно положительные случаи (TP). Высокая чувствительность является желательной в задачах, где снижение ложноположительных результатов (пропущенных положительных случаев) критически важно, даже за счет увеличения числа ошибок первого рода. Полнота модели составила 88,54 и 95 % и говорит о том, что в модели минимизированы случаи пропусков заболевания. Сделан вывод, что чем точнее будут рассчитаны параметры ABCD, тем точнее модель сможет классифицировать заболевание, в перспективе уточнение и разбиение параметра D на несколько составляющих может дать модели дополнительные признаки для классификации.

Ключевые слова: меланома, алгоритм Штольца, компьютерное зрение в медицине, многослойный персептрон, диагностика кожных новообразований, правило ABCD.

Введение

Раннее обнаружение играет ключевую роль в выявлении рака кожного покрова и других злокачественных заболеваний кожи. Своевременное предупреждение и выявление этих заболеваний на начальных стадиях существенно повышает шансы на успешное лечение и благоприятный исход [1, 2].

Регулярные осмотры кожи для выявления новых или измененных образований являются важным способом диагностики рака кожи на ранних стадиях [3]. Поскольку рак кожи иногда проявляется через появление новых родимых пятен, изменения в уже существующих родимых пятнах или язвах, проведение периодических осмотров помогает обнаружить любые подозрительные изменения [4].

Существует широко используемое правило ABCD для диагностики меланомы, предложенное Р. Фридманом в 1985 году. Оно оценивает пигментные образования кожи по четырем параметрам:

асимметрия (A), неровные границы (B), неравномерность окраски (C) и диаметр более 6 мм (D) [5, 6]. С 1999 года это правило было дополнено критерием E, который позволяет отслеживать динамику изменений в пигментных образованиях у лиц с повышенным риском. В 1994 году Вильгельмом Штольцем и его коллегами разработан дерматоскопический алгоритм для диагностики меланомы кожи на основе правила ABCD (ABCDRule [Stolzetal. EurJ Dermatol 1994]. URL: <https://dermoscopy.org/consensus/2b.asp> (дата обращения: 22.11.2023)). Они провели анализ 31 дерматоскопического критерия при изучении 157 образований кожи, доброкачественных и злокачественных. Каждому признаку (асимметрия, границы, цвет, структуры) были присвоены баллы, умноженные на коэффициенты веса для точного оценивания признаков [7–10].

Описание дерматоскопического алгоритма Штольца приведено в табл. 1 [11].

Таблица 1. Дерматоскопическое правило ABCD W. Stolz, 1994

Table 1. Dermoscopic rule ABCD W. Stolz, 1994

Признак	Оценка	Баллы	Весовой коэффициент	Диапазон подсчета
A – асимметрия	Отсутствие асимметрии (0), асимметрия по одной (1) оси или по двум (2) осям Учитываются цвет, очертания, и наличие различных структур	0–2	1,3	0–2,6
B – границы	Пигментное образование делится на 8 равных частей, подсчитывается число сегментов с резким обрывом пигментных структур (от 0 до 8)	0–8	0,1	0–0,8

Окончание табл. 1

Признак	Оценка	Баллы	Весовой коэффициент	Диапазон подсчета
C – распределение цвета	Количество цветов (белый, красный, светло-коричневый, темно-коричневый, голубой / серый, черный)	1–6	0,5	0,5–3,0
D – дерматоскопические структуры	Пигментная сеть, глобулы, точки, бесструктурная зона / бело-голубая вуаль, псевдоподии	1–5	0,5	0,5–2,5

При суммировании произведения факторов веса и относительных единиц каждого признака можно определить общее количество баллов (TDS – total dermoscoryscore):

$$TDS = (A*1.3) + (B*0.1) + (C*0.5) + (D*0.5).$$

Интерпретация полученного значения приведена в табл. 2.

Таблица 2. Интерпретация значения общего дерматоскопического балла

Table 2. Interpretation of the total dermoscoryscore

Общий дерматоскопический балл (TDS)	Интерпретация
<4,75	Доброкачественные меланоцитарные новообразования
4,75–5,45	Подозрительные новообразования, рекомендуется пристальное наблюдение или удаление
>5,45	Новообразования с высоким подозрением на меланому
Ложноположительный балл (>5,45) иногда наблюдается при:	<ul style="list-style-type: none"> • невусах Рида и Шпитца; • невусах Кларка с присутствием глобул; • врожденных меланоцитарных невусах

Цель и дизайн исследования

Целью исследования является разработка алгоритма для эффективной классификации меланомы на изображениях, а также влияние дерматоскопических признаков на постановку диагноза.

Исследование включает в себя следующие этапы:

- выделение новообразования на изображении;
- расчет параметров для формулы Штольца [12];
- расчет TDS (вычисление диагноза);
- решение задачи оптимизации для уточнения границ областей дифференциации новообразований и корректировка коэффициентов формулы Штольца;
- генерация сбалансированного набора для обучения нейронной сети [13];
- классификация нейронной сетью двух наборов изображений по параметрам Штольца [14];
- постановка диагноза.

Данные для исследования

Все операции по работе с изображениями реализованы с помощью алгоритмов компьютерного зрения и библиотеки с открытым исходным кодом OpenCV (OpenCV. URL: <https://opencv.org> (дата обращения: 02.02.2023)) [15].

Набор данных для разработки и апробации предлагаемых методов состоит из 127 фотографий (62 изображения меланомы, 65 – доброкачественные новообразования), сделанных в ГБУЗ «Самарский областной клинический онкологический диспансер» (далее – СамараОнко), и набора The Human Against Machine with 10000 training images (HAM10000), включающего в себя 10015 изображений (меланома – 1113 изображений, другие заболевания – 8902 изображения) [16].

Выделение новообразований на изображениях

К каждому изображению из наборов применялись поочередно 12 предложенных методов с перебором порогового значения от 10 до 180 с шагом 10. Целью проведенной работы было максимально точное выделение объекта-новообразования для дальнейшего исследования (табл. 3).

1. Выделение контура новообразования из исходного изображения по пороговому значению.

2. Выделение контура новообразования из исходного изображения методом Canny (при пороговых значениях $minVal=80, maxVal=200$) [17].

3. Удаление фона изображения с помощью морфологических операций дилатации и эрозии, выделение контура по пороговому значению.

4. Удаление фона изображения с помощью морфологических операций дилатации и эрозии, выделение контура методом Canny.

5. Цветовая сегментация с применением морфологических операций (операция закрытия), выделение контура по пороговому значению.

6. Цветовая сегментация с применением морфологических операций (операция закрытия), выделение контура методом Canny.

7. Цветовая сегментация с применением морфологических операций (на основе предположения диапазона оттенков объекта и фона MIN-MAX), выделение контура по пороговому значению.

8. Цветовая сегментация с применением морфологических операций (на основе предположения диапазона оттенков объекта и фона MIN-MAX), выделение контура методом Canny.

9. Применение билатерального фильтра с последующим выделением контура новообразования из исходного изображения по пороговому значению.

10. Применение билатерального фильтра с последующим выделением контура новообразования из исходного изображения методом Canny.

11. Повышение резкости изображения с последующим выделением контура новообразования по пороговому значению.

12. Повышение резкости изображения с последующим выделением контура новообразования методом Canny.

Таблица 3. Результаты работы алгоритма выделения новообразований на изображении

Table 3. Results of the algorithm for identifying tumors in the image

Параметр	НАМ 10000 (ед.)	СамОнко (ед.)
Общее количество изображений в наборе	10015	127
Ошибка выделения на всем наборе изображений (% от общего количества в наборе)	291 (2,9)	3 (2,36)
Ошибка по нозологии меланомы (% от общего количества в наборе)	31 (2,78)	2, (3,2)
Ошибка на наборе доброкачественных новообразований (% от общего количества в наборе)	260 (2,92)	1 (1,5)

В ходе апробации предложенной методики выделения объектов по фото было отбраковано менее 3 % от общего числа изображений по причине несоответствия установленным требованиям. А именно, новообразование на фото было слишком маленьким и занимало менее 5 % площади, либо слишком большим и соприкасалось с границами изображения, либо располагалось не по центру фото, либо небольшое контрастное значение между поверхностью кожи и новообразованием.

Вычисление признаков алгоритма Штольца и расчет TDS

После выделения новообразования на изображении выполнено вычисление признаков и расчет TDS [18–20].

А – асимметрия. Максимальная цена критерия = 2, предполагается отсутствие симметрии по обеим осям. Определение допустимой погрешности, при сравнении площади фрагментов выделенного изображения относительно центра, может быть субъективным и зависит от контекста задачи (рис. 1). Экспериментальным путем установлен порог допустимой погрешности 5 %:

Симметрия относительно оси x :

$$\frac{|AB-DC|}{AB+DC} * 100\% < 5\%. \quad (1)$$

Симметрия относительно оси y :

$$\frac{|AD-BC|}{AD+BC} * 100\% < 5\%. \quad (2)$$

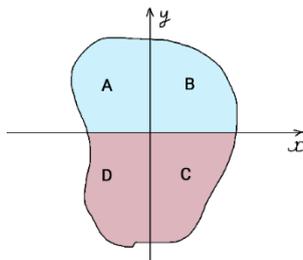


Рис. 1. Расчет симметричности новообразования

Fig. 1. Calculation of the symmetry of the tumor

В – границы. Максимальная цена критерия = 8. Через точки максимума и минимума (x_{\max} , x_{\min} , y_{\max} , y_{\min}) проведем 4 прямые, параллельные осям координат. Точки пересечения этих прямых с осями будут вершинами вписанного в построенный прямоугольник эллипса.

l_d – разница длины контуров рассчитывается как отношение разности длины контура эллипса (l_{el}) и контура выделенного объекта (l_{con}) к длине контура эллипса:

$$l_d = \frac{|l_{el} - l_{con}|}{l_{el}}. \quad (3)$$

Экспериментальным путем (для наборов НАМ1000 и СамараОнко) были получены максимальная ($l_{d\max}$) и минимальная ($l_{d\min}$) разница длины контуров. Полученный диапазон разделим на 8 равных участков, значение l_d будет попадать в один из таких участков, порядковый номер которого будет соответствовать значению критерия В (рис. 2).

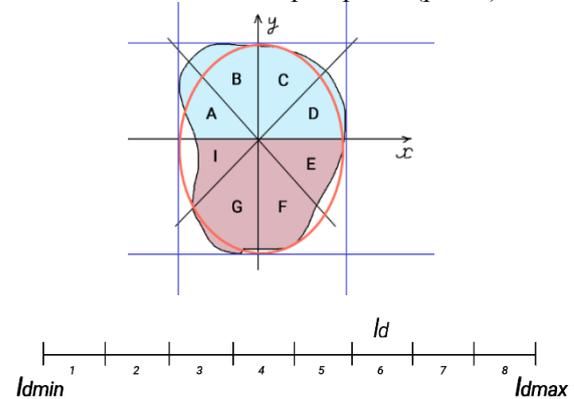


Рис. 2. Расчет количества сегментов новообразования с четким контуром

Fig. 2. Calculation of the number of tumor segments with a clear contour

С – распределение цвета. Максимальная цена критерия = 6. Значения оттенка в OpenCV варьируются от 0 до 179. Условно палитра разделяется на отдельные группы оттенков, по 10 единиц на каждую группу. Если при подсчете цветов их оказалось более 6 или 6, то критерий С имеет максимальное значение – 6 баллов. Если цветов менее 6, то за наличие в наборе цвета добавляется по одному баллу к критерию С. Мультиколорность меланомы часто является одним из признаков, на которые врачи обращают внимание при дерматологическом осмотре или оценке образований на коже [23].

Д – дерматоскопические структуры. Максимальная цена критерия = 5. Для анализа и оценки паттернов выделенного объекта необходимо найти цвета, соответствующие дерматоскопическим структурам злокачественных новообразований. С помощью масок определяются следующие цвета:

- черный (черные точки по периферии);
- коричневый, от светло-коричневого до темно-коричневого;
- голубой (бело-голубая пелена);
- серый (множественные голубые и серые точки);
- белый.

Наличие более 200 точек цвета добавляет к критерию 1 балл. Значение 200 было получено в ходе проведенных экспериментов и является минимально достаточным для утверждения наличия признака.

При подсчете метрик значения, попавшие в подозрительный диапазон, следует относить к правильным, так как они являются гипердиагностикой. Результаты классификации представлены в табл. 4.

Таблица 4. Результаты классификации по TDS наборов HAM10000 и СамараОнко

Table 4. TDS classification results for HAM10000 and SamaraOnco kits

Параметр	HAM 10000 (ед.)	HAM 10000 (%)	Самара Онко (ед.)	Самара Онко (%)
Всего случаев	9724	100	124	100
Правильно рассчитанные случаи	5236	53,84	73	58,87
Подозрительные случаи	3150	32,39	29	23,39
Неверно спрогнозированные случаи	1338	13,76	16	12,9

Оптимизация границ по алгоритму Штольца и генерация набора для обучения нейронного классификатора

В целях оптимизации алгоритма было выполнено уточнение коэффициентов и границ по набору СамараОнко. Исходя из того, что сдвиг границ к центру, т. е. сокращение диапазона подозрительных новообразований приведет к увеличению числа ошибок, а расширение диапазона хотя и даст улучшение метрик, приведет к увеличению изображений, классифицируемых как подозрительные, было установлено ограничение на количество определения подозрительных новообразований (Δ_{unk}) – не более 25 %, шаг смещения границы 1 % от фактора веса, количество смещений (n_{step}) = 6. Принятые ограничения были установлены экспериментальным путем и позволяют оптимизировать алгоритм, не допуская потери диагностической точности.

Таким образом, при максимальном значении точности представим полученные по набору СамараОнко данные как функцию (F_1) нескольких переменных:

$$F_1 = \max_{pre}(F(q_1, q_2, k_a, k_b, k_c, k_d)), \tag{4}$$

где q_1 – верхняя граница доброкачественного новообразования; q_2 – нижняя граница злокачественного новообразования; k_a, k_b, k_c, k_d – коэффициенты (факторы веса) критериев по Штольцу.

В результате из 531441 комбинации был выбран вариант с наибольшим значением точности и высокой чувствительностью, где $q_1=q_2=4,785$; $k_a = 1,339$; $k_b = 0,101$; $k_c = 0,52$; $k_d = 0,52$.

На основе полученных границ и коэффициентов сгенерирован сбалансированный набор данных, равное количество доброкачественных новообразований и меланом, представляющий собой числовой набор параметров ABCD и бинарную отметку принадлежности к классу.

Классификация заболевания нейронной сетью по критериям Штольца

Обученной нейронной сетью были классифицированы рассчитанные параметры новообразований из наборов HAM10000 и СамараОнко. В качестве классификатора был взят многослойный перцептрон. Предложенная модель состоит из трех слоев. Входной слой содержит 4 нейрона. Скрытый слой содержит 16 нейронов. На выходном слое используется 1 нейрон. Увеличение количества скрытых слоев не дало увеличения точности модели.

Результаты приведены в табл. 5.

Таблица 5. Результаты диагностирования нейронной сетью по критериям Штольца наборов HAM10000 и СамараОнко

Table 5. Results of diagnosing the HAM10000 and SamaraOnco kits using a neural network according to Stolz criteria

Параметр	HAM 10000 (ед.)	HAM 10000 (%)	Самара Онко (ед.)	Самара Онко (%)
Всего случаев	9724	100	124	100
Правильно спрогнозированные случаи	8475	87,16	106	85,48
Неверно спрогнозированные случаи	1249	12,84	18	14,51
Меланома (верно/всего)	958/1082	88,54	57/60	95

Оценка качества модели

Для оценки используемого нейронного классификатора использованы наиболее популярные характеристики, такие как матрица ошибок, точность модели, полнота, чувствительность и специфичность, рассчитаны доля правильных ответов и взвешенное гармоническое среднее полноты и точности (табл. 6).

Таблица 6. Характеристики оценки модели нейронного классификатора

Table 6. Evaluation characteristics of a neural classifier model

Параметр	HAM10000	СамараОнко
Истинно положительные результаты (TP)	958	57
Ложноотрицательные результаты (FN)	124	3
Истинно отрицательные результаты (TN)	7517	49
Ложноположительные результаты (FP)	1125	15
Точность (Pre) (%)	45,99	79,16
Полнота (Recall) (%)	88,54	95
Чувствительность (Se) (%)	88,54	95
Специфичность (Sp) (%)	86,98	76,52
Доля правильных ответов алгоритма (accuracy)	87,16	85,48
F-мера	75,95	86,35

Заключение

Предлагаемый алгоритм автоматизированной диагностики меланомы на основе дерматоскопического

метода Штольца показал хорошие результаты на реальных наборах изображений.

Комплексный подход к выделению новообразования на изображении позволяет получать объект для дальнейшего исследования с незначительной отбраковкой изображений (менее 3 %). Модификация алгоритма Штольца путем оптимизации коэффициентов рассчитываемых клинических признаков увеличивает точность модели и позволяет создать сбалансированный обучающий набор данных для нейронного классификатора. Полученные оценки качества модели коррелируются с ранее полученными результатами и имеют преимущество в виде отсутствия зависимости от качественных характеристик набора изображений.

Пониженная точность модели на наборе HAM10000 обусловлена несбалансированностью классов (соотношение классов 1 к 9). В такой ситуации более информативной является оценка сбалансированной точности, составляющая 87,76 %. Для набора СамараОнко – 85,76 %. Высокое значение *F*-меры указывает на хороший баланс между чувствительностью и специфичностью модели, модель склонна лучше обнаруживать меланомы – истинно положительные случаи (TP). Высокая чувствительность является желательной в задачах, где снижение ложноотрицательных результатов (пропущенных положительных случаев) критически важно, даже за счет увеличения числа ошибок первого рода.

Полнота модели составила 88,54 и 95 % и говорит о том, что в модели минимизированы случаи пропусков заболеваний.

По результатам исследования можно сделать вывод: чем точнее будут рассчитаны параметры ABCD, тем точнее модель сможет классифицировать заболевание, в перспективе уточнение и разбиение параметра *D* на несколько составляющих может дать модели дополнительные признаки для классификации.

Библиографические ссылки

1. Козачок А. В., Спирин А. А., Козачок Е. С. Обзор методов раннего обнаружения меланомы // Труды ИСП РАН. 2022. № 34 (4). С. 241–250.
2. Ранняя диагностика меланомы кожи с применением нескольких изображающих систем / К. Г. Кудрин, Е. Н. Римская, И. А. Аполлонова, А. П. Николаев, Н. В. Черномырдин, Д. С. Святославов, Д. В. Давыдов, И. В. Решетов // Оптика и спектроскопия. 2020. № 128 (6). DOI:10.21883/OS.2020.06.49416.53-20.
3. Ляхов П. А., Ляхова У. А. Система нейросетевой классификации пигментных новообразований кожи с предварительным удалением волос на фотографиях // Компьютерная оптика. 2021. № 45 (5). С. 728–735.
4. Новообразования кожи: современные представления о неинвазивных возможностях и перспективах диагностики / О. В. Минкина, А. С. Дворников, П. А. Скрипкина, Л. В. Оганесян, В. С. Палагина, К. С. Иванова // Профилактическая медицина. 2020. № 23 (6). С. 120–128.
5. Kittler H. Evolution of the Clinical, Dermoscopic and Pathologic Diagnosis of Melanoma. *Dermatology Practical & Conceptual*. 2021. Vol. 11. No. S1. P. 1-10.

6. Saginala K, Barsouk A, Aluru JS, Rawla P, Barsouk A. *Epidemiology of Melanoma*. *Medical Sciences*. 2021. Vol. 9(4). P. 63. <https://doi.org/10.3390/medsci9040063>.

7. Мошкин А. В. Чувствительность и специфичность как клинические индикаторы качества лабораторных исследований // *Лабораторная служба*. 2020. № 9 (4). С. 5–6.

8. Higgins H, Nakhla A, Lotfalla A, Khalil D, Doshi P, Thakkar V, Shirini D, Bebawy M, Ammari S, Lopci E, et al. Recent Advances in the Field of Artificial Intelligence for Precision Medicine in Patients with a Diagnosis of Metastatic Cutaneous Melanoma. *Diagnostics*. 2023. Vol. 13 (22). P. 3483. <https://doi.org/10.3390/diagnostics13223483>.

9. Dixon AJ, Sladden M, Zouboulis CC, Popescu CM, Nirenberg A, Steinman HK, Longo C, Dixon ZL, Thomas JM. Primary Cutaneous Melanoma—Management in 2024. *Journal of Clinical Medicine*. 2024. Vol. 13(6). P. 1607. <https://doi.org/10.3390/jcm13061607>.

10. Неинвазивные методы диагностики опухолей кожи и их потенциал применения для скрининга меланомы кожи: систематический обзор литературы / О. Е. Гаранина, И. В. Самойленко, И. Л. Шливко, И. А. Клеменова, М. С. Незнахина, Л. В. Демидов // *Медицинский совет*. 2020. № 9. С. 102–120.

11. Mandal A., Priyam S., Chan H.H., Gouveia B.M., Guitera P., Song Y., Baker MAB, Vafaei F. Computer-Aided Diagnosis of Melanoma Subtypes Using Reflectance Confocal Images. *Cancers*. 2023. Vol. 15(5). P. 1428. <https://doi.org/10.3390/cancers15051428>.

12. Patel RH, Foltz EA, Witkowski A, Ludzik J. Analysis of Artificial Intelligence-Based Approaches Applied to Non-Invasive Imaging for Early Detection of Melanoma: A Systematic Review. *Cancers*. 2023. Vol. 15 (19). P. 4694. <https://doi.org/10.3390/cancers15194694>.

13. Томакова Р. А., Дзюбин И. А., Брежнев А. В. Метод и алгоритм обучения сверточной нейронной сети, предназначенной для интеллектуальной системы распознавания меланомы // *Известия Юго-Западного государственного университета*. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. № 12 (1). С. 65–83.

14. Искусственный интеллект: как работает и критерии оценки / О. Е. Гаранина, И. Л. Шливко, И. А. Клеменова, К. А. Ускова, А. М. Миронычева, В. И. Дардык, В. Н. Ласьков // *Consilium Medicum*. 2021. № 8. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-kak-rabotaet-i-kriterii-otsenki> (дата обращения: 07.12.2023).

15. Rizzi M, Guaragnella C. A Decision Support System for Melanoma Diagnosis from Dermoscopic Images. *Applied Sciences*. 2022. Vol. 12(14). P.7007. <https://doi.org/10.3390/app12147007>.

16. Saghir U., Devendran V. A Brief Review of Feature Extraction Methods for Melanoma Detection. In Proc. of the 7th International Conference on Advanced Computing and Communication Systems (ICACCS). 2021. Vol. 1. P. 1304-1307.

17. Sepehr S. G., Hamed K., Hamid G., Fariba F., M. melanoma diagnosis applying a machine learning method based on the combination of nonlinear and texture features, *Biomedical Signal Processing and Control*. 2023. Vol. 80, PART 1. <https://doi.org/10.1016/j.bspc.2022.104300>.

18. Senan E.M., Jadhav M.E. Analysis of dermoscopy images by using ABCD rule for early detection of skin cancer. *Global Transitions Proceedings*. 2021. Vol. 2. Issue 1. P. 1-7.

19. Thanh D.N., Prasath V.B. et al. Melanoma skin cancer detection method based on adaptive principal curvatures, colour normalisation and feature extraction with the ABCD rule. *Journal of Digital Imaging*. 2020. Vol. 33 (3). P.574-585.

20. Young AT, Vora NB, Cortez J, et al. The role of technology in melanoma screening and diagnosis. *Pigment Cell Melanoma Res.* 2021. Vol. 34. P. 288–300.

References

1. Kozachok A.V., Spirin A.A., Kozachok E.S. [Review of methods for early detection of melanoma]. *Proceedings of ISP RAS.* 2022. No. 34. Pp. 241-250 (in Russ.).

2. Kudrin K.G., Rimskaya E.N., Apollonova I.A., Nikolaev A.P., Chernomyrdin N.V., Svyatoslavov D.S., Davydov D.V., Reshetov I.V. [Early diagnosis of skin melanoma using several imaging systems]. *Optics and spectroscopy.* 2020. No. 128 (in Russ.). DOI:10.21883/OS.2020.06.49416.53-20.

3. Lyakhov P.A. [System of neural network classification of pigmented skin tumors with preliminary hair removal in photographs]. *Computer optics.* 2021. No. 45. Pp. 728-735 (in Russ.).

4. Minkina O.V., Dvornikov A.S., Skripkina P.A., Oganasyan L.V., Palagina V.S., Ivanova K.S. [Skin neoplasms: modern ideas about non-invasive possibilities and diagnostic prospects]. *Preventive medicine.* 2020. No. 23. Pp. 120–128 (in Russ.).

5. Kittler H. [Evolution of the Clinical, Dermoscopic and Pathologic Diagnosis of Melanoma]. *Dermatology Practical & Conceptual*, 2021, vol. 11. no. S1, p. 1-10.

6. Saginala K, Barsouk A, Aluru JS, Rawla P, Barsouk A. [Epidemiology of Melanoma]. *Medical Sciences*, 2021, vol. 9, p. 63. <https://doi.org/10.3390/medsci9040063>

7. Moshkin A.V. [Sensitivity and specificity as clinical indicators of the quality of laboratory tests]. *Laboratory service*, 2020, no. 9, pp. 5-6 (in Russ.).

8. Higgins H, Nakhla A, Lotfalla A, Khalil D, Doshi P, Thakkar V, Shirini D, Bebawy M, Ammari S, Lopci E, et al. [Recent Advances in the Field of Artificial Intelligence for Precision Medicine in Patients with a Diagnosis of Metastatic Cutaneous Melanoma]. *Diagnostics*, 2023, vol. 13(22), p. 3483. <https://doi.org/10.3390/diagnostics13223483>

9. Dixon AJ, Sladden M, Zouboulis CC, Popescu CM, Nirenberg A, Steinman HK, Longo C, Dixon ZL, Thomas JM. [Primary Cutaneous Melanoma—Management in 2024]. *Journal of Clinical Medicine*, 2024, vol. 13(6), p. 1607. <https://doi.org/10.3390/jcm13061607>

10. Garanina O.E., Samoilenko I.V., Shlivko I.L., Klemenova I.A., Neznakhina M.S., Demidov L.V. [Non-invasive methods for diagnosing skin tumors and their potential for use in skin melanoma screening: a systematic review of the literature]. *Medical advice*, 2020, no. 9, pp. 102–120 (in Russ.).

11. Mandal A, Priyam S, Chan HH, Gouveia BM, Guitera P, Song Y, Baker MAB, Vafae F. [Computer-Aided Diagnosis of Melanoma Subtypes Using Reflectance Confocal Images]. *Cancers*, 2023, vol. 15(5), p. 1428. <https://doi.org/10.3390/cancers15051428>.

12. Patel RH, Foltz EA, Witkowski A, Ludzik J. [Analysis of Artificial Intelligence-Based Approaches Applied to Non-Invasive Imaging for Early Detection of Melanoma: A Systematic Review]. *Cancers*, 2023, vol. 15 (19), p. 4694. <https://doi.org/10.3390/cancers15194694>.

13. Tomakova R. A., Dzyubin I. A., Brezhnev A. V. [Method and algorithm for training a convolutional neural network designed for an intelligent melanoma recognition system]. *Proceedings of the South-Western State University. Series: Management, computer technology, computer science. Medical instrumentation*, 2022, no. 12(1), pp. 65-83 (in Russ.).

14. Garanina O.E., Shlivko I.L., Klemenova I.A., Uskova K.A., Mironycheva A.M., Dardyk V.I., Laskov V.N. [Artificial intelligence: how it works and evaluation criteria]. *Consilium Medicum*. 2021, no. 8 (in Russ.). URL: <https://cyberleninka.ru/article/n/iskusstvenny-intellekt-kak-rabotaet-i-kriterii-otsenki> (access date: 12/07/2023).

15. Rizzi M, Guaragnella C. A. [Decision Support System for Melanoma Diagnosis from Dermoscopic Images]. *Applied Sciences*, 2022, vol. 12 (14), p.7007. <https://doi.org/10.3390/app12147007>.

16. Saghir U., Devendran V. A. [Brief Review of Feature Extraction Methods for Melanoma Detection]. *In Proc. of the 7th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 2021, vol. 1, p. 1304-1307.

17. Sepehr S. G., Hamed K., Hamid G., Fariba F. [Melanoma diagnosis applying a machine learning method based on the combination of nonlinear and texture features]. *Biomedical Signal Processing and Control*. 2023, vol. 80, part 1. <https://doi.org/10.1016/j.bspc.2022.104300>.

18. Senan E.M., Jadhav M.E. [Analysis of dermoscopy images by using ABCD rule for early detection of skin cancer]. *Global Transitions Proceedings*. 2021, vol. 2, issue 1, p. 1-7.

19. Thanh D.N., Prasath V.B. et al. [Melanoma skin cancer detection method based on adaptive principal curvatures, color normalization and feature extraction with the ABCD rule]. *Journal of Digital Imaging*, 2020, vol. 33 (3), p. 574-585.

20. Young AT, Vora NB, Cortez J, et al. [The role of technology in melanoma screening and diagnosis]. *Pigment Cell Melanoma Res.* 2021, vol. 34, p. 288–300.

* * *

Automated Diagnosing of Melanoma Based on the Stolz Algorithm

T. A. Korobkova, Post-graduate, Samara National Research University named after Academician S.P. Korolev, SamSMU of the Ministry of Health of Russia, Samara, Russia

The article discusses an algorithm for automating melanoma diagnosing using computer vision and a neural classifier. The aim of the study is to develop an algorithm for efficient classification of melanoma in images, as well as the influence of dermoscopic features on diagnosing. New growths in the image are highlighted. Calculation of parameters for the Stolz formula and calculation of TDS (calculation of diagnosis) were carried out. Based on the calculations performed, the optimization problem was solved to clarify the boundaries of the neoplasm differentiation areas, and the Stolz formula coefficients adjustment, and a set for neural network training was generated; MLP was selected as a classifier. The average accuracy of the algorithm on two independent data sets is 86%. Classification by a neural network of two sets of images according to Stolz parameters is given. Based on the results, a diagnosing was made. Based on the Stolz algorithm, a set of images with skin neoplasms is pre-processed: the neoplasm is isolated, ABCD signs and the overall dermoscopic score are calculated from the image. The proposed algorithm for automated melanoma diagnosing based on the Stolz dermoscopic method showed good results on real sets of images. The reduced accuracy of the model on the HAM10000 set is due to the class imbalance (ratio of classes 1 to 9). A high F-measure value indicated a good balance between sensitivity and specificity of the model, with the model tending to be better at detecting melanoma true positive (TP) cases. High sensitivity

is desirable for problems, where reducing false negatives (missing positive cases) is critical, even at the expense of increasing Type I errors. The completeness of the model was 88.54% and 95% and suggests that the model minimizes cases of missing diseases. It is concluded that the more accurately the ABCD parameters are calculated, the more accurately the model will be able to classify the disease; in the future, refining and dividing parameter D into several components can provide the model with additional features for classification.

Keywords: melanoma, Stolz algorithm, computer vision in medicine, multilayer perceptron, diagnosing of skin tumors, ABCD rule.

Получено: 07.05.24

Образец цитирования

Коробкова Т. А. Автоматизированная диагностика меланомы на основе алгоритма Штольца // Интеллектуальные системы в производстве. 2024. Т. 22, № 3. С. 10–16. DOI: 10.22213/2410-9304-2024-3-10-16.

For Citation

Korobkova T.A. [Automated diagnosing of melanoma based on the stolz algorithm]. *Intellektual'nye sistemy v proizvodstve*. 2024, vol. 22, no. 3, pp. 10-16 (in Russ.). DOI: 10.22213/2410-9304-2024-3-10-16.