

АВТОМАТИЗИРОВАННОЕ ИЗВЛЕЧЕНИЕ ДИАГНОСТИЧЕСКИХ ПРИЗНАКОВ ABCD ПО ГИПЕРСПЕКТРАЛЬНЫМ ИЗОБРАЖЕНИЯМ НОВООБРАЗОВАНИЙ КОЖИ

А.П. Неповиннов¹, И.А. Матвеева¹

¹Самарский университет, г. Самара
e-mail: komahda_komahd@mail.ru

Аннотация

В работе представлен автоматизированный алгоритм для извлечения диагностических признаков по системе ABCD из гиперспектральных изображений новообразований кожи. Проведена предварительная сегментация данных с использованием метода Оцу и предварительно обученной модели U-Net с применениями алгоритмов предобработки изображения. Формализованы математические критерии для признаков асимметрии, неровности границ, вариативности цвета и диаметра. Метод успешно апробирован на 331 изображении, подтвердив соответствие результатов клинической картине патологий.

Ключевые слова: гиперспектральные изображения, сегментация, правило ABCD, машинное обучение, меланома, компьютерное зрение.

Введение

Золотым стандартом визуальной диагностики злокачественных новообразований кожи является дерматоскопическое правило ABCD (Асимметрия, Границы, Цвет, Диаметр)[1]. В клинической практике оно часто дополняется параметром E (Эволюция), однако при анализе одиночных статических изображений оценка динамики невозможна. В связи с этим, для интеграции в системы машинного обучения целесообразно использовать автоматизированную количественную оценку параметров ABCD, дополненную строгими морфологическими признаками, такими как эксцентриситет (вытянутость формы). Визуальная оценка упомянутых параметров субъективна и во многом зависит от квалификации специалиста. Использование гиперспектральных изображений (ГСИ) открывает новые возможности, предоставляя расширенную оптическую информацию о тканях. Целью работы является разработка и программная реализация метода объективной математической оценки геометрических и текстурных признаков новообразований по их маскам, полученным из ГСИ, для последующей интеграции в системы машинного обучения.

1. Материалы и методы

Исследование проводилось на наборе данных из 331 гиперспектрального куба (151 спектральный канал), включающем образцы базальноклеточной карциномы, злокачественной меланомы и доброкачественных невусов. На первом этапе выполнялась автоматическая сегментация области интереса. Для этого гиперспектральные срезы на опорных длинах волн (преимущественно 580–612 нм) подвергались предварительной

обработке, включающей удаление аппаратного виньетирования и выравнивание гистограммы методом CLAHE. Бинаризация осуществлялась двумя методами: Оцу и U-Net[2][3]. Наиболее подходящие под оригинальное изображение маски были отобраны вручную.

Извлечение признаков выполнялось на основе контурного и статистического анализа бинарной маски[4]:

1. A (Asymmetry, асимметрия) – оценивается через поиск центра масс контура (с использованием пространственных моментов изображения) и наложение зеркально отраженных масок с помощью операции исключающего ИЛИ (XOR). Индекс представляет собой отношение площади несовпадающих областей к удвоенной общей площади образования.

2. B (Border, границы) – оценивается с использованием формулы индекса компактности контура:

$$B = \frac{P^2}{4\pi S}, \quad (1)$$

где P – периметр контура, S – площадь новообразования. Для идеально округлого контура показатель стремится к 1, а при изрезанных краях возрастает.

3. C (Color, цвет/яркость) – вычисляется как стандартное отклонение интенсивностей пикселей исходного среза ГСИ на длине волны, где была произведена сегментация, строго внутри полученной бинарной маски. Показывает структурную неоднородность.

4. D (Diameter, диаметр) – максимальный габаритный размер описанного прямоугольника контура (Bounding Box) в пикселях.

Дополнительные морфологические признаки:

5. Эксцентриситет (Eccentricity) – оценивается путем вписывания эллипса в контур новообразования. Характеризует степень вытянутости пятна (от 0 для круга до 1 для линии).

2. Результаты и обсуждение

Разработанный программный комплекс был успешно применен к выборке гиперспектральных изображений. Пример работы алгоритма сегментации представлен на рисунке 1.




Рисунок 1 – Результат автоматической сегментации

Анализ распределения извлеченных математических параметров показал высокое соответствие клинической картине различных типов новообразований. Количественные показатели подтверждают дифференцирующую способность предложенных признаков. Расчет математических параметров производился по экспертно отобранным маскам (наилучшим результатам работы Оцу или U-Net для каждого конкретного снимка). В таблице 1 представлены средние значения извлеченных метрик для двух ключевых типов из тренировочной выборки.

Таблица 1 – Усредненные показатели математических признаков
для 94 злокачественных новообразований и 236 доброкачественных

Тип новообразования	Индекс асимметрии (A)	Индекс границ (B)	Вариативность яркости (C)	Диаметр (D)	Эксцентриситет
Злокачественные	0,2294	1,796	19,8524	140,1064	0,6714
Доброкачественные	0,1897	1,573	20,1116	104,8263	0,6769

Анализ усредненных значений параметров показал, что математические дескрипторы признаков A, B и D демонстрируют ожидаемую клиническую тенденцию. Злокачественные новообразования в среднем обладают более высоким индексом асимметрии (0,23 против 0,19) и выраженной неровностью границ (1,80 против 1,57). Наиболее существенное различие наблюдается в геометрическом размере: средний диаметр (D) группы злокачественных патологий на 34% превышает показатель доброкачественных.

В то же время, параметры вариативности яркости (C) и эксцентриситета в данной выборке не показали статистически значимого различия между группами, демонстрируя схожую внутреннюю текстуру и общую вытянутость формы объектов.

Полученные результаты подтверждают, что классификация новообразований на основе одиночных признаков или простых пороговых правил (If-Then) является неэффективной из-за того, что классы сильно пересекаются в многомерном пространстве.

Именно этот факт обосновывает необходимость применения методов машинного обучения. Алгоритмы ML будут оценивать не каждый признак по отдельности, а весь вектор параметров одновременно (включая спектральные характеристики), улавливая сложные, нелинейные зависимости, недоступные простому статистическому анализу

Заключение

Формализация правила ABCD методами компьютерного зрения и статистического анализа позволяет устранить субъективный фактор при диагностике кожных патологий. Извлеченные геометрические и текстурные характеристики образуют интерпретируемый вектор признаков. В сочетании со спектральными данными гиперкуба данный вектор формирует надежную основу для построения высокоточных классификаторов на базе методов машинного обучения, что станет следующим этапом исследования.

Список использованных источников

1. Friedman, R. J. Early detection of malignant melanoma: the role of physician examination and self-examination of the skin / R. J. Friedman, D. S. Rigel, A. W. Kopf // CA: a Cancer Journal for Clinicians. – 1985. – V. 35, № 3. – P. 130–151.
2. Otsu, N. A Threshold Selection Method from Gray-Level Histograms / N. Otsu // IEEE Transactions on Systems, Man, and Cybernetics. – 1979. – V. 9, № 1. – P. 62–66.
3. Ronneberger, O. U-Net: Convolutional Networks for Biomedical Image Segmentation / O. Ronneberger, P. Fischer, T. Brox // Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. – Springer, Cham, 2015. – P. 234–241.

4. A methodological approach to the classification of dermoscopy images / M. E. Celebi, H. A. Kingravi, B. Uddin [et al.] // Computerized Medical Imaging and Graphics. – 2007. – V. 31, № 6. – P. 362–373.

AUTOMATED EXTRACTION OF ABCD DIAGNOSTIC FEATURES FROM HYPERSPECTRAL IMAGES OF SKIN NEOPLASMS

A.P. Nepovinnov¹, I.A. Matveeva¹

*¹Samara University, Samara
e-mail: komahda_komahd@mail.ru*

Abstract

The paper presents an automated algorithm for extracting diagnostic features based on the ABCD system from hyperspectral images of skin neoplasms. Preliminary data segmentation was performed using Otsu's method and a pre-trained U-Net model, along with image preprocessing techniques. Mathematical criteria for asymmetry, border irregularity, color variation, and diameter were formalized. The method was successfully tested on 331 images, confirming that the results are consistent with the clinical presentation of the pathologies.

Keywords: hyperspectral images, segmentation, ABCD rule, machine learning, melanoma, computer vision.