



УДК 004.932.2

МРНТИ 28.23.15

https://doi.org/10.53364/24138614_2025_38_3_8

З.Г. Кабдрахманова^{1*}, А.С. Тлебалдинова¹, М.А.Карменова², С.К. Кумаргажанова¹,
И.Б. Карымсакова³

¹Восточно-Казахстанский технический университет им. Д. Серикбаева,
Усть-Каменогорск, Казахстан

² Восточно-Казахстанский университет им. С.Аманжолова, Усть-Каменогорск, Казахстан

³Университет имени Шакарима города Семей, Семей, Казахстан

*E-mail: zkabdrahmanova@vku.edu

ПРИМЕНЕНИЕ ТЕКСТУРНОГО АНАЛИЗА ПРИ КЛАССИФИКАЦИИ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ

Аннотация. В современной медицине анализ текстурных признаков изображений играет важную роль в диагностике различных заболеваний. Данное исследование посвящено методам классификации текстурных признаков изображений ожоговых поражений, позволяющим выделять информативные характеристики и повышать точность диагностики. Рассмотрены современные алгоритмы машинного обучения, применяемые для автоматизированного анализа изображений. Проведен сравнительный анализ различных методов классификации, выявлены наиболее эффективные подходы к обработке текстурных признаков. Результаты исследования могут быть использованы для разработки интеллектуальных систем поддержки принятия врачебных решений. В исследовании использован набор данных, включающий 1500 изображений ожоговых поражений, полученных из открытых источников Roboflow и Kaggle. Для выделения текстурных признаков применена программа MaZda, обеспечивающая детальный анализ изображений. Исходный массив, содержащий 279 признаков, был оптимизирован путем выбора наиболее информативных характеристик с использованием шести методов: ANOVA, Fisher, Relief, SBS, SFS и RFE, что позволило сократить их количество до 21. Проведен обзор современных подходов к автоматизированному анализу ожогов, включая методы обработки изображений и машинного обучения, опубликованных за последние пять лет. Работа демонстрирует перспективность применения машинного обучения в медицине и необходимость дальнейших исследований для повышения точности классификации и практического внедрения разработанных алгоритмов.

Ключевые слова: текстурные признаки, MaZda, автоматизированный анализ ожогов, медицинская диагностика, обработка изображений, классификация ожогов.

Введение.

Современные методы диагностики ожогов требуют высокой точности и объективности при определении степени тяжести повреждений кожи. Врачебная оценка, основанная на визуальном осмотре, может быть субъективной и зависеть от опыта специалиста. В связи с этим актуальной задачей является разработка автоматизированных информационных систем, использующих методы компьютерного зрения и машинного обучения для классификации ожогов. Автоматическое распознавание степени тяжести ожогов на основе изображений позволяет повысить скорость и точность диагностики, что

особенно важно для своевременного выбора тактики лечения. Одним из перспективных направлений является анализ текстурных характеристик поврежденных участков кожи, поскольку текстурные признаки несут значимую информацию о структуре ткани и степени ее поражения.

В данном исследовании рассматривается подход к автоматизированной классификации ожогов по трем степеням тяжести на основе анализа текстурных признаков, вычисленных с использованием программного обеспечения MAZDA. Для отбора наиболее информативных признаков применяются методы фильтрации: ANOVA, Fisher, Relief, а также методы оболочки: SBS, SFS и RFE.

Цель исследования – разработать и обосновать эффективный подход к автоматизированной диагностике ожоговых поражений на основе анализа текстурных признаков изображений, используя методы отбора признаков для повышения точности и интерпретируемости классификации. Исследование направлено на определение наиболее информативных признаков для классификации ожоговых поражений, снижение размерности признакового пространства и улучшение работы алгоритмов машинного обучения в задачах медицинской диагностики.

Научная новизна этого исследования заключается в адаптации конфигурации и гиперпараметров модели и алгоритмов машинного обучения для определения наилучшей стратегии классификации с целью повышения точности классификации ожоговых поражений.

За последние пять лет было проведено множество исследований, посвященных применению методов машинного обучения в медицинской диагностике, включая анализ изображений ожогов. Рассмотрим основные направления, связанные с данной тематикой. Методы машинного обучения и компьютерного зрения находят широкое применение в медицинской визуализации, включая диагностику кожных заболеваний, таких как ожоги. В исследовании Веденичева Д.А. рассматривается использование нейронных сетей для сегментации и классификации кожных патологий на основе фотографий пациентов [1]. Однако нейросетевые алгоритмы требуют значительных объемов данных и высоких вычислительных мощностей, что затрудняет их интеграцию в клиническую практику. Текстуальный анализ активно применяется для диагностики кожных и других заболеваний. Одним из распространенных инструментов для работы с текстурными признаками является программа MAZDA, включающая широкий спектр методов статистического анализа изображений. В исследовании Венцека Ю.К. рассматриваются подходы к сегментации изображений с использованием текстурных характеристик, а также проводится оценка их эффективности на реальных медицинских данных [2].

В задачах медицинской диагностики важную роль играет отбор наиболее информативных признаков, позволяющий избежать переобучения моделей. Методы фильтрации, такие как ANOVA, Fisher и Relief, позволяют выявить наиболее значимые для классификации признаки. В работе Настенко Е. анализируется использование текстурных характеристик в задачах классификации медицинских изображений, а также исследуется влияние различных методов отбора признаков на точность моделей [3]. Методы оболочки, включая SBS, SFS и RFE, позволяют формировать оптимальные подмножества признаков, способствующие повышению эффективности классификации.

Следующее исследование [4] посвящено разработке автоматизированной системы анализа ожоговых ран, включающей три ключевых этапа: сегментацию изображений, извлечение признаков и классификацию областей. Авторы рассматривают различные методы на каждом этапе, стремясь определить их оптимальную комбинацию. В качестве одного из подходов была применена семантическая сегментация на основе глубокой нейросети SegNet. Результаты экспериментов показали, что наиболее эффективной комбинацией методов является использование нечеткого алгоритма *c-means* для сегментации и многослойной искусственной нейронной сети прямого распространения,

обученной методом обратного распространения, для классификации. Данный подход позволил достичь F-оценки 74,28% при анализе изображений, полученных без специального протокола. В то же время метод глубинного обучения продемонстрировал несколько более высокую точность с F-оценкой 80,50%. Таким образом, предложенный алгоритм классификации оказался сопоставимым с глубоким обучением, что делает его перспективным для автоматизированного анализа ожоговых поражений.

Ультразвуковая диагностика, являясь неинвазивным методом визуализации, широко применяется для выявления патологий печени. Важным направлением исследований является анализ текстурных характеристик и классификация ультразвуковых изображений печени. В данном [5] исследовании для обработки изображений сначала была использована матрица совместного встречаемого градиента серых уровней (GLGCM), а затем – матрица совместного встречаемого уровня серого (GLCM). Эти методы позволили выделить 22 признака, из которых были отобраны семь наиболее информативных для дальнейшей классификации с использованием нейронной сети обратного распространения ошибок (BP). В рамках исследования фиброз печени классифицировался по пяти стадиям (S0-S4), при этом точность классификации составила 100% для S0 и S4, 90% для S1 и S3, а также 70% для S2.

Исследователи Cirillo и его коллеги [6] использовали сверточные нейронные сети (CNN) для прогнозирования прогрессирования ран и улучшения результатов лечения ожогов. Они проанализировали параметры цветового изображения трех типов глубоких термических повреждений, полученные путем оценки изображений здоровой кожи и фона. После обучения CNN средняя точность, чувствительность и специфичность для четырех типов ожогов составили 90,54%, 74,35% и 94,25% соответственно. Таким образом, в настоящем исследовании делается акцент на использовании текстурных признаков, отобранных методами фильтрации, для обучения традиционных моделей машинного обучения, что позволяет достичь высокой точности при классификации ожогов.

В работе [7] Щетинина и соавторов предложен подход к обнаружению злокачественных новообразований кожи на основе анализа дермоскопических изображений с использованием методов глубокого обучения. Разработанная архитектура глубокой сверточной нейронной сети была применена к обработке дермоскопических изображений различных повреждений кожи, что обеспечило точность на тестовой выборке 94%.

Использование моделей глубокого обучения при решении вышеупомянутых проблем, связанных с ожогами, также обсуждается в следующей работе [8]. Авторы рассматривают использование глубоких сверточных нейронных сетей (CNN) в машинном обучении для автоматического прогнозирования глубины ожога. В исследовании использовались цветные изображения четырех типов глубины ожогов, снятые камерой TiVi, и четыре предварительно обученные глубокие сверточные нейронные сети: VGG-16, GoogleNet, ResNet-50 и ResNet-101. Наилучшие результаты были достигнуты при использовании модели ResNet-101, которая показала точность 81,66% и другие показатели, такие как чувствительность и специфичность.

Это исследование подтверждает, что искусственный интеллект может быть полезным инструментом для прогнозирования глубины ожогов и оказания помощи в принятии клинических решений и первичном лечении ожоговых ран. Аналогичным образом, исследование [9] из цитируемой работы показывает, что тонкая настройка всех слоев дает лучшие результаты, чем тонкая настройка только верхних слоев, и доказано, что время, необходимое для тонкой настройки всех слоев, на самом деле меньше времени, необходимого для тонкой настройки только верхних слоев. Это объясняется тем, что при настройке всех слоев было выполнено всего 20 эпох, тогда как при настройке только верхних слоев количество эпох составило 30. Если бы настройка верхних слоев не была завершена в течение 30 эпох, достигнутые результаты были бы неудовлетворительными.

Это наблюдение говорит о том, что более глубокая настройка всей модели не только обеспечивает более высокое качество конечного результата, но и способствует более быстрой сходимости модели, чем настройка только верхних слоев.




Эти подходы демонстрируют эффективность использования современных технологий, таких как глубокое обучение и текстурные анализы медицинских изображений для диагностики и оценки тяжести ожогов кожи, расширяя возможности медицинской диагностики и улучшая результаты лечения пациентов.

Материалы и методы исследования.

Для обучения и тестирования моделей использовался набор изображений ожогов, включающий 1500 изображений, разделенных на три класса по 500 изображений в каждом. Изображения были получены из открытых источников, включая медицинские базы данных и доступные научные публикации, что обеспечило разнообразие данных и их соответствие реальным клиническим условиям. При анализе текстуры тканей важно свести к минимуму процедуры предварительной обработки, чтобы сохранить естественные особенности изображений. Все изображения стандартизированы по освещению и углу съемки, чтобы минимизировать влияние внешних факторов.

Классификация ожогов осуществлялась по трем степеням тяжести, представленных в таблице 1.

Таблица 1 – Степень тяжести ожогов и их признаки

№	Степень тяжести ожогов	Признаки	Изображение
1	I степень	поверхностные ожоги, затрагивающие только эпидермис	
2	II степень	поражение эпидермиса и частично дермы	
3	III степень	глубокие ожоги, затрагивающие все слои кожи и подкожную клетчатку	

Текстурные признаки были вычислены с использованием программы MAZDA, которая позволяет извлекать статистические характеристики изображений. Всего было получено 279 признаков, включающих: Матрицу совместной встречаемости уровней серого (GLCM) – параметры контрастности, однородности, энтропии и корреляции; Статистические моменты первого и второго порядка; Вейвлет-преобразование; Гистограммы распределения интенсивностей пикселей.

Области интереса выделялись путем наложения выбранных вручную цветных областей на полутоновое изображение (см. таб. 1). Можно определить до 16 профилей областей интереса, используя 16 уникальных цветов. Анализ с помощью программы MaZda выполняется в пределах этих областей интереса. После применения методов отбора признаков из 279 параметров были отобраны 21 наиболее информативных признаков, обеспечивающих наилучшую классификацию. Это позволило снизить вычислительную сложность и повысить точность моделей машинного обучения. Для сокращения размерности признакового пространства применялись шесть методов:

- Методы статистического тестирования: Anova (дисперсионный анализ) – анализ значимости различий между классами; Fisher – оценка соотношения межклассовой и внутриклассовой дисперсий; Relief – оценка значимости признаков на основе расстояния до ближайших соседей.

- Методы оболочки (wrapper methods): SBS (Sequential Backward Selection) – последовательное удаление наименее значимых признаков; SFS (Sequential Forward Selection) – последовательное добавление наиболее значимых признаков; RFE (Recursive Feature Elimination) – рекурсивное удаление признаков на основе их важности, оцениваемой с использованием модели, что помогает выявить наиболее информативные признаки. Средние значения параметров рассчитаны для обучающей и тестовой выборок. Процедура селекции признаков осуществлена с применением шести методов. Результаты выделенных признаков представлены в таблице 2

Таблица 2 – Средние значения параметров и результаты селекции признаков для обучающей и тестовой выборок

Обучающий набор		Тестовый набор	
Название признака	Среднее значение признака	Название признака	Среднее значение признака
Mean	-0.000000061	Mean	0.016216035
Variance	0.000000005	Variance	0.012079924
Skewness	0.000000003	Skewness	-0.023899715
Kurtosis	0.000000017	Kurtosis	0.018523313
Perc.01%	-0.000000244	Perc.01%	0.000204855
S(1,0)AngScMom	0.000000026	S(1,0)AngScMom	-0.02420533
S(0,1)Contrast	-0.000000029	S(0,1)Contrast	-0.065411258
S(0,1)Correlat	0.000000005	S(0,1)Correlat	0.080724801
S(1,0)Contrast	-0.000000003	S(1,0)Contrast	-0.081832485
S(1,0)Correlat	0.000000003	S(1,0)Correlat	0.108972243
S(1,0)InvDfMom	0.000000014	S(1,0)InvDfMom	0.065677647
Horzl_GLevNonU	0.000000017	Horzl_GLevNonU	-0.079309261
Horzl_LngREmph	-0.000000009	Horzl_LngREmph	-0.064593038
Vertl_GLevNonU	-0.000000022	Vertl_GLevNonU	-0.036143453
Vertl_LngREmph	0.000000018	Vertl_LngREmph	-0.042272361
Teta1	-0.000000041	Teta1	0.049204005
Teta2	0.000000065	Teta2	-0.013152038
Teta3	0.000000057	Teta3	-0.036801371
WavEnHH_s-1	0.000000030	WavEnHH_s-1	-0.0528722
WavEnHL_s-4	-0.000000015	WavEnHL_s-4	0.002418665
WavEnLH_s-4	0.000000015	WavEnLH_s-4	-0.042384786

Отбор признаков позволит уменьшить количество используемых параметров, повысив эффективность классификации и снизив вероятность переобучения.

Процедура реализации классификации изображения при ожоговых поражениях представлена на рисунке 1.

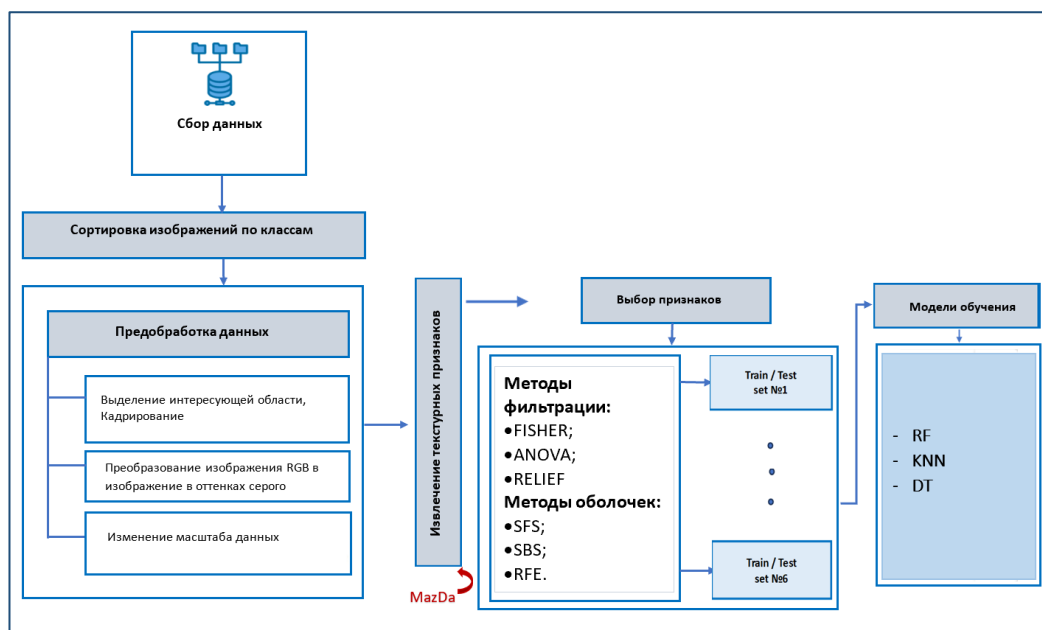


Рисунок 1 – Схема процедуры реализации классификации изображения при ожоговых поражениях

Обучающая выборка составляла 70% от общего объема данных, а тестовая - 30%. Процесс обучения и тестирования классификаторов выполнялся дважды, после чего рассчитывалось среднее значение всех тестов в качестве итогового результата. Для каждого набора данных формировались два обучающих и два тестовых поднабора с использованием метода случайной выборки с возвращением. В исследовании были задействованы три широко применяемых метода обучения: K-Nearest Neighbors (KNN) – метод ближайших соседей, работающий на основе вычисления расстояний между объектами; Discriminant Analysis (DR) – метод дискриминантного анализа, определяющий границы классов; Random Forest (RF) – ансамблевый метод на основе деревьев решений, демонстрирующий высокую устойчивость к шуму в данных. Для оценки качества моделей использовались метрики: Accuracy – Точность (общая доля правильно классифицированных объектов); Precision – Прецизионность (доля истинно положительных предсказаний среди всех положительных предсказаний); Recall – Полнота (доля истинно положительных предсказаний среди всех фактических положительных объектов).

Результаты и обсуждение.

После проведения обучения и тестирования моделей машинного обучения на изображениях ожоговых поражений были получены количественные показатели их эффективности. В таблице 3 представлен сравнительный анализ точности классификации различных алгоритмов на основе метрик.

Таблица 3 – Сравнительный анализ точности классификации

Модель	Accuracy(%)	Precision(%)	Recall(%)
KNN	71.2	70.5	69.8
DR	73.5	72.8	73.2
RF	79.0	78.5	78.9

Модель Random Forest (RF) показала наивысшую точность (79%), что объясняется ее способностью эффективно работать с высокоразмерными признаковыми пространствами и учитывать сложные зависимости в данных.

Для повышения точности классификации ожогов по степени тяжести использовалась настройка гиперпараметров с применением методов Grid Search и Random Search на основе 5-кратной кросс-валидации. Рассмотрим детально, какие параметры изменялись и какие значения давали наилучшие результаты. Результаты, полученные в процессе оптимизации гиперпараметров моделей на основе оценочных метрик, представлены в таблице 4.

Таблица 4 – Результат после настраивания гиперпараметров метрик

№	Методы	Настраиваемые параметры:	Результат:
1	Метод k-ближайших соседей (K-Nearest Neighbors, KNN)	Число соседей (k): варьировалось от 3 до 15 с шагом 2. Оптимальное значение: $k = 7$ (баланс между переобучением и недообучением). Метрика расстояния: Евклидово (L2), Манхэттенское (L1), Минковского (p=3). Оптимальный выбор: Евклидово расстояние (показало лучшую классификацию). Веса соседей: Равномерные, обратно пропорциональные расстоянию. Оптимальный выбор: обратные веса (дают большую значимость ближайшим объектам).	Без настройки: Точность ~67% После оптимизации гиперпараметров: Точность ~72%
2	Дерево решений (Decision Tree, DT)	Максимальная глубина дерева: Значения: от 5 до 30 (с шагом 5). Оптимальное значение: 15 (сбалансированное разбиение). Критерий разбиения: Gini, Энтропия. Оптимальный выбор: Gini (давал меньшую вариативность в разбиениях). Минимальное количество объектов в листе: От 1 до 10 (шаг 2). Оптимальное значение: 5 (устраняет переобучение).	Без настройки: Точность ~60% После оптимизации гиперпараметров: Точность ~70%
3	Случайный лес (Random Forest, RF)	Число деревьев в ансамбле: Варьировалось от 50 до 500 с шагом 50. Оптимальное значение: 300 деревьев (баланс между скоростью и точностью). Максимальная глубина деревьев: От 10 до 50 (шаг 5). Оптимальное значение: 25 (дальнейшее увеличение не давало прироста точности). Максимальное число признаков при разбиении: Варианты: sqrt (квадратный корень от числа признаков), log2, все признаки. Оптимальный выбор: sqrt (баланс между вычислительной эффективностью и точностью). Критерий разбиения: Gini, Энтропия. Оптимальный выбор: Gini (показал лучшую точность на кросс-валидации).	Без настройки: Точность ~72% После оптимизации гиперпараметров: Точность ~79% (лучший результат среди всех моделей).

Выводы по настройке гиперпараметров:

- Случайный лес (RF) с 300 деревьями и глубиной 25 показал наивысшую точность — 79%.
- Методы KNN и DT показали улучшение после настройки, но не превзошли RF.

Подбор гиперпараметров проводился через Grid Search и Random Search на 5-кратной кросс-валидации, что помогло избежать переобучения. Всего в результате анализа изображений было извлечено 279 дескрипторов текстур. Затем уменьшение размерности было выполнено с использованием метода выбора шести признаков. В таблице 5 продемонстрированы лучшие результаты, полученные каждым методом.

Таблица 5 – Результат применения методов классификации и оценки точности модели

Название модели	Метод отбора	Метод классификации	Оценка точности	Оптимальное количество характеристик
MODEL_19_FISHER_RF	FISHER	RF	0.79	19
MODEL_7_FISHER_KNN		KNN	0.74	7
MODEL_7_FISHER_DT		DT	0.73	7
MODEL_13_ANOVA_RF	ANOVA	RF	0.78	13
MODEL_8_ANOVA_KNN		KNN	0.74	8
MODEL_17_ANOVA_DT		DT	0.74	17
MODEL_18_RFE_RF	RFE	RF	0.78	18
MODEL_11_RFE_KNN		KNN	0.75	11
MODEL_18_RFE_DT		DT	0.73	18
MODEL_20_RELIEF_RF	RELIEF	RF	0.79	20
MODEL_18_RELIEF_KNN		KNN	0.75	18
MODEL_20_RELIEF_DT		DT	0.73	20
MODEL_20_SFS_RF	SFS	RF	0.79	20
MODEL_6_SFS_KNN		KNN	0.74	6
MODEL_16_SFS_DT		DT	0.74	16
MODEL_18_SBS_RF	SBS	RF	0.79	18
MODEL_7_SBS_KNN		KNN	0.75	7
MODEL_9_SBS_DT		DT	0.73	9

Анализ влияния методов отбора признаков показал, что применение ANOVA и Fisher позволило повысить точность моделей на 3-5% по сравнению с использованием всех признаков. Методы оболочки SBS и Relief показали наилучший баланс между размерностью признакового пространства и точностью классификации, что делает их предпочтительными для данной задачи.

Заключение.

В рамках данного исследования был разработан подход для автоматической классификации ожогов по степени тяжести на основе анализа текстурных признаков. В ходе исследования были извлечены текстурные характеристики с применением программы MAZDA, что позволило учитывать характеристики структуры тканей. Проведен анализ эффективности различных методов отбора признаков, при котором наилучшие и одинаковые результаты продемонстрировали SBS и Relief. Подтверждена высокая результативность текстурного анализа в диагностике ожогов путем сопоставления полученных данных с результатами других исследований. Обучены и протестированы три модели машинного обучения (KNN, DR, RF), где Random Forest достиг максимальной точности 79%.

Перспективы дальнейших исследований заключаются в интеграции сверточных нейронных сетей (CNN) с текстурными признаками, расширении датасета за счет включения данных из различных источников, а также применении методов, повышающих интерпретируемость моделей.

Список литературы

1. Веденичев, Д.А., Лавриченко, О.А. (2022). Применение нейронных сетей для сегментации и классификации кожных заболеваний на основе фотоснимков человека

[Электронный ресурс]. – Режим доступа: <https://elib.spbstu.ru/dl/3/2022/vr/vr22-2804.pdf/info>

2. Венцек, Ю.К. (2023). Сегментация изображений на основе текстурных признаков // Электронные системы и технологии: материалы 59-й научной конференции аспирантов, магистрантов и студентов БГУИР. -Минск: БГУИР, 95–96. URL: <https://libeldoc.bsuir.by/handle/123456789/51401>

3. Настенко, Е. (2020). Применение текстурного анализа в задаче классификации медицинских изображений [Электронный ресурс]. – Режим доступа: <https://www.academia.edu/95767470>.

4. Rowland, R., Ponticorvo, A., Baldado, M., Kennedy, G., Burmeister, D., Christy, R., Bernal, N., Durkin, A. (2019). Burn wound classification model using spatial frequency-domain imaging and machine learning. *Journal of biomedical optics*; 24(5):1-9. DOI: 10.1117/1.JBO.24.5.056007.

5. Gao Shuang, Peng Yuhua, Guo Huizhi, Liu Weifeng, Gao Tianxin, Xu Yuan-qing, Tang Xiaoying (2019). Texture analysis and classification of ultrasound liver images. *Bio-medical materials and engineering*; 24(1):1209-16. DOI: 10.3233/BME-130922.

6. Cirillo, M.D., Mirdell, R., Sjöberg, F. (2019). Time-independent prediction of burn depth using deep convolutional neural networks // *Journal of Burn Care & Research*; (6). 857-863.

7. Щетинин, Е.Ю., Севастьянов, Л.А., Демидова, А.В., Кулябов, Д.С. (2020). Классификация повреждений кожи по данным дермаскопии с использованием методов глубокого обучения. *Математическая биология и биоинформатика*. 15, (№2). 180–194. DOI: 10.17537/2020.15.180.

8. Chang, C.W., Ho, C.Y., Lai, F., Christian, M., Huang, S.C., Chang, D.H., Chen, Y.S. (2023). Application of multiple deep learning models for automatic burn wound assessment. *Burns*; 49(5):1039-1051. DOI: 10.1016/j.burns.2022.07.006. Epub 2022 Jul 18. PMID: 35945064.

9. Chen, L.C., Zhu, Y., Papandreou, G., Schroff, F., Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation // *European Conference on Computer Vision February, Computer Science*. DOI:10.1007/978-3-030-01234-2_49

References

1. Vedenichev, D.A., Lavrichenko, O.A. (2022). Primenenie nejronnyh setej dlja segmentacii i klassifikacii kozhnyh zabolevanij na osnove fotosnimkov cheloveka [Jelektronnyj resurs]. – Rezhim dostupa: <https://elib.spbstu.ru/dl/3/2022/vr/vr22-2804.pdf/info>

2. Vencek, Ju.K. (2023). Segmentacija izobrazhenij na osnove teksturnyh priznakov // Jelektronnye sistemy i tehnologii: materialy 59-j nauchnoj konferencii aspirantov, magistrantov i studentov BGUIR, Minsk: BGUIR. 95–96; URL: <https://libeldoc.bsuir.by/handle/123456789/51401>

3. Nastenko, E. (2020). Primenenie teksturnogo analiza v zadache klassifikacii medicinskih izobrazhenij [Jelektronnyj resurs]. – Rezhim dostupa: <https://www.academia.edu/95767470>.

4. Rowland, R., Ponticorvo, A., Baldado, M., Kennedy, G., Burmeister, D., Christy, R., Bernal, N., Durkin, A. (2019). Burn wound classification model using spatial frequency-domain imaging and machine learning // *Journal of biomedical optics*; 24(5):1-9. DOI: 10.1117/1.JBO.24.5.056007.

5. Gao Shuang, Peng Yuhua, Guo Huizhi, Liu Weifeng, Gao Tianxin, Xu Yuan-qing, Tang Xiaoying (2019). Texture analysis and classification of ultrasound liver images. *Bio-medical materials and engineering*; 24(1):1209-16. DOI: 10.3233/BME-130922.

6. Cirillo, M.D., Mirdell R., Sjöberg F. (2019). Time-independent prediction of burn depth using deep convolutional neural networks // *Journal of Burn Care & Research*; (6). 857-863.

7. Shhetinin E.Ju., Sevast'janov, L.A., Demidova, A.V., Kuljabov, D.S. (2020). Klassifikacija povrezhdenij kozhi po dannym dermaskopii s ispol'zovaniem metodov glubokogo

obuchenija. *Matematicheskaja biologija i bioinformatika*. 15, (2). 180–194. DOI: 10.17537/2020.15.180.

8. Chang, CW, Ho CY., Lai, F., Christian M, Huang, S.C., Chang, D.H., Chen, Y.S. (2023). Application of multiple deep learning models for automatic burn wound assessment. *Burns*; 49(5):1039-1051. DOI: 10.1016/j.burns.2022.07.006. Epub 2022 Jul 18. PMID: 35945064.

9. Chen, L.C., Zhu, Y., Papandreou, G., Schroff, F., Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation // European Conference on Computer Vision February, Computer Science. DOI:10.1007/978-3-030-01234-2_49

МЕДИЦИНАЛЫҚ БЕЙНЕЛЕРДІ КЛАССТАРҒА ЖІКТЕУДЕ ТЕКСТУРАЛЫҚ ТАЛДАУДЫ ҚОЛДАНУ

Аңдатпа. Қазіргі заманғы медицинада кескіндердің текстуралық ерекшеліктерін талдау әртүрлі ауруларды диагностикалауда маңызды рөл атқарады. Бұл зерттеу ақпараттық сипаттамаларды анықтауға және диагностикалық дәлдікті арттыруға мүмкіндік беретін күйік жарақаттары кескіндерінің текстуралық ерекшеліктерін жіктеу әдістеріне арналған. Кескінді автоматтандырылған талдау үшін қолданылатын қазіргі заманғы машиналық оқыту алгоритмдері қарастырылады. Әртүрлі жіктеу әдістеріне салыстырмалы талдау жүргізіліп, текстураның ерекшеліктерін өңдеудің ең тиімді тәсілдері анықталды. Зерттеу нәтижелерін медициналық шешім қабылдауды қолдау үшін интеллектуалды жүйелерді әзірлеу үшін пайдалануға болады. Зерттеуде Roboflow, Kaggle ашық көздерден алынған 1500 дана күйіктердің кескіндері (әр класс үшін 500 данадан) пайдаланылды. Әрі қарай жіктеу үшін MaZda бағдарламасы арқылы алынған текстуралық ерекшеліктер пайдаланылды. Бастапқыда 279 ерекшелік анықталды, оның ішінде 6 таңдау әдістерін: ANOVA, Фишер, Рельеф, SBS, SFS және RFE қолдану арқылы 21 маңызды ерекшелік таңдалды. Соңғы бес жылда жарияланған күйіктерді автоматтандырылған талдаудың заманауи тәсілдеріне шолу жасалды, оның ішінде кескіндерді өңдеу және машиналық оқыту әдістері. Жұмыс медицинадағы машиналық оқытудың әлеуетін және классификация дәлдігін және әзірленген алгоритмдерді практикалық енгізуді жақсарту үшін одан әрі зерттеу қажеттілігін көрсетеді.

Түйін сөздер: текстураның ерекшеліктері, MaZda, автоматтандырылған күйік талдауы, медициналық диагностика, кескінді өңдеу, күйік классификациясы.

APPLICATION OF TEXTURE ANALYSIS IN MEDICAL IMAGE CLASSIFICATION

Abstract. In modern medicine, the analysis of texture features of images plays an important role in the diagnosis of various diseases. This study is devoted to the methods of classifying texture features of burn injury images, which allow identifying informative characteristics and increasing the accuracy of diagnosis. Modern machine learning algorithms used for automated image analysis are considered. A comparative analysis of various classification methods is carried out, the most effective approaches to processing texture features are identified. The results of the study can be used to develop intelligent systems to support medical decision-making. The study used 1,500 burn images (500 for each class) obtained from open sources Roboflow, Kaggle. Texture features extracted using MaZda software were used for further classification. Initially, 279 features were extracted, from which 21 most significant features were selected using 6 selection methods: ANOVA, Fisher, Relief, SBS, SFS and RFE. A review of current approaches to automated burns analysis, including image processing and machine learning methods, published in the last five years is performed. The work demonstrates the promising application of machine learning in medicine and the need for further research to improve classification accuracy and practical implementation of the developed algorithms.

Keywords: *texture features, MaZda, automated burn analysis, medical diagnosis, image processing, burn classification.*

Сведение об авторах

Кабдрахманова Зауре Гадьяльжановна	Докторант 2 года обучения ОП 8D06101 – «Информационные системы (по отраслям)» Школы информационных технологий и интеллектуальных систем Восточно-Казахстанского технического университета имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан, E-mail: zkabdrahmanova@vku.edu
Тлебалдинова Айжан Солтангалиевна	PhD, ассоциированный профессор Школы информационных технологий и интеллектуальных систем Восточно-Казахстанского технического университета имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан, E-mail: atlebaldinova@edu.ektu.kz
Карменова Мархаба Ахметоллиновна	PhD, ассоциированный профессор Восточно-Казахстанского университета имени С. Аманжолова, Усть-Каменогорск, Казахстан, E-mail: mkarmenova@vku.edu.kz
Кумаргажанова Сауле Кумаргажановна	Кандидат технических наук, профессор Школы информационных технологий и интеллектуальных систем Восточно-Казахстанского технического университета имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан, E-mail: saule.kumargazhanova@edu.ektu.kz
Карымсакова Индира Бекеновна	PhD, и.о. ассоциированного профессора кафедры «IT технологии», Некоммерческое акционерное общество «Шәкәрім университет», Семей, Республика Казахстан, E-mail: karymsakova.indira@mail.ru

Авторлар туралы мәлімет

Кабдрахманова Зауре Гадьяльжановна	Д.Серікбаев атындағы Шығыс Қазақстан техникалық университетінің Ақпараттық технологиялар және зияткерлік жүйелер мектебінің 8D06101 – «Ақпараттық жүйелер (салалар бойынша)» БББ 2 оқу жылындағы докторанты, Өскемен қ., Қазақстан, E-mail: zkabdrahmanova@vku.edu
Тлебалдинова Айжан Солтангалиевна	PhD, Д.Серікбаев атындағы Шығыс Қазақстан техникалық университетінің Ақпараттық технологиялар және зияткерлік жүйелер мектебінің қауымдастырылған профессоры, E-mail: atlebaldinova@edu.ektu.kz
Карменова Мархаба Ахметоллиновна	PhD, С.Аманжолов атындағы Шығыс Қазақстан университетінің қауымдастырылған профессоры,, Өскемен қ., Қазақстан, E-mail: mkarmenova@vku.edu.kz
Кумаргажанова Сауле Кумаргажановна	Техникалық ғылымдар кандидаты, Д.Серікбаев атындағы Шығыс Қазақстан техникалық университетінің Ақпараттық технологиялар және зияткерлік жүйелер мектебінің профессоры, E-mail: saule.kumargazhanova@edu.ektu.kz
Карымсакова Индира Бекеновна	PhD, «IT технологиялар» кафедрасының қауымдастырылған профессорының м.а., «Шәкәрім университеті» коммерциялық емес акционерлік қоғамы, Семей, Қазақстан Республикасы, E-mail: karymsakova.indira@mail.ru

Information about the authors

Kabdrakhmanova Zaure	Doctoral student of the 2nd year of study EP 8D06101 – «Information systems (by branches)» School of Information Technologies and Intelligent Systems at D.Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan, E-mail: zkabdrahmanova@vku.edu
Tlebaldinova Aizhan	PhD, Associate Professor of the School of Information Technologies and Intelligent Systems at D. Serikbayev East Kazakhstan Technical University, E-mail: atlebaldinova@edu.ektu.kz
Karmenova Marhaba	PhD, Associate Professor, S. Amanzholov East Kazakhstan University, Ust-Kamenogorsk, Kazakhstan, E-mail: mkarmenova@vku.edu.kz
Kumargazhanova Saule	Candidate of Technical Sciences, Professor of the School of Information Technologies and Intelligent Systems at D. Serikbayev East Kazakhstan Technical University, E-mail: saule.kumargazhanova@edu.ektu.kz
Karymsakova Indira	PhD, acting associate professor of the department of «IT technologies», Non-profit Joint-stock company "Shakarim University", Semey, Republic of Kazakhstan, E-mail: karymsakova.indira@mail.ru