

УДК 658.512.011

ОПТИМИЗАЦИЯ ИДЕНТИФИКАЦИИ МИКРООБЪЕКТОВ НА ОСНОВЕ МОРФОЛОГИЧЕСКИХ И ЯРКОСТНЫХ ХАРАКТЕРИСТИК ТОЧЕК ИЗОБРАЖЕНИЯ

Жуманов И.И.¹, + Сафаров Р.А.¹, Джуманов О.И.¹

¹ Самаркандский государственный университет имени Шарофа Рашидова,
Самарканд, Узбекистан

+ Rustammix.rs@gmail.com

Аннотация. Разработана методология оптимизации идентификации, распознавания, классификации микрообъектов на основе совмещенных с нейронными сетями динамических моделей с инструментами фильтрации импульсной помехи и шума, инородных частиц, других дефектов точек изображения методы и модели которой используются в системах палинологии, экологии, охраны окружающей среды, медицины и в других областях знаний. Разработаны механизмы идентификации, включающие инструменты выделения контура, сегментации, получения границ сегментов с жесткими и мягкими порогами, фильтрации с использованием морфологических характеристик изображения. Получены оценки погрешностей идентификации, обусловленных неадекватностью аппроксимации, интерполяции, экстраполяции контура изображения. Разработан программный комплекс распознавания и классификации изображения микрообъектов, в котором синтезированы кубический, биквадратический, интерполяционный сплайн-функции и вейвлет-преобразование.

Ключевые слова: изображение, микрообъект, идентификация, распознавание, классификация, фильтрация, эффективность, программный комплекс.

1 ВВЕДЕНИЕ

Исследование и разработка методов, механизмов (моделей и алгоритмов) идентификации микрообъектов, которые основаны на инструментах использования свойства и характеристик, составляющих в структуре изображения представляет актуальную тему, а также очень востребованы в производственно - технологических комплексах, системах палинологии, охраны окружающей среды, экологии, медицины и других областях знаний. Методология построения их способствует решению широкого спектра проблемных задач, связанных с распознаванием, классификацией микрообъектов, пыльцевых зерен, одноклеточных медицинских микроорганизмов, картинок полезных минералов и др. [1-3].

Настоящее исследование посвящено разработке конструктивных подходов, принципов, механизмов идентификации на основе фильтрации нестационарных составляющих изображение с использованием, совмещенных с нейронными сетями (НС) статистических, динамических моделей, а также инструментов извлечения статистических, динамических, специфических характеристик. Предполагается, что такие методы идентификации изображений обладают рядом несомненных достоинств, простотой реализации, высокой скоростью обработки информации [4-6].

2 ОСНОВНАЯ ЧАСТЬ

2.1 Механизм оптимизация идентификации микрообъектов с использованием особенностей в морфологии изображения

На этапе предварительной обработки информации микрообъектов, реализованы механизмы идентификации с инструментами выделения контура, сегментации, получения границ сегментов с жесткими и мягкими порогами, фильтрации, которые используют особенности в морфологии изображения [7-9]. Реализована вычислительная схема идентификации, распознавания и классификации микрообъектов, которая включает блоки ввода входного изображения, предварительной обработки

информации, определения объектов интереса для выделения признаков и особенностей в морфологии изображения и представления результатов.

Эффективность применения предложенной вычислительной схемы обоснована по реальным данным системы обработки рентгенографии грудной клетки (СХР) проблемы медицинской диагностики лиц больных с туберкулезом [3, 6, 8]. Определено, что изображения медицинских объектов имеют заметные шумы, различные уровни контраста и нуждаются в применении механизмов фильтрации для устранения «шума», «помехи», «инородных микрочастиц» и других дефектов.

Исследование начато с применения медианного фильтра в качестве базового инструмента борьбы с шумами Гаусса и Пуассона, который выполняет функции усиления контраста, определения и формирования границ сегментов, классификации микрообъектов. Инструменты фильтрации улучшают определения параметров изображения, в частности, отношения сигнал/шум, визуального вида, удаляет шумов и нежелательных частей в морфологии изображения [10-12].

Для классификации изображения предложено применение конкурирующей вероятностной нейронной сети (КВНС), которая нечувствительна к отклонениям сигнал/шум и генерирует значения параметра с точной оценкой вероятности. Особенностью предложенного подхода является то, что КВНС образует уровень конкуренции между гауссовыми ядрами и условными вероятностями. Применение инструмента связано с ранжированием значения условной вероятности в порядке убывания. Все части с признаками ядра изображения соревнуется между собой для классификации. При этом, используется только существенные значения условных вероятностей [9, 13, 14].

Аппроксимации точек выполняется усреднением многомерных нормальных гауссовых ядер с формированием произведения собственных одномерных ядер, центрированием их в каждом образце по распределению Гаусса [15-18]:

$$W_{i,j} = \frac{1}{(2\pi)^{\frac{d}{2}} \sigma^d} \cdot \exp\left(-\frac{x_{new} - x_{C_i,j}}{2\sigma^2}\right),$$

где: $|C_i|$ – мощность подмножества C_i ; $W_{i,j}$ – многомерное нормальное ядро; σ – разброс, который является регулируемым параметром; $X_{C_i,j}$ – вход классификатора; NC – набор входных изображений, подлежащих классификации $C_i = \{X_{C_{i,1}}, X_{C_{i,2}}, \dots, X_{C_{i,|C_i|}}\}$.

Числа ядер, выбранных в классе i определяет количество победителей NW_i . Отношение NW_i к общему количеству ядер в каждом классе i задается, как $\gamma_i = \frac{NW_i}{|C_i|} \rightarrow NW_i = \lceil \gamma_i |C_i| \rceil$, где

$\gamma_{i\min} = \frac{1}{|C_i|} \leq \gamma_i \leq 1$ - непрерывная переменная. Условная вероятность каждого класса рассчитывается, как:

$$P_i = \frac{1}{NW_i} \sum_{i=1}^{NW_i} w_{ij} = \frac{1}{\lceil \gamma_i |C_i| \rceil} \sum_{i=1}^{\lceil \gamma_i |C_i| \rceil} w_{ij}.$$

В традиционном подходе рассматривается условие $\gamma_i = 1$.

Эффективность механизма идентификации изображения микрообъектов зависит от значений параметров σ и γ_i , которые способствуют оптимизации классификации. При этом, операторы инструмента регулирования, расширения и сжатия размера обучающего набора данных выполняются до достижения максимальной производительности.

Реализована двухуровневая оптимизация, в которой σ рассматривается на верхнем уровне, а γ_i на нижнем уровне.

Оптимизация верхнего уровня предполагает, что все значения γ_i остаются постоянными и равным единице. На нижнем уровне, оптимум σ достигается путем регулирования значения параметра γ_i .

При классификации на основе КВНС, величины всех ядер соревнуются в порядке убывания, а также формируется новый класс 2, который должен соответствовать условию: $P_1^{КВНС} < P_2^{КВНС}$.

Рассмотрим механизм оптимизация идентификации микрообъектов на основе адаптивного обучения КВНС. Исследованы динамические нейронные сети.

В данном случае механизм выполняется в следующих этапах. На этапе 1 производятся ввод новых изображений x_{new} , расчет ядро Гаусса по каждому входному вектору, сортировка ядер в каждом классе, формирование их в порядке убывания, как:

$$\begin{aligned} \{\omega_{1,1}, \omega_{1,2}, \omega_{1,3}, \dots, \omega_{1,|C_1|}\} &= \{\omega'_{1,1}, \omega'_{1,2}, \omega'_{1,3}, \dots, \omega'_{1,|C_1|}\}; \\ \{\omega_{2,1}, \omega_{2,2}, \omega_{2,3}, \dots, \omega_{2,|C_1|}\} &= \{\omega'_{2,1}, \omega'_{2,2}, \omega'_{2,3}, \dots, \omega'_{2,|C_1|}\}; \\ \{\omega_{NC,1}, \omega_{NC,2}, \omega_{NC,3}, \dots, \omega_{NC,|C_{NC}|}\} &= \{\omega'_{NC,1}, \omega'_{NC,2}, \omega'_{NC,3}, \dots, \omega'_{NC,|C_{NC}|}\}. \end{aligned}$$

Далее из отсортированных ядер в классе I выбирается NW_i ядра с самым высоким рейтингом $NW_i = [y_i | C_i]$. Вместо использованных ядер используются выбранные на последнем шаге ядра. Вычисляется условная вероятность классификации для каждого класса:

$$\begin{aligned} \{\omega'_{1,1}, \dots, \omega'_{1,NW_1}\} &\rightarrow P_1 = \frac{1}{NW_1} \sum_{j=1}^{NW_1} \omega'_{1,j}; \\ \{\omega'_{2,1}, \dots, \omega'_{2,NW_2}\} &\rightarrow P_2 = \frac{1}{NW_2} \sum_{j=1}^{NW_2} \omega'_{2,j}; \\ \{\omega'_{NC,1}, \dots, \omega'_{NC,NW_{NC}}\} &\rightarrow P_{NC} = \frac{1}{NW_{NC}} \sum_{j=1}^{NW_{NC}} \omega'_{NC,j}. \end{aligned}$$

Выбирается класс с более высокой условной вероятностью, который назначается классом нового ввода при условии $x_{new} = \arg \max \{P_i\}, 1 \leq i \leq NC$.

Реализации инструментов адаптивного обучения КВНС протестированы на основе набора из 80 изображений медицинских микробиологических объектов с патологией легких и 50 изображений без их патологии.

Распознавание медицинских микробиологических объектов оценивалось по следующим коэффициентам: сходство Ω , сходство по среднему значению; расстояния до контура изображения. Эти метрики, в основном, зависят от следующих значений TP , TN , FP , FN и RN_{Cnt} , где TP – количество пикселей, правильно идентифицированной области; TN – количество пикселей, правильно детектированной области как фон; FP – количество пикселей, ложно идентифицированной области, FN – количество пикселей, ложно детектированной области как фон; RN_{Cnt} – количество опорных пикселей краев на контуре изображения.

Коэффициент сходства определяется, как:

$$\Omega = \frac{TP}{TP + FP + FN}.$$

Коэффициент сходство по среднему значению определяется, как:

$$D = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}.$$

Метрики задаются значениями от 0 до 1, при значении метрики равной 1, то применяется инструмент полностью, перекрывающейся сегментация. Классификационное значение каждого пикселя оказывает одинаковое влияние на результат вычисления расстояния до границы контура.

Достоверность оценки по метрике производится расстоянием до границы контура эталонного образца. Определяется минимальное расстояние каждой точки на границе S до контура R . При этом: $S_i, i = 1, \dots, n_S$, $R_j, j = 1, \dots, n_R$ – точки на обнаруженной границе объекта S , опорная граница эталонного объекта R . Минимальное расстояние точки S_i до R определяется, как $d(S_i, R) = \min_j \|r_j - s_i\|$ с коэффициентом:

$$A(S, R) = \frac{1}{2} \left(\frac{\sum_i d(s_i, R)}{n_S} + \frac{\sum_j d(r_j, R)}{n_R} \right).$$

Точности классификации объектов исследованы на основе совместных наборов обучения МС – 40 CXR изображения с патологиями и SH - 40 CXR изображений без патологии. В табл. 1 приведены количественные оценки эффективности механизма обучения КВНС на основе выявленных границ легких.

Таблица 1. Эффективность идентификации на основе метрики морфологических характеристик изображения микрообъектов

Характеристики морфологии изображения				
Коэффициенты	Минимум a	$a \pm 3\sigma$	Средний a	Максимум a
Сходства	0.952	0.969±0.016	0.968	0.985
Средней	0.965	0.964±0.012	0.967	0.990
Расстояние до контура объекта	0.957	0.975±0.015	0.970	0.989
среднее расстояние	1.247	1.642±0.323	1.523	2.551

Определено, что средняя точность классификации микрообъектов составляет 96%. Большая точность классификации достигается при наборе SH. Ошибка классификация CXR изображений составляет 4-5%. В табл. 2 приведены результаты экспериментального исследования.

Таблица 2. Оценки эффективности механизма идентификации с обучением КВНС

Изображения	МС – набор			SH – набор		
	Число	Классифицировано %		Число	Классифицировано %	
		Правильно	Неправильно		Правильно	Неправильно
без патологии	75	96.94	3.06	99	97.89	2.11
с патологией	50	96.58	3.42	80	95.77	4.23
Общее число	125	96.76	3.24	179	96.83	3.17

В таблице 3 приведен результат оценки эффективности механизма идентификации с инструментами фильтрации изображения микрообъектов.

Таблица 3. Эффективность инструментов фильтрации изображения микрообъектов

Фильтры	Расстояние до объекта
Превитта	24.68
Собеля	26.25
Со сдвигом и вейвлет - преобразованием	27.05
С обратным сдвигом и вейвлет – преобразованием	33.50
КВНС	34.36

2.2 Эффективность реализации механизмов идентификации микрообъектов на основе различных инструментов фильтрации импульсной помехи и шума изображения

Реализован механизм идентификации микрообъектов на основе инструмента, использующего векторной медианной фильтрации (ВМФ). Инструмент предназначен устранению шумовых частей, помех и других дефектов в структуре морфологии изображения микрообъектов.

Механизм обеспечивает сохранение наиболее важных признаков, свойств микрообъектов, которые используются при обнаружении, выделении, сегментации. Инструмент фильтрации изображения получает новые значения точек границ контура каждого компонента, выделяет окна для точек по значениям медианы в виде:

$$C_m(R_m, G_m, B_m);$$

$$(R_0, R_1, \dots, R_{p-1}, R_m), R_0 \leq R_1 \leq \dots \leq R_{p-1}; m = p/2;$$

$$(G_0, G_1, \dots, G_{p-1}, G_m), G_0 \leq G_1 \leq \dots \leq G_{p-1}; m = p/2;$$

$$(B_0, B_1, \dots, B_{p-1}, B_m), B_0 \leq B_1 \leq \dots \leq B_{p-1}; m = p/2.$$

Исследованы характеристики яркости, цветного кодирования в координатном пространстве компонент исходных изображений, которые задаются семью дискретными значениями: 0, 169, 77, 104, 40, 122, 125. Проводится фильтрация 5×5 каждой компоненты тона, которая задается 16 дискретными значениями: 0, 169, 77, 104, 122, 125, 126, 114, 115, 137, 109, 45, 46, 105, 35, 32.

Механизм сохраняет границ объектов, малоразмерных деталей, цветовых характеристики изображения.

Векторный медианный фильтр с минимальным расстоянием от среднего вектора $C_{cp}(R_{cp}, G_{cp}, B_{cp})$ определяется, как $R_{cp} = \frac{1}{p} \sum_{i=0}^{p-1} R_i$, где p - общее число элементов в окне.

Расстояние d от каждого элемента окна до вектора C_{cp} , располагается в неубывающем порядке $d_0 \leq d_1 \leq \dots \leq d_{p-1}$. Такой подход не обеспечивает сохранении границ объектов при классификации микрообъектов.

Сохранение информации о границах и текстурах достигается за счет того, что из всех компонентов набора изображений выбирается тот, в котором дисперсия минимальна. Тогда инструмент фильтрации изображения имеет вектор медианы компонента с минимальной дисперсией, отстоящий от вектора C_m на минимальное расстояние,

$$\min_{k \in [1, N_w]} \varepsilon_{wk} = \sum_{j \in [1, N_w]} \|C_j - C_{mk}\|,$$

где k - номер компоненты набора, w - номер окна фильтрации, N_w - число компонентов в i -м окне набора, p_w - размер апертуры, C_{mk} - оценка C_m в k -й апертуре.

Выбирается два размера для каждого окна. Первый, с минимальной дисперсией, а второй с оценкой медианы $C_{mk}(R_{mk}, G_{mk}, B_{mk})$.

Производится сравнение расстояния между оценками по пороговым значениям $T = (R_t, G_t, B_t)$.

Если расстояние будет больше нее, то инструмент фильтрации выбирается из апертуры большего размера W_2 , находящийся на минимальном расстоянии от медианы компонента.

Если расстояние между медианами меньше порога, то механизм фильтрации выбирается из апертуры меньшего размера W_1 .

Если это расстояние меньше порога, то выходным элементом фильтра является центральный элемент апертуры.

Определено, что механизм адаптивной фильтрации обеспечивает лучшее сохранение границ, использует оценку медианы вдоль границы объекта. Подавление малоразмерных деталей определяется размером апертуры окна меньшего размера.

Подавление импульсной помехи производится за счет медианной фильтрации в окне большего размера.

Рассмотрим методику построения механизма оптимизации идентификации микрообъектов на основе фильтрации шума и импульсной помехи изображения.

В качестве шума исследованы реализации случайного процесса, распределенные по нормальному закону со статистическими параметрами $(0, \sigma_{ш})$. Предполагается, что шум $n(l, m)$ накладывается на каждый компоненту изображения.

Моделирование шума и импульсной помехи производится следующим образом. Импульсная помеха I моделируется псевдослучайными координатами отсчетов, которая выбирается по равномерному закону распределения. Числа пораженных отсчетов из-за воздействия шума либо импульсной помехи задается вероятностью P . Сигналы отсчетов изображения моделируются по уравнению:

$$C(l, m) = \begin{cases} S(l, m) + n(l, m), & (1-P), \\ I(l, m), & P, \end{cases}$$

где $S(l, m)$ - отсчеты изображения.

В качестве порогового значения T выбирается среднеквадратическое отклонение аддитивного шума изображения по условиям:

$$C_{\text{вых}} = \begin{cases} \arg \min_{C_i \in W_2} \|C_i - C_{m2}\|, \|C_{m1} - C_{m2}\| > T; \\ C_c, & \|C_c - C_{m1}\| \leq T; \\ \arg \min_{C_i \in W_1} \|C_i - C_{m1}\|, \|C_{m1} - C_{m1}\| \geq T, \end{cases}$$

где C_c - центральный элемент апертуры, $C_{вых}$ - выходной элемент фильтра, C_{m1} - медиана, рассчитанная в апертуре меньшего размера, C_{m2} - медиана, рассчитанная в апертуре большего размера.

Критерий среднеквадратического отклонения (СКО) значений отсчетов изображения из-за ошибок оценивает качества фильтрации, как:

$$\sigma = \sqrt{\sigma_R^2 + \sigma_G^2 + \sigma_B^2}.$$

Определено, что наименьшая ошибка идентификации изображения достигается при векторной медианной фильтрации (АВМФ) и каскадном многоканальном медианном фильтре (КММФ). Исследованы характеристики идентификации, синтезированных с НС механизмов фильтрации, результаты которых приведены в табл. 4.

Таблица 4. Эффективность векторной медианной фильтрации на основе синтеза НС

Медианная фильтрация	σ_R	σ_G	σ_B	σ	ψ
КММФ	1,05	1,47	1,55	2,38	40,6
АМФ 3×3	2,23	3,33	4,37	5,9	32,67
М 3×1	2,88	3,8	4,04	6,24	32,2
М 5×1	3,96	5,3	5,53	8,62	29,4
МФ 3×3	6,82	9,15	8,8	14,41	24,95
МФ 5×5	7,52	10,25	9,67	15,97	24,1

Механизм КММФ обеспечивает более эффективную фильтрацию, который также обеспечивает лучшее сохранение информации о верхних частотах изображения. Получены оценки ошибок фильтрации для рассмотренных механизмов на идеальных изображениях, а также на изображениях, содержащих аддитивный шум и импульсную помеху, подтверждающие эффективности механизма.

Разработанный механизм реализован в виде функциональных модулей программного комплекса (ПК) визуализации, распознавания и классификации изображений микрообъектов. В табл. 5 показана эффективность КММФ при устранении аддитивного шума изображения.

Таблица 5. Эффективность механизма КММФ при устранении аддитивного шума

Медианная фильтрация	Аддитивный шум с нормальным законом распределения				
	σ_R	σ_G	σ_B	σ	ψ
5	1,28	1,68	1,81	2,78	39,2
10	3,31	3,55	3,81	6,17	32,3
15	7,22	7,35	7,74	12,89	25,9
20	11,14	11,37	11,79	19,8	22,2

Проведены два вида экспериментальных исследований в системе селекции и семеноводство зерновых культур на примере моделирования изображения пыльцевых зерен.

В первом случае, формируется и анализируется картинки образцов пыльцевых зерен, определяется пикселя точек изображения, т.е. «пыльцевые пятна», которые отличаются от фоновых пикселей после сегментации исходного изображения.

Эти точки изображения в пикселях классифицируются как «черная» или «белая». В первом эксперименте образованы окна изображений «пыльца» или «не пыльца». Модель сегментации «пыльцевых пятен» позволяет отличить пыльцевые пикселя от пикселей фона изображения.

Во втором случае эксперимента, модель сегментации применяется к новому набору окон, которые используются при классификации видов пыльцы. Модель изображения обучается на основе набора пикселей точек. В результате в среднем 9% пикселей помечены, как «не пыльца». В табл. 6 приведены оценки эффективности идентификации изображения микрообъектов с другими инструментами фильтрации, основанных на применении НС.

Предложен и реализован инструмент обучения модели изображения на основе применения хэш-кода, который позволяет вычислять числовую характеристику, установить индексы каждого пикселя, характеристики его окрестности. Каждый хэш-код указывает «класс формы» или категорию, к которой принадлежит пикселя и представляет собой целое число в диапазоне от 1 до N , где N - параметр, подлежащий оптимизации.

Контролируется число различных типов пыльцы, подлежащих распознаванию. Чем больше используется обучающие примеры, тем оправдана методика построения механизма идентификации микрообъектов.

Инструмент применения хэш-кода представлен в виде программного модуля, который включает операторы: идентификации пикселей, окружения пикселя, подлежащего классификации, адаптации размера 64-битных хэш-кодов, диапазона модульного деления.

Таблица 6 Эффективность инструментов фильтрации импульсных помех и шума

Помеха	КММФ	МФ 3x3	МФ 5x5	КМФ 3x1	КМФ 5x1
Без шума	0,39	18,74	20,09	0,78	3,74
	0,27	15,27	16,18	0,48	4,43
	0,42	15,95	16,79	0,46	4,61
	0,63	28,96	30,78	1,02	7,41
Нормальный (0,100)	9,70	19,13	21,28	7,11	7,58
	9,76	15,02	15,98	7,1	7,29
	9,71	15,74	16,86	7,1	7,41
	16,84	28,97	31,5	12,3	12,86
Импульсный (1%)	2,72	18,46	20,22	6,82	3,99
	2,44	15,07	16,29	6,82	4,57
	2,21	15,72	16,9	6,91	4,87
	4,27	28,54	30,98	11,86	7,78
Аддитивный (нормальный и импульсный)	1,06	19,94	20,74	7,34	7,68
	10,03	15,68	15,52	7,4	7,4
	9,97	16,4	16,41	7,52	7,54
	17,36	30,2	30,66	12,85	13,06

Исследованы размеры сеток 2×2 , 4×4 , 8×8 , 16×16 , 32×32 , 64×64 и 128×128 . Например, сетки 8×8 с интервалом в 1 пиксель означает, что учитываются все 64 соседних пикселей. А сетки 8×8 с интервалом в 2 пикселя означает, что будет учитываться каждый второй пиксель.

Для уменьшения размерности входного пространства вычислены хэш-коды, результаты которых формируются в БД, как для положительных, так и для отрицательных примеров.

Если положительные результаты больше, чем отрицательных, то пиксель-кандидат классифицируется как пыльца. В противном случае, как «негативный» пример, то есть как фон точек изображения в слайде.

3 ЗАКЛЮЧЕНИЕ

Разработана методология оптимизации идентификации, распознавания и классификации микрообъектов, основанных на использовании морфологических и яркостных характеристик точек в структуре изображения, включающая комплекс инструментов сегментации по порогам, различных фильтров. Для определения контуров объектов интереса реализован механизм векторной медианной фильтрации, совмещенной со сдвигом вейвлет – преобразованием.

Определено, что разработанные механизмы позволяют повысить точность идентификации с инструментом обнаружения границ объектов интереса на 2%, чем традиционная технология определения границ объектов на рентгеновских снимках СХР.

Предложена вычислительная схема идентификации изображений микрообъектов на основе инструмента адаптивного обучения КВНС, который протестирован при решении задач определения границ легких и распознаваний патологий грудной клетки, включая обнаружение опухолей на изображениях КТ. Средняя точность распознавания достигает 96 %.

Реализован механизм идентификации, распознавания, классификации изображения микрообъектов, включающий в себя инструменты с операторами конкуренции, вычисления гауссовых ядер эффективности, которых ярко проявляется на основе НС. Реализованы инструменты подавления импульсной помехи и шума на основе применения КММФ с АВМФ, которые обеспечивают сохранение границ объектов и малоразмерных деталей. Максимальная эффективность КММФ проявляется при устранении импульсных помех.

ЛИТЕРАТУРА

- [1] S.V. Kuleshov, Yu.A. Aksenov, A.A. Zaitseva “An approach to identifying the source of images from digital cameras” Innovative Science, 2015, №5. pp. 82-86.
- [2] Yu. V. Vizilter “Image processing and analysis in machine vision tasks: A course of lectures and practical exercises” Yu.V. Visilter [and others]. Moscow. Fizmatkniga. 2010 pp. 672.

- [3] *Jumanov, I.I., Safarov, R.A.* (2024). Control of Distorted Image Points Based on the Mechanism of Identification of a Micro-object with a Cosine Transform. In: Aliev, R.A., et al. 12th World Conference "Intelligent System for Industrial Automation" (WCIS-2022). WCIS 2022. Lecture Notes in Networks and Systems, vol 912. Springer, Cham. https://doi.org/10.1007/978-3-031-53488-1_24.
- [4] *Rendon R., Marcos V.* Pollen segmentation and feature evaluation for automatic classification in bright-field microscopy // *Computers and Electronics in Agriculture*, Vol. 110. P. 56–69.
- [5] *Chica M.* Standard methods for inexpensive pollen loads authentication by means of computer vision and machine learning. URL: <http://www.arxiv.org/ftp/arxiv/papers/1511/1511.04320.pdf>.
- [6] *Jumanov, Isroil I., and Rustam A. Safarov.* "Improving the efficiency of recognition of micro-objects based on the use of redundant information structures of images." *AIP Conference Proceedings*. Vol. 2700. No. 1. AIP Publishing, 2023. <https://doi.org/10.1063/5.0124901>.
- [7] *Chica M., Campoy P.* Discernment of bee pollen loads using computer vision and one-class classification techniques // *Journal of Food Engineering* 112. P. 50–59.
- [8] *Jumanov, I.I., Safarov, R.A.* (2023). Optimization of Identification and Recognition of Micro-objects Based on the Use of Specific Image Characteristics. In: Hu, Z., Zhang, Q., He, M. (eds) *Advances in Artificial Systems for Logistics Engineering III. ICAILE 2023. Lecture Notes on Data Engineering and Communications Technologies*, vol 180. Springer, Cham. https://doi.org/10.1007/978-3-031-36115-9_44.
- [9] *Jumanov I. I., Safarov R. A., Djumanov O. I.* Mechanisms for using image properties and neural networks in identification of micro-objects // *2022 IEEE 16th International Conference on Application of Information and Communication Technologies (AICT)*. – IEEE, 2022. – С. 1-6. DOI: 10.1109/AICT55583.2022.10013633.
- [10] *Jumanov, I. I., O. I. Djumanov, and R. A. Safarov.* "Algorithmic synthesis of computational schemes for optimization of identification and image recognition of micro-objects." *Artificial Intelligence, Blockchain, Computing and Security Volume 2*. CRC Press, 2024. 629-636.
- [11] *Ханжина Н.Е., Замятина Е.Б.* Использование классических методов и нейронных сетей для распознавания пыльцевых зерен // *Вестник Пермского университета. Математика. Механика. Информатика*. 2013. Вып. 4(23). С. 111–119.
- [12] *Черных А.С., Замятина Е.Б.* Исследование возможности применения ряда классических методов для распознавания пыльцевых зерен. Пермь: Изд-во Перм. гос. нац. исслед. ун-та, 2012.
- [13] *Jumanov I., Safarov R.* Optimization of recognition of microorganisms based on histological information structures of images // *2023 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*. – IEEE, 2023. – С. 679-684. DOI: 10.1109/ICIEAM57311.2023.10139033.
- [14] *Hecht-Nielsen R.* Counterpropagation Networks // *Proceedings of the IEEE First International Conference on Neural Networks*. - N.Y., 1987. - P.19-32.
- [15] *Тархов Д.А.* Нейронные сети. Модели и алгоритмы. Кн. 18. - М.: Радиотехника, 2005.
- [16] *Jumanov I. I., Safarov R. A., Djumanov O. I.* Optimization of micro-object identification by correcting distorted image points // *2023 International Russian Smart Industry Conference (SmartIndustryCon)*. – IEEE, 2023. – С. 83-88. DOI: 10.1109/SmartIndustryCon57312.2023.10110801.
- [17] *Жуманов И.И.* Оптимизация обработки изображений микрообъектов на основе рекуррентного обучения нейронной сети и имплекативного отбора информативных признаков // «Проблемы информатики и энергетики», Издательство «Фан» АН РУз, - Ташкент, 2016 - №4. - с.12.
- [18] *Safarov R.A.* Оптимизация обработки изображений пыльцевых зерен на основе использования метрических характеристик // *Муҳаммад ал-Хоразмий номидаги Тошкент ахборот технологиялари университети Фарғона филиали "Ёш олимлар, докторантлар ва тадқиқотчиларнинг онлайн илмий форуми"* 25.02.2023.

Поступила в редакцию 29.01.2025

Цитирование: *Жуманов И.И., Сафаров Р.А., Джуманов О.И.* (2025). Оптимизация идентификации микрообъектов на основе морфологических и яркостных характеристик точек изображения. *Международный Журнал Теоретических и Прикладных Вопросы Цифровых Технологий*, 8(1), –С. 105-113. <https://doi.org/10.62132/ijdt.v8i1.238>.

OPTIMIZATION OF IDENTIFICATION OF MICRO-OBJECTS BASED ON MORPHOLOGICAL AND BRIGHTNESS CHARACTERISTICS OF IMAGE POINTS

Jumanov I.I.¹, + Safarov R.A.¹, Djumanov O.I.¹

¹ Samarkand State University named after Sharof Rashidov, Samarkand, Uzbekistan

+ Rustammix.rs@gmail.com

Abstract. A methodology has been developed for optimizing the identification, recognition, and classification of micro-objects based on dynamic models combined with neural networks with tools for filtering impulse interference and noise, foreign particles, and other defects of image points; the methods and models of which are used in the systems of palynology, ecology, environmental protection, medicine, and other fields of knowledge. Identification mechanisms have been developed, including tools for contour extraction, segmentation, obtaining segment boundaries with hard and soft thresholds, and filtering using morphological characteristics of the image. Estimates of identification errors due to inadequacy of approximation, interpolation, and extrapolation of the image contour have been obtained. A software package for recognizing and classifying images of micro-objects has been developed, in which cubic, biquadratic, and interpolation spline functions and wavelet transformation have been synthesized.

Keywords: image, micro-object, identification, recognition, classification, filtering, efficiency, software package.