

УДК 658.512.011

ИДЕНТИФИКАЦИЯ, РАСПОЗНАВАНИЕ И КЛАССИФИКАЦИЯ МИКРООБЪЕКТОВ НА ОСНОВЕ РАЗРЕЖЕНИЯ 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. В статье разработаны научно – методические основы оптимизации процессов идентификации, распознавания, классификации микрообъектов на основе использования характеристик компонентов в структуре изображения. Предложены инструменты извлечения статистических, динамических, морфологических характеристик и метода разрежения избыточных точек на поверхности микрообъектов. Разработаны модифицированные алгоритмы обучения сети с инструментами настройки значений переменных, контроля погрешности по границам допустимых значений, учета стационарного, квази – стационарного и нестационарного поведения точек изображений при формировании обучающих наборов. Эффективность алгоритмов исследована по критериям среднеквадратической погрешности и скорости обработки информации. Разработан программный комплекс визуализации, распознавания, классификации изображений пылевых зерен, реализации которого протестированы при условиях априорной недостаточности, неопределенности и нестационарности процессов.

Ключевые слова: изображение, микрообъект, идентификация, распознавание, классификация, гибридная модель, нейронная сеть, оптимизация, программный комплекс.

1 ВВЕДЕНИЕ

В палинологии, медицине, охраны окружающей среды и экологии, в производственно- технологических комплексах управления сталкиваются с решениями задач учета, анализа, идентификации, распознавания, классификации, систематизации различных микрообъектов - пылевые зерна, одноклеточные микроорганизмы, медицинских объектов, картинки полезных минералов и картинки других предметных областях знаний [1, 2].

Современные методы, модели, алгоритмы, направленные на идентификации, распознавании, классификации микрообъектов, отличаются по функциональным возможностям, которые используются в виде программно-аппаратных средств, комплексов, систем компьютерного зрения и обработки изображений [3].

В традиционных технологиях микрообъекты идентифицируются с большой погрешностью и отличаются ненадежностью распознавания и классификации. Кроме того, существующие подходы не ориентированы на применение в условиях априорной недостаточности, неопределенности, не стационарности [4, 5].

Рассматриваемое исследование направлено на использовании динамических моделей различных видов, нейронных сетей (НС) различной топологии, изображения микрообъектов получаются из фото, видео камеры, цифрового микроскопа [6, 7].

Технология основана также на применении программных средств интерактивного измерения, подсчета, определения структуры, проведения статистического анализа, выделения и сегментации контуров изображений, формирования информативных (опорных) точек, регулирования значений переменных и оптимизации [8, 9].

Настоящая работа посвящена разработке методических основ, механизмов и инструментов оптимизации идентификации, распознавания и классификации микрообъектов на основе использования статистических, динамических, морфометрических, гистологических, сигнально- частотных, спектральных, яркостных характеристик изображения.

Предполагается разработка инструментов разрежения точек компонентов в структуре изображения, предварительной обработки информации, текстурной, контурной сегментации, фильтрации дефектных точек, оптимизации поиска при обучении гибридных с НС динамических моделей аппроксимации изображения.

2 ОСНОВНАЯ ЧАСТЬ

2.1 Идентификация, распознавания и классификации микрообъектов на основе инструментов использования свойств и характеристик компонентов в структуре изображения

Разработаны механизмы идентификации, распознавания и классификации микрообъектов, основанных на гибридных с динамическими моделями НС различной топологии, а также на инструментах, использующих свойства и характеристик таких компонентов, как статистических, динамических, гистологических, морфометрических, геометрических, сигнально-частотных, спектральных и яркостных характеристик точек в структуре изображения.

В механизмах идентификации микрообъектов НС выступает в роли идентификатора, распознавателя и классификатора изображения микрообъектов в условиях априорной недостаточности, параметрической неопределенности и нестационарности процессов [10, 11].

В механизмах идентификации микрообъектов как методика построения важного инструмента оптимизации решается задача разрежения точек, фрагментов, признаков в структуре компонентов изображения. Результаты задач используются при адаптивном формировании наборов обучения, проверки принадлежности опорных точек фрагментов изображения в требуемый класс. Исследована эффективность вычислительных схем оптимизации обучения гибридных НС на основе линейной и нелинейных регрессии, инструментов применения способов опорных векторов и дерево решений [12-14].

Рассматриваются инструменты оптимизации процессов идентификации, распознавания и классификации по точечным, фрагментным, признаковым, объектам поиска. Эти инструменты способствуют разделению точек в области поверхности изображения на достоверные классы. Считаются, что микрообъекты принадлежат двум, трем, либо большему числу классов.

При этом, функция кластеризации принимает одинаковое значение для каждой точки из области поверхности изображения. А для точки из других областей поверхности изображения ее значения будут различными.

На рис. 1 а), б) показаны графические принципы разделения точек n_i поверхности изображения и проверки ее принадлежности классификаторам микрообъектов K_I и K_{II} . Используются линейной (а) и нелинейные (б) функции, т.е. авторегрессионные модели с НС.

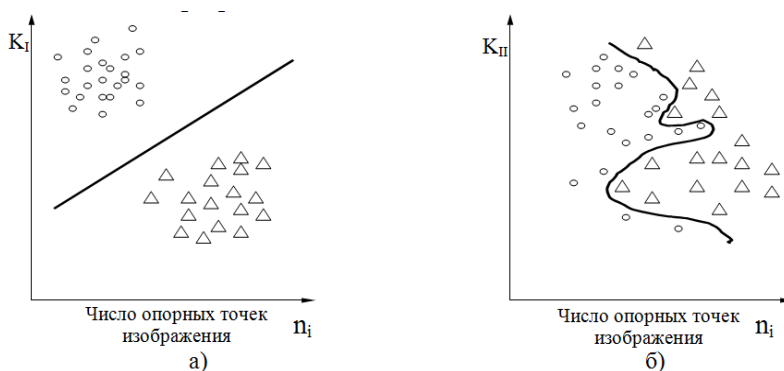


Рис. 1. Проверка принадлежности точки изображения нужному классу микрообъектов

При решении задач, определены приближения функции классификации в ограниченное либо существенно узкое множество точек, которые задаются в зависимости от принятых условий. Решена задача аппроксимации точек изображения микрообъектов на основе совмещенной с НС регрессионной модели [15].

Особенностью построенной гибридной модели в механизме идентификации микрообъектов является еще то, что в входные нейроны первого слоя НС представляются со значением точки изображения, а также параметром интенсивности составляющих ее пикселей. Выходной слой НС формируется числом нейронов, которые будут равны числу классов. Выходное значение каждого нейрона нормируется в интервале $[0, 1]$.

Эффективность механизмов идентификации микрообъектов оценена по вероятности принадлежности точки на выходе сети из поверхности изображения соответствующему классу.

Функция принадлежности P представляется $g: X \rightarrow Y$ аргументом, который отражается множеством точек $x_n \in X$. Последовательность точек изображения на выходе сети представляется опорным вектором с длиной n точек $y \in Y$. Гибридная НС используется как инструмент выполнения аппроксимирующей функции $h: X \rightarrow Y$ для всей области поверхности изображения.

Наборы обучения гибридной модели НС формируются по принципу $D = \{(x_0, y_0), (x_1, y_1), \dots, (x_m, y_m)\}$ для выполнения классификации микрообъектов.

Обучение гибридной с НС динамической модели оптимизируется по способу градиентного спуска, который связан с вычислениями частных производных по весам ω_{ij} . Вычислительная схема

$$\text{для каждого нейрона сети задается по схеме } \frac{\partial E}{\partial \omega_{ij}} = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_{ij}} \frac{\partial net_{ij}}{\partial \omega_{ij}}.$$

Эффективность обучения гибридной модели НС оценивается также по критерию среднеквадратического отклонения (СКО) значений точек целевого $g(x)$ и действительного векторов $h(x)$ [16, 17].

Результаты получены для трехслойной НС, НС Хопфильда, НС Кохенена, а также радиально базисной сети (РБС) [18, 19].

Результаты сравнены между собой при числе 25 базис - нейронов, сигмоидальной активационной функции. При этом, выходные нейроны сети считаются линейно связанными.

Сформированы случайным образом 500 векторов для проведения обучения: контрольного (КО) – 1; 367 тестового (ТО); эталонного обучений (ЭО) – 2.

В табл.1 приведены данные по результатам тестирования гибридной с НС модели изображения для трех типов сети.

Таблица 1. Эффективность гибридной с НС модели идентификации микрообъектов

Тип НС	Идентификации без фильтра точек изображения микрообъектов				Идентификации с фильтром дефектных точек изображения микрообъектов			
	1	2	3	4	1	2	3	4
Хопфильда	205	122	241	164	191	162	233	235
РБС	77	45	76	76	79	49	80	79
3- слойная	73	43	88	71	79	52	77	84
Кохенена	42	42	43	42	43	44	44	43

Исследована эффективность механизмов идентификации, распознавания и классификации изображения при инструментах фильтрации дефектных точек, образованных шумом, смазью и сдвигами точек на основе реализации фильтра Гаусса -1, медианного фильтра - 2, лапласиан фильтра – 3, лапласиан и медианный фильтров – 4.

В состав ЭО добавлены еще 150 векторов точек изображения, которые равномерно распределены по всему диапазону изменения значений.

2.2 Механизмы оптимизации процессов идентификации, распознавания и классификации микрообъектов на основе динамических свойств опорных точек поверхности изображения

Отметим, что эффективность традиционного алгоритма обучения НС, характеризуется прямой зависимостью от размера обучающего набора (числа точек поверхности изображения), времени итерации, значения критерия устойчивости гибридной модели обучения. Однако, в них практически не учитываются те требования, которые должны выполняться при выделении, использовании большого числа рассматриваемых в структуре изображения фрагментов, признаков и точек. Все эти факторы негативно отражаются и приводят снижению производительности обучения сетей. В результате производятся идентификации микрообъектов с низкой точностью, распознавании и классификации становятся низко достоверными.

Реализован инструмент, основанный на градиентной оптимизации гибридной модели обучения с НС. При этом реализации инструментов использования опорных векторов, динамических характеристик в последовательности точек, адаптивного формирования наборов обучения заметным образом проявляет свою эффективность. Реализован инструмент проверки принадлежности точек из поверхности изображения соответствующему классу на выходе гибридной сети. Для решения задачи на входе НС задается, наборы опорного вектора обучения, как $\{(x_0, y_0), (x_1, y_1), \dots, (x_m, y_m)\}$, где

x_i - i -я опорная точка на поверхности изображения; y_i - i -й класс принадлежности точки на выходе.

Точка x_i представляются в n -мерном векторе и нормализуются в интервале $[0, 1]$. Вычисляется расстояние с максимальным значением от начальной точки до ближайшей точки, которое позволяет выделить наилучший из множества возможных вариантов.

Для распознавания и классификации задается точки на плоскости с параметром w - нормализованного вектора значений.

Решено уравнение $wx - b = 0$. Оптимизации сводятся к минимизации числа элементов $\|w\|$. Эффективность выхода гибридной НС задается по функции

$$F(x) = \text{sign}((w, x) + b),$$

где b - параметр смещения точек изображения; $\hat{x}(x, x') = (\phi(x), \phi(x'))$ - ядро классификатора на выходе модели.

Для оптимизации получения w представляются линейные комбинации опорных векторов обучения как $w = \sum_{i=1}^n a_i y_i x_i$, a_i - множители Лагранжа [20, 21].

Для дальнейшего улучшения целевой функции классификации вводится инструмент использования динамических характеристик опорных точек в последовательности. Эти свойства последовательности опорных точек изображения представляется значениями коэффициентов статистических, корреляционных, логических связей.

В рассматриваемом исследовании большую значимость имеет задача адаптивного формирования обучающих наборов и использовании опорных векторов. При решении задачи требуется ограничивать сверху размеры наборов обучения. Требуется прореживание набора за счет отбора информативных точек, путем декорреляции и устранения ненужных фрагментов, признаков на поверхности модели изображения.

Предложен принцип представления опорного вектора обучения НС на основе построения матрицы

$$U = (u_1, u_2, \dots, u_p),$$

где u_1, u_2, \dots, u_p - элементы ковариационной матрицы; p - собственный вектор ковариационной матрицы, элементы которой выбираются в порядке убывания соответствующих им собственных значений.

Опорные вектора обучающих наборов представляются, как суммы линейных компонент с ковариационной матрицей точек изображения

$$\frac{1}{m} \sum_{i=1}^m x_i = \frac{1}{m} \sum_{i=1}^m (x_i x_i^T).$$

При оптимизации базисной функции классификации реализованный инструмент основан на способ выбора главного компонента.

Представим методику разрежения точек на поверхности изображения. Модель изображения микрообъекта представляется, как

$$x^{PCA} = U^T x.$$

Разреженная поверхность изображения представляется в виде $x = \sum_{i=1}^k a_i \phi_i$ так, чтобы $k > n$.

Наборы обучения формируются из опорных точек $x \in R^n$.

Для разрежения применен инструмент, который основан на принцип статистического кодирования последовательности точек на поверхности изображения [22-24].

Эффективность обобщенного алгоритма обучения трехслойной НС оценивается по значениям показателя качества идентификации с параметрами X - нормализованное отклонение, X' - абсолютное отклонение $r(X, X') = 1 - \frac{X - X'}{X}$.

Соответствие входа и выхода гибридной модели НС оценивается по модели

$$J(x, a, \phi) = \sum_{j=1}^m \left(x^j - \sum_{i=1}^k a_i^j \phi_i \right)^2 + \beta \sum_{i=1}^k S(a_i^j),$$

где x, a, φ - переменные опорного вектора набора обучения, которые использует инструмент при оптимизации числа точек на поверхности изображения; $y = \sum_{i=1}^k a_i^j \varphi_i$ - аргументы, в которых значения a_i^j будут равным «0»; $S(a_i^j)$ - функция разрежения точек на поверхности изображения; $S(a_i^j) = \log(1 + (a_i^j)^2)$ - функции разрежения точек на поверхности изображения.

С учетом принятых условий модель соответствия входа и выхода гибридной модели НС запишется $E(x, y) = \sum_{j=1}^m x^j + \beta \sum_{i=1}^k \log(1 + (a_i^j)^2)$.

Требуется, что при некоторых допущениях инструмент максимизировал значение следующего функционала эффективности для систем обработки изображения микрообъектов

$$E(x, y) = \sum_{u,v} \omega(x, y) \beta,$$

где I – интенсивность пикселей в точке изображения в пределах «окна»; $\beta = [I(x+u, y+v) : I(x, y)]$ - коэффициент разрежения число точек на поверхности изображения.

На рис. 2 показаны графики функции $E(x, y)$ эффективности систем обработки изображения микрообъектов при гибридной с трехслойной НС динамической модели обучения.




Рис. 2. Эффективности обучения НС

Архитектуры НС построены числами 36×36 нейронов (рис. 1 а); б) 64×64 нейронов в скрытом слое (рис. 1 б). Графики получены при значениях β : 1, когда $\beta = 0,5$; 2, когда $\beta = 1,5$; 3, когда $\beta = 2,5$; 4, когда $\beta = 3,5$; 5, когда $\beta = 4,5$.

На базе 450 изображений составлены 5 - тестирующие наборы обучения, каждая из которых включает в среднем 12 фрагментов и не менее 10 признаков.

В табл. 2 приведены результаты исследования эффективности инструмента разрежения точек на поверхности изображения микрообъектов по значениям критерия среднеквадратического отклонения при обучении гибридной модели НС, которые равны в среднем на 13%.

Таблица 2. Результаты оценок ошибок обучения гибридной модели НС различных топологий

Тип НС	Идентификации без фильтра точек изображения микрообъектов				Идентификации с фильтром дефектных точек изображения микрообъектов			
	1	2	3	4	1	2	3	4
Хопфильда	0,021	0,020	0,031	0,025	0,030	0,047	0,035	0,034
РБС	0,024	0,022	0,023	0,027	0,034	0,056	0,041	0,048
3- слойная	0,027	0,024	0,028	0,031	0,036	0,059	0,042	0,048
Кохенена	0,023	0,021	0,025	0,028	0,036	0,051	0,039	0,038

Определено, что целесообразно применение сверточной НС при преобразовании точек входного изображения из двумерной структуры в трехмерные. При такой сети, межнейронные связи входного, сверточного, скрытого слоев разряжаются, т.е., ограничивается их число [25].

Каждый нейрон скрытого слоя связан только с ограниченным локальным (не имеющим разрывов) участком изображения. НС использует общие, или разделяемые веса, накладывает ограничения на их количества. Обучение сети проводится на основе метода обратного распространения ошибок так, чтобы каждый нейрон скрытого слоя имел набор весов с другими нейронами сверточных слоев.

3 АНАЛИЗ РЕЗУЛЬТАТОВ ИССЛЕДОВАНИЯ

Исследована эффективность алгоритмов обучения НС прямого и обратного распространения ошибок и алгоритмов обучения с и без учителя.

Установлено, что гибридная модель на основе НС Кохонена с инструментами фильтрации дефектных точек изображения по скорости обучения превосходит скорости других модификаций моделей изображения 1,7 до 5,4 раза. Скорость обучения гибридной модели при РБС превосходит своих аналогов на 22%. Эти преимущества НС достигаются за счет применения свойств самообучения, самоорганизации, самоадаптации сети, а также инструмента разрежения точек на поверхности изображения.

Эффективность алгоритмов гибридных моделей обучения НС в механизмах идентификации, распознавания и классификации микрообъектов исследована по критериям минимальной среднеквадратической ошибки, достоверности распознавания и кластеризации, коэффициентам трудоемкости и стоимости обработки изображения микрообъектов на примере данных различных предметных областях знаний. Реализована методика, которая позволяет доказать конструктивность принятых подходов к оптимизации процессов идентификации, распознавания и классификации путем сравнения схожих свойств характеристик входного изображения и изображения модального примера в базе микрообъектов. Требуется, чтобы выходы сети должны точно соответствовать результатам, полученным по базисной функции классификации. Проверено максимальное соответствие исходного и эталонного фрагмента изображений.

Определено, что обобщенный алгоритм гибридной обучения НС с инструментами отбора информативных точек изображения, статистического кодирования, разрежения, формирования набора обучения производит согласованное слежение и определяет регрессии наименьшего угла. Устойчивость обучения сети обеспечивается за счет инвариантного преобразования участков изображений на каждом слое НС. Инструменты компактного представления преобразованного участка изображений и разрежения способствует снижению размерности и в совокупности обеспечивают устойчивость обучения сети. А при использовании метода прямого распространения ошибок сеть основывается на операции свертки входного изображения. При этом, используются «карты признаков» в виде двумерной матрицы, которая представляет свертки отдельного фильтра.

Исследована эффективность инструментов фильтрации дефектных точек изображения на основе моделей Канни, Собеля, Габора и вейвлет – преобразований.

Для проверки качества и достоверности результатов исследования разработан программный комплекс (ПК) идентификации, распознавания и классификации микрообъектов, который основан на инструментах:

- представления компонентных характеристик в структуре изображения;
- выделения границ фрагментов; снижения влияний составных фрагментов таких, как «освещение» и «тени»;
- фильтрации помех, дефектных точек изображений; функции $\omega(x, y)$ - скользящего «окна»;
- выбора любых комбинаций значений параметров (u, v) при их сдвиге в двумерной плоскости.

В табл. 3 приведены результаты сравнения временных характеристик и достоверности распознавания микрообъектов на основе различных НС.

Таблица 3. Сопоставление положительных характеристик различных моделей НС

Типы НС	Ошибка распознавания		Время обучения (мкс)	
	Набор 1	Набор 2	Набор 1	Набор 2
Хопфильда	3,072	4,396	21,6	27,8
РБС	3,327	4,159	18,8	19,0
3- слойная	2,776	3,762	16,6	17,9
Кохенена	2,811	3,875	17,5	19,1

Инструменты проявляют положительные свойства в задачах визуального слежения за смещением, смазью точек изображений, а также при редукации большего числа точек и адаптивном формировании наборов обучения. Инструменты проявляют способности при устранении окклюзии изображений. Установлено, что при явлениях окклюзии изображений обобщенный алгоритм с механизмом фильтрации демонстрируют, не корректности распознавания микрообъектов до 10%.

Увеличение числа нейронов в слоях НС незначительно повышает достоверность распознавания изображения и сопровождается существенными вычислительными расходами.

Обобщенные алгоритмы обучения НС с инструментами фильтрации дефектных точек изображения демонстрирует гибкость, более корректное распознавание и классификации микрообъектов. Эффективность обучения гибридной с НС динамической модели повышается за счет регулирования

весов нейронных связей, статистического кодирования, разрежения числа признаков, фрагментов и точек изображения.

В табл. 4 даны результаты идентификации на основе трехслойной НС в составе инструментов использования характеристик избыточных компонентов в структуре изображения пыльцевых зерен.

Таблица 4. Качество идентификации характеристик пыльцевого зерна

Характеристики пыльца	a)	b)	c)	d)
Споры	79 ± 4	95 ± 3	96 ± 3	96 ± 3
Экзины	82 ± 3	92 ± 3	93 ± 3	94 ± 2
Цитоплазмы	84 ± 3	97 ± 4	97 ± 3	97 ± 3
Ретикулы	72 ± 3	91 ± 3	93 ± 4	93 ± 3
Частоты	78 ± 2	89 ± 4	90 ± 3	91 ± 3
Окно	73 ± 3	90 ± 4	91 ± 4	91 ± 3
Начальная граница интенсивности пикселей точки со сдвигом	71 ± 3	90 ± 4	91 ± 4	91 ± 4
Средне - взвешенное значение границы	77 ± 4	94 ± 2	95 ± 3	96 ± 4

Определено, что в задачах распознавания и классификации пыльцевых зерен отдельные фрагменты изображений - углы, детали контуров поддаются реконструкции более успешно, чем основные характеристики пыльца - спора, экзина, ретикула, цитоплазма, частоты и др.

Алгоритм обучения НС Кохенена продемонстрировал положительные результаты среднеквадратической погрешности обучения, чем трехслойная НС. Выигрыш по времени обучения сети Кохенена составляет 9%, чем другие НС.

4 ЗАКЛЮЧЕНИЕ

Разработаны конструктивные подходы, принципы, методы оптимизации идентификации изображений для распознавания и классификации микрообъектов на основе инструментов адаптивного обучения НС, которые позволяют извлекать информации о пространственных взаимоотношениях локальных признаков и фрагментов, обеспечивать корректного распознавания произвольно ориентированных трехмерных микрообъектов. Разработана модель распознавания трехмерного микрообъекта с алгоритмами обучения, распознавания на основе иерархического сопоставления локальных признаков и фрагментов, которые содержат информацию о принадлежности изображения к его классу, имеет ограниченный размер, параметры локализации объекта, расположения его в трехмерном пространстве.

Предложены статистические механизмы, позволяющие оценить точность и полноту распознавания, определить долю успешно распознанных изображений из общей выборки, а также оценить точность определения параметров локализации объекта. Исследован вариант построения гибридной модели на основе НС, которая состоит из входного, сверточного, скрытого - субдискретизационного и выходного - полносвязанного слоев. Устойчивость обучения сети обеспечивается за счет инвариантного преобразования участков изображений на каждом слое НС. А инструмент компактного представления преобразованного участка изображений и разрежения способствуют снижению размерности и обеспечивает устойчивость обучения сети.

ЛИТЕРАТУРА

- [1] *Визильтер, Ю.В.* (2010). Обработка и анализ изображений в задачах машинного зрения: Курс лекций и практических занятий. - М.: Физматкнига, 672 с.
- [2] *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.
- [3] *Безуглов Д.А., Рытиков С.Ю., Юхнов В.И., Швидченко С.А.* (2012). Выделение контуров изображений с использованием метода вейвлет - дифференцирования // Современные проблемы радиоэлектроники: IV международная научная конференция, г. Ростов на Дону, с. 203-212.
- [4] *Маланин В.В., Полосков И.Е.* (2005). Методы и практика анализа случайных процессов в динамических системах. Изд-во: РХД, 314 с.

- [5] *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>.
- [6] *Шашев Д.В.* (2016). Обработка изображений в интеллектуальных медицинских робототехнических системах // Информационно-измерительная техника и технологии, Томск, С. 544 - 550.
- [7] *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.
- [8] *Осовский С.* (2002). Нейронные сети для обработки информации. — М.: Финансы и статистика, -304 с.
- [9] *Джуманов, О.И.* (2016). Методы адаптивной обработки данных на основе механизмов гибридной идентификации с настройкой параметров моделей нестационарных объектов. Проблемы информатики, (2 (31)), 13-20.
- [10] *Кузнецов, В.И.* (2008). Адаптивная фильтрация в задачах параметрической идентификации нестационарных динамических систем. Двойные технологии, (1), 29-34.
- [11] *Jumanov, I.I., Djumanov, O.I., Safarov, R.A.* (2021). Mechanisms for optimizing the error control of micro-object images based on hybrid neural network models // AIP Conference Proceedings, 2021, 2402, 030018. <https://doi.org/10.1063/5.0074019>.
- [12] *Кричевский, М.Л., Мартынова, Ю.А.* (2022). Выбор варианта развития предприятия методами машинного обучения. Вопросы инновационной экономики, 12(2), 1099-1110.
- [13] *Баев Н.О.* (2017). Использование метода опорных векторов в задачах классификации // Международный журнал информационных технологий и энергоэффективности. Т. 2(2). С. 17-21.
- [14] *Росляков, А.В., Пальмов, С.В., Глушаков, Е.В.* (2019). Исследование методов искусственного интеллекта для построения классификационной модели успешности реализации транзакции в сети общеканальной сигнализации. Моделирование, оптимизация и информационные технологии, 7(3), 23-23.
- [15] *Неделько, В.М.* (2014). Регрессионные модели в задаче классификации. Сибирский журнал индустриальной математики, 17(1), 86-98.
- [16] *Гржибовский, А.М.* (2008). Выбор статистического критерия для проверки гипотез. Экология человека, (11), 48-57.
- [17] *Потапкин, К.О.* (2018). Искусственные нейронные сети. Нейронная сеть Хопфилда. In XLVI Огарёвские чтения (pp. 315-320).
- [18] *Манжула, В.Г., Федяшов, Д.С.* (2011). Нейронные сети Кохонена и нечеткие нейронные сети в интеллектуальном анализе данных. Фундаментальные исследования, 4, 108-114.
- [19] *Алёшин, Н.А.* (2020). Сети радиальных базисных функций. In European Scientific Conference (pp. 11-13).
- [20] *Грешиков, А.А.* (2014). Математические методы принятия решений. Издательство МГТУ им. НЭ Баумана.
- [21] *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.
- [22] *Зубакин, И.А., Фахми, Ш.С.* (2008). Обзор методов кодирования и декодирования изображений. Вопросы радиоэлектроники. Серия: Техника телевидения, (1), 13-41.
- [23] *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.
- [24] *Ошаровская, Е.В., Самусь, Н.С.* (2015). Статистическое кодирование топологии сеток 3d изображений. Вимірювальна та обчислювальна техніка в технологічних процесах, (1), 248-251.

- [25] *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.

Поступила в редакцию 25.04.2025

Цитирование: *Жуманов И.И., Сафаров Р.А., Джуманов О.И.* (2025). Идентификация, распознавание и классификация микро-объектов на основе разрежения точек изображения. *Международный журнал теоретических и прикладных вопросов цифровых технологий*, 8(3), –С. 29-37. <https://doi.org/10.62132/ijdt.v8i3.283>.

IDENTIFICATION, RECOGNITION, AND CLASSIFICATION OF MICRO-OBJECTS BASED ON IMAGE POINT SPARSIFICATION

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. Scientific and methodological principles for optimizing the processes of identification, recognition, and classification of micro-objects have been developed based on the use of component characteristics in the image structure. Tools for extracting statistical, dynamic, and morphological characteristics and a method for rarefying excess points on the surface of micro-objects have been proposed. Modified network training algorithms have been developed with tools for adjusting variable values, error control at the boundaries of acceptable values, and taking into account stationary, quasi-stationary, and non-stationary behavior of image points when forming training sets. The efficiency of the algorithms was studied according to the criteria of mean square error and information processing speed. A software package for visualization, recognition, and classification of pollen grain images was developed, the implementations of which were tested under conditions of a priori insufficiency, uncertainty, and non-stationarity of processes.

Keywords: image, micro-object, identification, recognition, classification, hybrid model, neural network, optimization, software package.