

МЕЖДУНАРОДНЫЙ ЖУРНАЛ ТЕОРЕТИЧЕСКИХ И ПРИКЛАДНЫХ ВОПРОСОВ ЦИФРОВЫХ ТЕХНОЛОГИЙ

P-ISSN: 2181-3086

E-ISSN: 2181-3094

Самаркандский филиал Ташкентского университета информационных технологий имени Мухаммада ал-Хоразмий

WEB: <https://ijdt.uz/index.php/ijdt>



ОПТИМИЗАЦИЯ РАСПОЗНАВАНИЯ ИЗОБРАЖЕНИЙ ПЫЛЬЦЕВЫХ ЗЕРЕН НА ОСНОВЕ ПАРАМЕТРИЧЕСКОЙ ИДЕНТИФИКАЦИИ

Исраил Жуманов¹, Рустам Сафаров¹

¹ Самаркандский государственный университет имени Шарофа Рашидова,
Самарканд, Узбекистан
isroil.jumanov2019@gmail.com, rustammix.rs@gmail.com

Цитирование: Жуманов И.И., Сафаров Р.А. (2024). Оптимизация распознавания изображений пыльцевых зерен на основе параметрической идентификации. Международный Журнал Теоретических и Прикладных Вопросов Цифровых Технологий, 7(3), –С. 92-98. <https://doi.org/10.62132/ijdt.v7i3.201>

Дата поступления: 24.05.2024

Дата принятия: 29.06.2024

Дата печати: 30.09. 2024

DOI: <https://doi.org/10.62132/ijdt.v7i3.201>

УДК 658.512.011

ОПТИМИЗАЦИЯ РАСПОЗНАВАНИЯ ИЗОБРАЖЕНИЙ ПЫЛЬЦЕВЫХ ЗЕРЕН НА ОСНОВЕ ПАРАМЕТРИЧЕСКОЙ ИДЕНТИФИКАЦИИ

Жуманов И.И.¹, Сафаров Р.А.¹

¹ Самаркандский государственный университет имени Шарофа Рашидова,
Самарканд, Узбекистан
isroil.jumanov2019@gmail.com, rustammix.rs@gmail.com

Аннотация. В статье рассматривается разработка методов оптимизации идентификации пыльцевых зерен с использованием статистических, динамических, текстурных и специфических характеристик изображений. Исследованы и предложены механизмы точечной, нелинейной проверки соответствия контуров вводимого и эталонного объектов - пыльцевых зерен, а также регулирования параметров растровых изображений. Реализованы механизмы редукции нулевых точек контура, уменьшения размерности растров, масштабирования, порогового и уровневого контроля, кодирования и размещения изображений микрообъектов на основе пирамидальной модели, отбора опорных точек контура, когнитивного анализа, поиска точек с отжигом, запретом, на основе стохастического моделирования по усеченной цепи Маркова. Реализован комплекс программ идентификации, распознавания, классификации и систематизации пыльцевых зерен на языке C++ в среде параллельных вычислений «CUDA».

Ключевые слова: идентификация, изображение, пыльцевое зерно, распознавание, классификация, эффективность, погрешность, трудоемкость, комплекс программ.

I. ВВЕДЕНИЕ

Современные технологии идентификации изображений микрообъектов, в частности пыльцевых зерен, микроорганизмов в составе крови, отпечатки пальцев, картинки полезных минералов в горной массе представляет большую теоретическую и практическую значимость в системах экологии и охраны окружающей среды медицинской диагностики, управления производственно-технологическими комплексами решения задач, которых проводятся в условиях априорной недостаточности, параметрической неопределенности, низкой достоверности данных [1, 2].

В настоящем исследовании предложены основные подходы, модели и алгоритмы распознавания и классификации изображений пыльцевых зерен, которые направлены на реализации механизмов оптимизации с адаптирующимися, самоорганизующимися, аппроксимирующие свойствами нейронных сетей (НС), а также использованием особенностей моделей [3, 4].

Механизмы оптимизации с извлечения скрытых знаний, свойств, закономерностей данных расширяют возможностей алгоритмов в условиях большой неопределенности, а также будут востребованы при разработке программных комплексов визуализации, распознавания, классификации изображений микрообъектов.

II. ОСНОВНАЯ ЧАСТЬ

2.1 Механизмы оптимизации идентификации изображений микрообъектов.

Разработана методология идентификации в компьютерных системах зрения микрообразов на основе НС различной топологии [5, 6]. Определен спектр подходов, направленных на распознавание изображений пыльцевых зерен с применением информационных технологий [7, 8].

Выделены характерные черты программных обеспечений, встроенных специализированных пакетов программ, которым относятся пакеты Statistica Neural Networks, MFC/C++ Nov, NeuroOffice, Synax, NeuroIterator, NeuroShell, NeuroBuilder, выполняющие функции генерации, моделирования и обучения, поддержки визуального отображения процесса. Анализ многочисленных исследований за последних 10-15 лет свидетельствует о том, что значительный интерес представляет исследование и разработка технологии идентификации, распознавания и классификации пыльцевых зерен на основе механизмов использования статистических параметров, динамических и специфических характеристик, имитационных моделей изображений, которые должны выполняться с наименьшими затратами [7, 9].

Решены задачи модифицирования вычислительных схем структурных компонентов НС прямого и обратного распространения, рекуррентного обучения трехслойной НС.

Построены механизмы регулирования значимости влияний входов на выходы сети, редукции избыточных связей нейронов в слоях, числа слоев и нейронов в слоях, весовых коэффициентов нейронов, межнейронных связей, переменных алгоритма обучения сети на основе квантования обучающих выборок, суперпозиции непрерывных функций «входы и выходы» [10, 11].

Построены вычислительные схемы адаптивного обучения НС с механизмами имитации динамики объекта, выделении и сегментации контура, фильтрации шума, помех, кластеризации изображения [12, 14, 20].

Разработаны алгоритмы оптимизации кодирования и размещения изображений на основе пирамидальной модели, отбора информативных (опорных) точек контура, применения когнитивного анализа, механизмов поиска с отжигом, запретами, стохастического моделирования.

Проведен алгоритмический синтез относительно простых вычислительных схем для обеспечения высокой скорости обработки информации и меньшей погрешности идентификации, которые позволяют оптимизировать распознавания и классификации микрообъектов [17, 18, 19].

Определено расстояние в пространстве точек изображения, которое позволяет сформировать рациональное число опорных точек контура для эффективной идентификации.

Новая модель изображения I задается набором $\Psi = \{V_1, \dots, V_N\}$, состоящего из наиболее информативных опорных точек контура I .

Информативность точек контура изображения определяется по методике вычисления энтропии многомерной вероятности вида $P(\|\xi_{ij}\|)$, где ξ_{ij} – набор точек контура изображения микрообъекта, которое представляется в виде матрицы.

Методика позволяет находить оценки энтропии, в которых учитываются, как неравномерность распределения, так и корреляция между точками контура изображения по матрице данных.

Верхняя оценка условной энтропии оценивается, как

$$\hat{H}(x_{ij} / \|\xi_{ij}\|) = \frac{\min_{x_{ij}^{(1)}, x_{ij}^{(k)} \in \|\xi_{ij}\|} H(x_{ij} / x_{ij}^{(1)}, x_{ij}^{(k)})}{x_{ij}^{(1)}, x_{ij}^{(k)} \in \|\xi_{ij}\|}, \quad (1)$$

где $x_{ij}^{(1)}, x_{ij}^{(k)} = x_{ij}^{(1)}, x_{ij}^{(2)}, \dots, x_{ij}^{(k)}$.

Энтропии матрицы размерности $n \times s$, где $n, s \geq 1$, сводится к вычислению энтропии наборов по $k+1$ элементов матрицы (k -грамм). Для малых k , использовано следующее соотношение

$$H(x_{ij} / x_{ij}^{(1)}, x_{ij}^{(k)}) = H(x_{ij}, \overline{x_{ij}^{(1)}, x_{ij}^{(k)}}) - H(x_{ij}^{(1)}, x_{ij}^{(k)});$$

$$H(\|\xi_{ij}\|) = H(x_{ij}, \overline{x_{ij}^{(1)}, x_{ij}^{(k)}}) + \sum_{r=k+1}^{ns-1} \frac{\min_{x_{ij}^{(1)}, x_{ij}^{(k)} \in x_{ij}^{(1)}, x_{ij}^{(r)}} H(x_{ij}^{(r)} / x_{ij}^{(1)}, x_{ij}^{(k)})}{x_{ij}^{(1)}, x_{ij}^{(k)} \in x_{ij}^{(1)}, x_{ij}^{(r)}}.$$

Усредненная энтропии k -грамм находится в виде

$$\tilde{H}(x_{ij}^{(1)}, x_{ij}^{(k)}) = - \sum_{\xi_{ij}^{(1)}, \xi_{ij}^{(k)}} \tilde{P}(\xi_{ij}^{(1)}, \xi_{ij}^{(k)}) \log \tilde{P}(\xi_{ij}^{(1)}, \xi_{ij}^{(k)}) \quad (2)$$

где $\xi_{ij}^{(1)}, \xi_{ij}^{(k)} \in x_{ij}^{(1)}, x_{ij}^{(r)}$ – конкретная реализация k -грамм, $\tilde{P}(\xi_{ij}^{(1)}, \xi_{ij}^{(k)})$ – вероятность появления соответствующих k -грамм.

Энтропии точек контура изображения использованы при оценке ёмкости памяти системы обработки изображений. Получены коэффициенты сокращения избыточности информации.

Установлено, что информационная избыточность по двумерной условной энтропии позволяет сократить объем памяти более, чем в 1,5 раза. Энтропии k -грамм приводит к дополнительному сокращению избыточности информации.

Для расширения возможностей методов визуализации изображений, распознавания и классификации микрообъектов разработана вычислительная схема оптимизации идентификации контуров с механизмами фильтрации шумовых составляющих, сегментации и кластеризации.

2.2. Адаптивная идентификации изображений микрообъектов на основе трехслойной НС. Осуществлена систематизация и проведена параметризация моделей активационных функций.

При подборе функции активации исследованы зависимости:

$$\sigma^1(\gamma u) = \tanh(\gamma u) = \frac{1 - e^{-2\gamma u}}{1 + e^{-2\gamma u}},$$

$$\sigma^2(\gamma u) = \frac{\gamma u}{\sqrt{1 + \gamma^2 u^2}}, \quad \sigma^3(\gamma u) = \sin\left(\frac{\pi}{2} \gamma u\right),$$

$$\sigma^4(\gamma u) = \frac{2}{\pi} \operatorname{arctg}(\gamma u), \quad \sigma^5(\gamma u) = \gamma u - \frac{\gamma^3}{3} u^3. \quad (3)$$

Установлено, что функции активации упрощают процесс адаптации путем введения унифицированной схемы обучения формального нейрона.

Исследован случай, когда в НС с двумя слоями в скрытом слое у каждого нейрона одна и та же нелинейная функция активации, а выходной слой состоит из одного элемента, представляющего адаптивный сумматор.

Разработаны модели конструирования структуры НС, которые при аппроксимации нелинейных зависимостей производят оценки значимости влияния входов на выход НС, настраивать параметры сети, удалять избыточных связей нейронов между слоями.

Доказано, что добавление дополнительных весов в скрытый слой НС способствует повышению эффективности идентификатора изображения.

Новый добавленный нейрон приводит к появлению аддитивной добавки

$$\tilde{y}(\tilde{w}, x) = \tilde{w}_{q+1} f\left(\sum_{j=1}^l \tilde{w}_{q+1,j} x_j\right),$$

где $\tilde{y}(\tilde{w}, x)$ - выход сети, зависящий от вектора весов $w \in R^n$, x - входной вектор при $x \in R^l$ и $\tilde{w} = [\tilde{w}_{q+1,1} \ \tilde{w}_{q+1,2} \ \dots \ \tilde{w}_{q+1,l} \ \tilde{w}_{q+1}]$.

$y_{new}(w, \tilde{w}, x) = y(w, x) + \tilde{y}(\tilde{w}, x)$ - выход НС.

Разработан механизм, основанный на использовании совмещенной модели НС и линейной фильтрации нестационарных составляющих изображения. Протестированы статические и динамические НС.

Эффективность обучения сети исследована с применением механизмов редукции малоинформативных точек, регулирования последовательности участвующих в идентификации контуров нейронов, увеличения их числа, отбора нейронов с большими весами, уменьшения числа нейронов и отбора нейронов с меньшими весами.

Настройка параметров НС с такими механизмами, как регулирование весовых значений нейронов должна соответствовать условию

$$\left|w_j^{(\mu,i)}\right| < \bar{w},$$

где $w_j^{(\mu,i)}$ - вес j -го входа i -го нейрона μ -го слоя НС.

А веса нейронов уменьшается на основе правила $w_j^{(\mu,i)} = R^-(w_j^{(\mu,i)})$.

А при условии $\left|w_j^{(\mu,i)}\right| \geq \bar{w}$ увеличивается весовое значение нейрона по правилу

$$w_j^{(\mu,i)} = R^+(w_j^{(\mu,i)}),$$

где $R(w_j^{(\mu,i)})$ - правило регулирования весов нейронов сети.

Построена и реализована вычислительная схема нейросетевого распознавания изображений микрообъектов, которая включает механизмы выбора рациональной архитектуры сети, подбора подходящей активационной функции, модифицированного расчета весовых коэффициентов сети, стохастического поиска, формирования обучающих выборок.

Обучение НС на основе модели оптимизируется с применением иерархической кластеризации и рекуррентно-итерационной процедурой Гесса-Ньютона.

Суперпозиционный характер «входов и выходов» НС используется на основе процедуры блочного псевдо-обращения матрицы, которая эквивалентно обращению уравнения

$$\nabla_w^T y(w_c) \Delta w = b - y(w_c)$$

в виде

$$\Delta w = (\nabla_w^T y(w_c))^+ (b - y(w_c)), \quad w_+ = w_c + \Delta w. \quad (4)$$

Для вычисления матрицы $\nabla_w^T y(w_c)$ модифицирован градиентная оптимизация по вектору весов путем введения матрицы Якоби.

Установлено, что реализации процедур псевдообращения матрицы со рекуррентно-итерационной схемой вычисления, суперпозиции непрерывных функций одной переменной, а также механизма корректировки весов нейронов в слоях сокращает числа итераций и оптимизирует обучения НС.

Алгоритмы обучения НС не требуют вычисления производных целевой функции по весам нейронов сети, что достигается при реализации процедур формирования сокращенного набора опорных точек контура изображения.

Реализованы механизмы повышения достоверности информации на основе порогового контроля значений точек контура изображения, контроля значений приращений последовательности точек, погрешности экстраполяции точек контура на основе применения широкого спектра статистических, динамических моделей и НС.

Изложим вопрос оптимизации идентификации изображений микрообъектов при условии низкой достоверности информации.

Определено, что механизм при нормальном законе распределения вероятностей ошибок способствует уменьшению вероятности необнаруженных ошибок до одного порядка.

Эффективность механизма исследована по критерию минимальной среднеквадратической погрешности контроля данных [13, 15, 16].

Предложено обобщенное правило контроля информации механизма, основанного на различные модели предсказаний точек изображения, согласно которого ошибочная информация исправляется путем отождествления с предсказанным значением

$$\gamma_k = \begin{cases} \beta_k, & \text{если } \Delta\beta_k^* \in \{\beta_\rho^*\}, \\ \beta_k^* & \text{если } \Delta\beta_k^* \in \{\beta_3^*\}. \end{cases}$$

Получено общее решение задач.

По результатам исследования минимизируется среднеквадратическая погрешность контроля данных в виде следующего математического выражения

$$\begin{aligned} \sigma_n^2 = & \int_{\Omega} \omega(\alpha) \frac{P}{B} \left[\int_{0(-\infty)}^B (\alpha - a_\alpha)^2 d\beta + \right. \\ & \left. + \int_x^y (\alpha - \beta)^2 d\beta + \int_y^{B(+\infty)} (\alpha - a_\alpha)^2 d\beta \right] d\alpha + \\ & + (1-P) \left[\int_{\Omega} (\alpha - a_\alpha)^2 \omega(\alpha) d\alpha - \int_x^y (\alpha - a_\alpha)^2 \omega(\alpha) d\alpha \right], \end{aligned} \quad (5)$$

Таблица 1. Эффективность применения моделей идентификации на основе НС

Факторы	Обучающие наборы			Погрешность обобщенной модели				
	Тестовые	Пятиточечная сплайн-функция	Погрешность	НС Хопфилда	НС Хемминга	НС Кохонена	НС Хебба	НС ДАП
Y1	0,176320	0,051673	-0,124647	0,362	0,475	0,293	0,321	0,312
X1	0,039266	0,039776	0,00051					
X3	0,076856	0,036176	-0,04068					
X8	0,200712	0,293121	0,092409					
X9	0,659101	0,076135	-0,582966					
X10	0,019382	0,314632	0,29525					
X11	0,013093	0,0404566	0,0273636					

Интересно отметить, что в случае применения трехслойной НС с числом нейронов в скрытом слое более 25, достигается значительное уменьшение числа итераций и повышении скорости обучения сети.

На рис. 1 проиллюстрированы графики зависимостей критерия относительной среднеквадратической погрешности идентификации

СВР $F_i^2 = \frac{\sigma_n^2}{B}$, по совмещенным с трехслойной

где $\int_{\Omega} (\alpha - a_\alpha)^2 \omega(\alpha) d\alpha = \sigma_\alpha^2$.

Эффективность механизма исследована по значениям оптимальной границы контроля информации, которые позволяют выводить оценки экстремального значения среднеквадратической погрешности при нормальном законе в виде

$$\begin{aligned} \sigma_n^2 = & 2[1 - B(\tau)]\sigma_n^2 \times \\ & \times \left\{ 1 + \frac{2(1-P)}{\sqrt{\pi}} \sqrt{-\ln \frac{\sqrt{4\pi(1-B(\tau))}\sigma_H}{1-P}} \times \right. \\ & \left. \times \left[\frac{\sqrt{4\pi(1-B(\tau))}\sigma_H}{1-P} + \ln \frac{\sqrt{4\pi(1-B(\tau))}\sigma_H}{1-P} - 1 \right] \right\}, \end{aligned}$$

где σ_H^* – погрешность предсказания, $B(\tau)$ – автокорреляционная функция предсказываемой последовательности, τ – предыстория предсказания.

Аналогичные решения получены для логнормального, экспоненциального распределения, Вейбула и Рэлея.

В табл. 1 даны оценки эффективности совмещенных с НС динамических моделей идентификации СВР.

НС моделями в зависимости от параметров таких, как вероятность ошибок P , относительной дисперсии σ_H / B процесса, колоколообразной функции автокорреляции, диапазона размаха элементов СВР $B = 10$. Графики обозначены, как:

1 – механизм контроля достоверности информации без применения специальных мер;

2 – механизм, реализованный на основе статистического предсказания по двум предыдущим точкам;

3 - механизм, построенный на основе алгебраического многочлена, в частности, Ньютона, Лагранжа, Бесселя;

4 – механизм, построенный по кубическому сплайн-функцию.

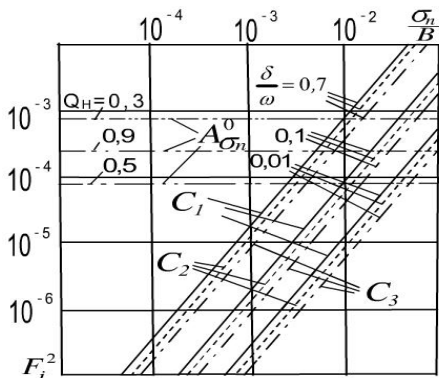


Рис. 1. Графики функции среднеквадратической погрешности

2.3. Программный комплекс визуализации, распознавания и классификации изображений пыльцевых зерен.

На рис. 2 проиллюстрирована схема функционирования модулей программного комплекса (ПК) визуализации, распознавания и классификации изображений микрообъектов, на примере пыльцевых зерен.



Рис. 2. Модули программного комплекса

Реализован механизм, основанный на сравнении характеристик изображений пыльцевых зерен с их эталонными характеристиками, размещенных в БД. На рис. 4 представлены результаты тестирования вычислительной схемы обучения НС. Графики обозначены, как: ○ – трехслойной НС по методу градиентной оптимизации; ■ – трехслойной НС по методу сопряженной градиентной оптимизации; ▲ –

трехслойной НС по методу стохастической оптимизации.




Рис. 3. Результаты обучения НС

Эффективность ПК исследована по коэффициентам снижения погрешности идентификации, трудоемкости и стоимости обработки информации.

Установлено, что реализованные механизмы при совмещенных с НС динамических моделях идентификации погрешности обработки информации снижают на два-три порядка, коэффициентов трудоемкости и стоимости обработки информации уменьшают три-четыре раза.

Повышается устойчивость алгоритмов обучения НС Хопфилда и НС Кохонена и других.

В табл. 2 даны результаты распознавания пыльцевых зерен на основе НС в виде корректно распознанных, распознанных некорректно и отвергнутых.

Определена значимость модифицированных вычислительных схем структурных компонентов НС таких, как выбора подходящей архитектуры НС, активационной функции, расчета весовых коэффициентов, числа слоев, числа нейронов в слоях, обучения НС при распознавании изображений пыльцевых зерен.

III. ЗАКЛЮЧЕНИЕ

Для оптимизации идентификации изображений микрообъектов, в частности пыльцевых зерен реализован программный комплекс на языке C++ в среде параллельных вычислений «CUDA» с механизмами выделения, сегментирования, интерполирования, контрастирования контуров, извлечения специфических характеристик, геометрических особенностей растровых изображений, редукции нулевых точек, уменьшения, порогового и уровневого контроля и регулирования точек параметров цвета - яркостной картины, фиксирования начальных значений, центра сегмента.

Эффективность ПК исследована по коэффициентам снижения погрешности, трудоемкости и стоимости обработки информации.

Результаты сравнены с визуальным контролем, механизмы которого погрешность идентификации снижают на два-три порядка, а коэффициенты трудоемкости и стоимости обработки информации уменьшают три раза.

Таблица 2. Анализ эффективности модулей распознавания ПК

Базовые модели обучения СОД	Показатель корректного распознавания	Показатель некорректного распознавания	Показатель отвергаемости
НС Хемминга	84,6%	10,5%	4,9%
НС Хопфилда	83,7%	11,15%	5,15%
НС Кохонена	78,8%	16,075 %	5,125%
НС Хебба - обучение без учителя	80,2%	14,1%	5,7%
НС на основе ДАП	84%	10,825%	5,175%

ЛИТЕРАТУРА

[1] Agrawal P, Girshick R., Malik J. Analyzing the Performance of Multilayer Neural Networks for Object Recognition // Lecture Notes in Computer Science. – 2014. – Vol. 8695. – PP. 329-344.

[2] 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.

[3] 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> (дата обращения: 20.05.2017).

[4] Jumanov, I.I., Djumanov, O.I., Safarov, R.A. 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>

[5] Форсайт Д., Понс Ж. Компьютерное зрение. Современный подход М.: Вильямс, 2004. 928 с.

[6] Ханжина Н.Е., Замятина Е.Б. Автоматизированное распознавание пыльцевых зерен с использованием нейронных сетей Хэмминга // Методы компьютерной диагностики в биологии и медицине: матер. Всерос. школы-семинара. Саратов: Изд-во Саратовский источник, 2014. С. 137–140.

[7] 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.

[8] I.I. Jumanov, O.I. Djumanov, R.A. Safarov. Recognition of micro-objects with adaptive models of image processing in a parallel computing environment // XIV International Scientific and Technical Conference "Applied Mechanics and Systems Dynamics" (AMSD) // Journal of Physics: Conference Series, Vol. 1791. Nov. 2020, Omsk, Russia. doi:10.1088/1742-6596/1791/1/012099

[9] Джуманов О.И., Холмонов С.М. Оптимизация обучения нейросетевой системы обработки информации при распознавании и прогнозировании нестационарных объектов// 4-th International Conference on Application of Information and Communication Technologies, Tashkent, 12-14 october 2010, Section 5. IEEE. – Tashkent, 2010. – p.17-21.

[10] Ibragimovich, J.I., Isroilovich, D.O., Abdullayevich, S.R. Optimization of identification of micro-objects based on the use of characteristics of images and properties of models // 2020 International Conference on Information Science and Communications Technologies, ICISCT 2020, 2020, 9351483. DOI: 10.1109/ICISCT50599.2020.9351483.

[11] Дюдин М.В., Поваляев А.Д., Подвальный Е.С., Томакова Р.А. Методы и алгоритмы контурного анализа для задач классификации сложно структурируемых изображений// Вестник Воронежского государственного технического университета. 2014. Т.10, –№ 3-1, –Стр. 54-59.

[12] Ibragimovich, J.I., Isroilovich, D.O., Abdullayevich, S.R. recognition and classification

- of pollen grains based on the use of statistical, dynamic image characteristics, and unique properties of neural networks // *Advances in Intelligent Systems and Computing*, 2021, 1323 AISC, pp. 170–179. https://doi.org/10.1007/978-3-030-68004-6_22
- [13] Блохинов Ю.Б., Горбачев В.А. Привязка наземных объектов на аэрофотоснимках на основе анализа контуров // *Известия РАН. Теория и системы управления*. - 2011. - №5 - Стр.83-94.
- [14] Корчевская Е. А., Мироненко В. М. Интеллектуальная система распознавания изображений микроскопических биологических нано- и микрообъектов на основе статистических методов и нейросетевого моделирования// *Информационные системы и технологии: Материалы международного конгресса по информатике*, Минск, 2013 г., Стр. 465-467.
- [15] I. I. Jumanov, O. I. Djumanov, R. A. Safarov “Optimization of image processing using characteristics and peculiarities of pollen grains” *Chemical Technology, Control and Management Tashkent*, 2019, №5 pp. 71-78.
- [16] O. I. Djumanov, R. A. Safarov “Algorithms for recognition and clusterization of features of useful minerals in the composition of mountain mass” *Scientific discussion: issues of technical sciences, Internauka*, 2016 pp. 23-27.
- [17] Liu D., Wang S., Huang D., Deng G., Zeng F., Chen H. Medical image classification using spatial adjacent histogram based on adaptive local binary patterns // *Computers in Biology and Medicine*. 2016. Vol.72. pp. 185-200.
- [18] Jumanov, I.I., Safarov, R.A., Djumanov, O.I. Detection of Distorted Points on Images of Micro-Objects Based on The Properties and Peculiarities of the Wavelet - Transformation // *International Russian Automation Conference, RusAutoCon 2022*, 2022, pp. 794–799. DOI: 10.1109/RusAutoCon54946.2022.9896243
- [19] Banarse D., France I., Duller A.W.G. Analysis of a self-organising image recognition neural network. L.: *Advances in engineering software*, 2000. 944 p.
- [20] Boucher A., P. Hidalgo, M. Thonnat, J. Belmonte and C. Galán. 3-D pollen image recognition based on palynological knowledge // *In 2nd European Symposium on Aerobiology, Vienna (Austria)*. 2000. p. 3.

Поступила в редакцию 24.05.2024

Цитирование: Жуманов И.И., Сафаров Р.А. (2024). Оптимизация распознавания изображений пыльцевых зерен на основе параметрической идентификации. *Международный Журнал Теоретических и Прикладных Вопросов Цифровых Технологий*, 7(3), –С. 92-98. <https://doi.org/10.62132/ijdt.v7i3.201>

OPTIMIZATION OF IMAGE RECOGNITION OF POLLEN GRAINS BASED ON PARAMETRIC IDENTIFICATION

Jumanov I.I.¹, Safarov R.A.¹

¹ Samarkand state university named after Sharof Rashidov, Samarkand, Uzbekistan
isroil.jumanov2019@gmail.com, rustammix.rs@gmail.com

Abstract. *Methods have been developed to optimize the identification of pollen grains using statistical, dynamic, textural and specific image characteristics. Mechanisms for point and nonlinear verification of the correspondence of the contours of the input and reference objects - pollen grains, as well as for adjusting the parameters of raster images have been studied and proposed. Implemented mechanisms for reducing contour zero points, reducing raster dimensions, scaling, threshold and level control, encoding and placing images of micro-objects based on a pyramidal model, selecting contour reference points, cognitive analysis, searching for points with annealing, prohibition, based on stochastic modeling using a truncated chain Markova. A set of programs for identification, recognition, classification and systematization of pollen grains was implemented in C++ in the parallel computing environment “CUDA”.*

Keywords: *identification, image, pollen grains, recognition, classification, efficiency, error, labor intensity, cost, software package.*