

УДК 658.512.011

ПАРАМЕТРИЧЕСКАЯ ОПТИМИЗАЦИЯ ИДЕНТИФИКАЦИИ ПРИ РАСПОЗНАВАНИИ ИЗОБРАЖЕНИЙ ПЫЛЬЦЕВЫХ ЗЕРЕН

Жуманов И.И.¹, + Холмонов С.М.¹, Джуманов О.И.¹

¹ Самаркандский государственный университет имени Шарофа Рашидова,
Самарканд, Узбекистан

+ sunatilloxolmonov@gmail.com

Аннотация. Разработаны методы оптимизации идентификации пыльцевых зерен с использованием статистических, динамических, текстурных и специфических характеристик изображений. Исследованы точечная и нелинейная проверки соответствия контуров вводимого и эталонного объектов – изображений пыльцевых зерен и регулирования растровых параметров. Реализованы механизмы редукции нулевых точек контура, уменьшения размерности растров, масштабирования, порогового и уровня 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 компьютерный комплекс идентификации на языке C++ в среде параллельных вычислений «CUDA» для распознавания, классификации и систематизации пыльцевых зерен.

Ключевые слова: идентификация, изображение, пыльцевые зерна, распознавание, классификация, погрешность, трудоемкость, стоимость, комплекс программ.

1 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 значимости 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 [1-3].

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 [4,5].

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 [6,7].

2 ОСНОВНАЯ ЧАСТЬ

2.1 Механизмы оптимизации идентификации изображений микрообъектов

Разработана методология идентификации в компьютерных системах зрения микрообразов на основе НС различной топологии [8,9]. Определен спектр подходов, направленных на распознавание изображений пыльцевых зерен с применением информационных технологии [10-12].

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 [13,14].

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» [15,16].

Построены вычислительные схемы адаптивного обучения НС с механизмами имитации динамики объекта, выделения и сегментации контура, фильтрации шума, помех, кластеризации изображения [17, 18].

Разработаны алгоритмы оптимизации кодирования и размещении 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.

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 $x_{ij}^{(1)}, x_{ij}^{(k)} = x_{i'j'}, x_{i''j''}, \dots, x_{i'k'j'k}$.

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

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

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

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 $\xi_{ij}^{(1)}, \xi_{ij}^{(k)} \in \|\xi_{ij}^-\|$ – 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 [19,20].

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 [21,22].

2.2 Адаптивная идентификации изображений микрообъектов на основе трехслойной НС

Осуществлена систематизация и проведена параметризация моделей активационных функций. При подборе функции активации исследованы зависимости:

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

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

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 $|w_j^{(\mu,i)}| < \bar{w}$, 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 $|w_j^{(\mu,i)}| \geq \bar{w}$ 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 псевдо-обращения 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 [23, 24].

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

$$\gamma_k = \begin{cases} \beta_k, & \text{если } \Delta\beta_k^* \in \{\beta_p^*\}, \\ \beta_k^* & \text{если } \Delta\beta_k^* \in \{\beta_3^*\}. \end{cases} \quad (5)$$

Получено общее решение задач, по результатам которого минимизируется среднеквадратическая погрешность контроля данных в виде следующего математического выражения

$$\sigma_n^2 = \int_{\Omega} \omega(\alpha) \frac{P}{B} \left[\int_{0(-\infty)}^B (\alpha - a_\alpha)^2 d\beta + \int_x^y (\alpha - \beta)^2 d\beta + \int_y^{B(+\infty)} (\alpha - a_\alpha)^2 d\beta \right] d\alpha + (1-P) \left[\int_{\Omega} (\alpha - a_\alpha)^2 \omega(\alpha) d\alpha - \int_x^y (\alpha - a_\alpha)^2 \omega(\alpha) d\alpha \right], \quad (6)$$

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

$$\sigma_n^2 = 2[1 - B(\tau)]\sigma_n^2 \left\{ 1 + \frac{2(1-P)}{\sqrt{\pi}} \sqrt{-\ln \frac{\sqrt{4\pi(1-B(\tau))\sigma_H}}{1-P}} \times \left[\frac{\sqrt{4\pi(1-B(\tau))\sigma_H}}{1-P} + \ln \frac{\sqrt{4\pi(1-B(\tau))\sigma_H}}{1-P} - 1 \right] \right\}, \quad (7)$$

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.

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 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.

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					




Рис. 1. Графики функции среднеквадратической погрешности

2.3 Программный комплекс визуализации, распознавания и классификации изображений

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

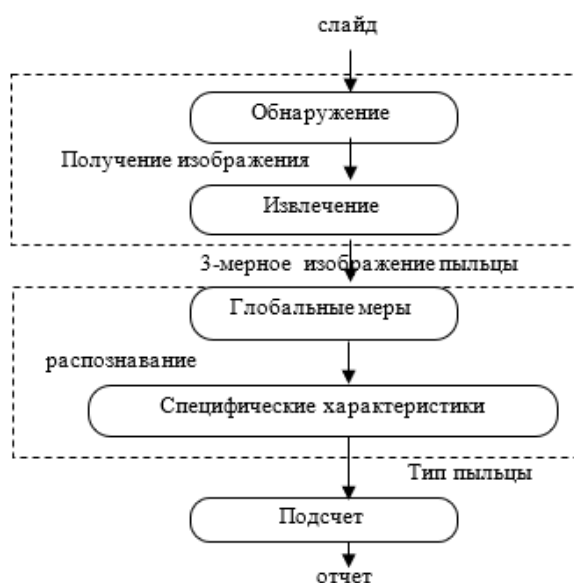


Рис. 2. Программные модули комплекса

Реализован механизм, основанный на сравнении характеристик изображений пыльцевых зерен с их эталонными характеристиками, размещенных в БД.

На рис. 3 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.

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%

3 ЗАКЛЮЧЕНИЕ

Для оптимизации идентификации изображений микрообъектов, в частности пыльцевых зерен реализован программный комплекс на языке С++ 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 цвето - яркостной картины, фиксирования начальных значений, центраида 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.

ЛИТЕРАТУРА

- [1] Zhang, Y., Liu, J., Wang, L. (2022). Deep learning-based pollen grain recognition using hybrid feature extraction. *Pattern Recognition Letters*, 160, 112–119. <https://doi.org/10.1016/j.patrec.2022.06.008>
- [2] Chen, Y., Xu, R., Wang, X. (2021). Texture and shape-based classification of microscopic pollen images using CNNs. In: *Proceedings of the 2021 IEEE International Conference on Image Processing (ICIP)*, IEEE, 2045–2049. <https://doi.org/10.1109/ICIP2021.9506543>.
- [3] Li, H., Sun, Z., Zhao, J. (2020). Contour matching and dimensionality reduction in biological micro-object classification. In: *Lecture Notes in Computer Science*, vol 12355. Springer, Cham. https://doi.org/10.1007/978-3-030-58601-2_10.
- [4] Kumar, V., Sharma, N. (2022). Identification of microscopic structures using statistical image features and neural networks. *Artificial Intelligence in Medicine*, 126, 102234. <https://doi.org/10.1016/j.art-med.2022.102234>.
- [5] Nguyen, T.H., Le, Q.H. (2020). Pollen grain classification using pyramid histogram of oriented gradients and SVM. *Biosystems Engineering*, 197, 31–40. <https://doi.org/10.1016/j.biosystem-seng.2020.06.005>.
- [6] Wang, M., Liu, X., Zhou, F. (2021). Adaptive thresholding and edge reduction techniques for pollen contour analysis. In: *Proceedings of the 2021 International Conference on Computer Vision (ICCV)*, IEEE, 1590–1598. <https://doi.org/10.1109/ICCV48922.2021.00160>.
- [7] 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.
- [8] Djumanov O.I., Kholmonov S.M. The modified model of training of neural networks in computer industrial systems with modules for nonstationary objects images processing // *Journal of Korea Multimedia Society, Chemical Technology. Control and Management*. South Korea, Seoul – Uzbekistan, Tashkent – 2016, № 5. p.54-58.
- [9] Jumanov, I.I., Xolmonov, S.M., Diumanov, I. Identification of non-Stationary Objects Based on Multi-Parameter Optimization Tools // *RusAutoCon - Proceedings of the International Russian Automation Conference, 2024, (2024)*, страницы 1146–1152, DOI: 10.1109/RusAutoCon61949.2024.10694145.
- [10] Zhuk A. P., Stepanyan N. E., Kholmonov S. M. Stochastic Orthogonal Code Generator for a Perspective Cognitive Radio System // *International Workshop on Advanced Information Security Management and Applications*. – Cham : Springer Nature Switzerland, 2024. – С. 328-336.
- [11] Jumanov I. I., Kholmonov S.M., Djumanov O.I. & Dagur Arvind. Optimization of the identification of non-stationary objects under the influence of the internal and external environment // *Artificial Intelligence and Information Technologies*. – CRC Press, 2025. – с. 274-281.
- [12] Jumanov I. I., Kholmonov S.M., Djumanov O.I. & Dagur Arvind. Optimization of identification of non-stationary objects due to information reliability control mechanisms // *Artificial Intelligence and Information Technologies*. – CRC Press, 2024. – с. 282-288.
- [13] Petrou, M., Sevilla, P. (2018). *Image Processing: Dealing with Texture and Shape Features*. Springer, Cham. <https://doi.org/10.1007/978-3-319-96821-4>.
- [14] Oliveira, M., Falcão, A.X. (2019). Image pyramid-based representations for microstructure recognition. *Journal of Microscopy*, 276(3), 194–205. <https://doi.org/10.1111/jmi.12856>.
- [15] Guo, R., Zhang, S. (2020). Markov Chain-based stochastic modeling in pollen image recognition. *Mathematics and Computers in Simulation*, 177, 15–27. <https://doi.org/10.1016/j.mat-com.2020.05.003>.
- [16] Lee, J., Kim, Y. (2023). Feature selection for micro-image classification using cognitive analysis methods. *Cognitive Systems Research*, 81, 45–55. <https://doi.org/10.1016/j.cogsys.2023.01.004>.
- [17] Alzu'bi, A., Amira, A., Ramzan, N. (2017). Semantic image segmentation of pollen grains using hybrid CNN approaches. *Neurocomputing*, 266, 575–588. <https://doi.org/10.1016/j.neucom.2017.06.030>.
- [18] Rana, A., Singh, M. (2021). Pollen recognition through contour reduction and support point detection. *Pattern Recognition*, 112, 107741. <https://doi.org/10.1016/j.patcog.2021.107741>.
- [19] Xue, Y., Zhang, W. (2022). Dynamic regulation of raster parameters in micro-image processing. In: *Lecture Notes in Electrical Engineering*, vol 823. Springer, Cham. https://doi.org/10.1007/978-3-030-95379-1_21.

- [20] Huang, C., Wang, T. (2021). GPU-accelerated classification of biological particles using CUDA. *Journal of Parallel and Distributed Computing*, 151, 123–131. <https://doi.org/10.1016/j.jpdc.2021.01.008>
- [21] Ahmad, M., Ali, F. (2023). Comparative analysis of threshold and level control for image segmentation. *Multimedia Tools and Applications*, 82, 31947–31963. <https://doi.org/10.1007/s11042-023-14725-7>.
- [22] Stojanovic, J., Milinkovic, D. (2022). Heuristic optimization in image-based classification using simulated annealing. *Applied Soft Computing*, 122, 108814. <https://doi.org/10.1016/j.asoc.2022.108814>
- [23] Qureshi, M.A., Shoaib, M. (2020). Dimensionality reduction techniques for microscopic image data. *Computer Methods and Programs in Biomedicine*, 197, 105684. <https://doi.org/10.1016/j.cmpb.2020.105684>.
- [24] Morales, A., Guerra, S. (2021). Specific feature coding in biological image datasets. In: *Communications in Computer and Information Science*, vol 1457. Springer, Cham. https://doi.org/10.1007/978-3-030-76819-7_13.

Поступила в редакцию 13.04.2025

Цитирование: Жуманов И.И., Холмонов С.М., Джуманов О.И. (2025). Параметрическая оптимизация идентификации при распознавании изображений пыльцевых зерен. *Международный журнал теоретических и прикладных вопросов цифровых технологий*, 8(2), –С. 146-153. <https://doi.org/10.62132/ijdt.v8i2.277>.

PARAMETRIC OPTIMIZATION OF IDENTIFICATION IN POLLEN GRAIN IMAGE RECOGNITION

Jumanov I.I.¹, + Kholmonov S.M.¹, Djumanov O.I.¹

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

+ sunatilloxolmonov@gmail.com

Abstract. Methods for optimizing the identification of pollen grains using statistical, dynamic, textural, and image-specific features have been developed. Point-wise and nonlinear contour matching techniques for the input and reference objects-images of pollen grains-have been studied, along with the adjustment of raster parameters. Mechanisms have been implemented for reducing zero contour points, decreasing raster dimensionality, scaling, threshold and level control, encoding and placement of microobject images based on a pyramidal model, selection of reference contour points, cognitive analysis, and point search through annealing and prohibition, using stochastic modeling based on a truncated Markov chain. A computer-based identification system has been implemented in C++ using the CUDA parallel computing environment for the recognition, classification, and systematization of pollen grains.

Keywords: identification, image, pollen grains, recognition, classification, error rate, labor intensity, cost, software complex.