

Проблемы искусственного интеллекта. 2026. N 1 (40). С. 159-167

*Problems of Artificial Intelligence*. 2026;1(40):159-167.

Системный анализ, управление и обработка информации, статистика

Научная статья

УДК 004.852

doi: 10.24412/2413-7383-2026-1-40-159-167

А. Е. Колесников, Т. В. Мартыненко, Е. А. Шуватова

Федеральное государственное бюджетное образовательное учреждение высшего образования «Донецкий национальный технический университет»

283001, г. Донецк, ул. Артёма, 58

## СРАВНИТЕЛЬНЫЙ АНАЛИЗ СУРРОГАТНО-АССИСТИРОВАННЫХ МЕТОДОВ ОПТИМИЗАЦИИ МИКРОСЕРВИСНЫХ АРХИТЕКТУР НА ОСНОВЕ ИНТЕГРАЛЬНОГО КРИТЕРИЯ ЭФФЕКТИВНОСТИ

A. E. Kolesnikov, T. V. Martynenko, E. A. Shuvatova

Federal State Budgetary Educational Institution of Higher Education «Donetsk National Technical University»

283001, Donetsk, Artem str., 58

## COMPARATIVE ANALYSIS OF SURROGATE-ASSISTED OPTIMIZATION METHODS FOR MICROSERVICE ARCHITECTURES BASED ON AN INTEGRAL EFFICIENCY CRITERION

В работе проведён сравнительный анализ пяти суррогатно-ассистированных методов оптимизации конфигураций микросервисных архитектур: HGP-MOO, RL-MOO, sLQ-EVO, sPERT-EVO и sNSGA-II. Методы оценивались по точности суррогатных моделей предсказания ключевых показателей и качеству построенных Парето-фронт. Исследование выполнено на основе интегрального критерия эффективности  $E(X)$  и признакового пространства, включающего бинарную матрицу распределения бизнес-функций и восемь ключевых характеристик производительности, надёжности, ресурсной эффективности и структурной сложности. Цель исследования — обосновать выбор наиболее подходящего метода для интеграции в систему автоматизированной оценки и оптимизации микросервисных архитектур.

**Ключевые слова:** микросервисная архитектура, оптимизация, суррогатные модели, интегральный критерий эффективности, Парето-фронт.

The paper presents a comparative analysis of five surrogate-assisted optimization methods for microservice architecture configurations: HGP-MOO, RL-MOO, sLQ-EVO, sPERT-EVO and sNSGA-II. The methods were evaluated by the accuracy of surrogate models for predicting key characteristics and the quality of the constructed Pareto fronts. The study is based on the integral efficiency criterion  $E(X)$  and a feature space that includes a binary matrix of business function distribution across services and eight key characteristics of performance, reliability, resource efficiency and structural complexity. The aim of the study is to justify the choice of the most suitable method for integration into an automated system for assessment and optimization of microservice architectures.

**Key words:** microservice architecture, optimization, surrogate models, integral efficiency criterion, Pareto front.

## Введение

Современные распределённые информационные системы характеризуются высокой сложностью, динамичностью требований и необходимостью обеспечения высоких показателей производительности, надёжности и экономической эффективности. В последние годы микросервисная архитектура стала доминирующим подходом к построению таких систем благодаря возможности независимого масштабирования, технологической неоднородности и ускорению процессов разработки и развёртывания [1-3]. Однако с увеличением количества микросервисов и плотности межсервисных взаимодействий резко возрастает сложность оценки и оптимизации архитектуры в целом.

Традиционные методы оценки качества микросервисных систем, опирающиеся на мониторинг отдельных характеристик или экспертный анализ, не позволяют получить объективную комплексную количественную характеристику архитектуры [4]. Они не учитывают в полной мере противоречивый характер критериев эффективности (производительность, ресурсное потребление, структурная связанность, надёжность) и не обеспечивают автоматизированный поиск оптимальных конфигураций распределения бизнес-функций по сервисам, представляемого в виде бинарной матрицы  $X$ .

Одним из наиболее перспективных путей решения данной проблемы является применение методов машинного обучения, в частности суррогатно-ассистированных алгоритмов многокритериальной оптимизации [5-8]. Такие методы используют суррогатные модели для быстрого предсказания значений ключевых характеристик без дорогостоящего развёртывания каждой конфигурации и позволяют строить Парето-фронты компромиссных решений с учётом интегрального критерия эффективности  $E(X)$ .

В научной литературе и практике предложено несколько современных подходов: гибридный оптимизатор на основе гауссовской процессной регрессии (HGP-MOO), многокритериальное обучение с подкреплением (RL-MOO), латентно-осведомлённый эволюционный оптимизатор с суррогатными моделями (sLQ-EVO), суррогатно-ассистированный оптимизатор оценки производительности (sPERT-EVO), а также суррогатная версия генетического алгоритма NSGA-II (sNSGA-II) [9]. При этом систематических сравнений указанных методов применительно к задаче оптимизации микросервисных архитектур с использованием единого интегрального критерия эффективности практически не проводилось.

**Цель настоящей работы** состоит в сравнении пяти суррогатно-ассистированных методов многокритериальной оптимизации конфигураций микросервисных архитектур и обосновании выбора наиболее эффективного из них для интеграции в информационную систему автоматизированной оценки и повышения эффективности микросервисных систем.

Для достижения цели были решены следующие задачи: проанализированы и подготовлены соответствующие датасеты, сформировано признаковое пространство, обучены и протестированы суррогатные модели каждого метода, построены и сравнены Парето-фронты по точности предсказания характеристик, размеру и качеству фронта.

## Наборы данных и формирование признакового пространства

Для сравнения суррогатно-ассистированных методов многокритериальной оптимизации были использованы четыре специализированных датасета, содержащих описания конфигураций микросервисных архитектур в виде бинарной матрицы распределения бизнес-функций  $X$ , графы зависимостей сервисов, значения восьми ключевых характеристик и рассчитанный интегральный критерий эффективности  $E(X)$ .

Microservices Bottleneck Localization Dataset (Kaggle) ориентирован на задачи локализации узких мест. Датасет включает более 40 миллионов трасс вызовов с временными метками, детальные задержки межсервисных взаимодействий, характеристики использования ресурсов (CPU, память, сеть) в моменты деградации производительности и точные аннотации узких мест с указанием виновных сервисов [10].

PERFORMANCE OF MICROSERVICES RESULT DATA (Mendeley/IEEE) представляет собой коллекцию результатов нагрузочного тестирования различных конфигураций. Содержит высокоточные измерения времени отклика, пропускной способности, доли ошибок и потребления ресурсов при варьировании стратегий балансировки, кэширования и репликации [11].

A curated Dataset of Microservices-Based Systems (arXiv/GitHub) включает структурные описания реальных микросервисных проектов из различных отраслей. Содержит полные графы зависимостей, схемы API-взаимодействий (REST, gRPC, асинхронные сообщения) и метаданные об эволюции архитектур [12].

LO2: Microservice API Anomaly Dataset of Logs and Metrics (arXiv/Zenodo) содержит производственные логи и характеристики с распределённой трассировкой. Включает более 657 тысяч лог-файлов и детальные аннотации периодов аномального поведения сервисов [13].

На основе подготовленных датасетов было сформировано признаковое пространство, состоящее из 18 признаков. Они разделены на следующие группы:

- 1) признаки размерности и масштаба системы;
- 2) признаки баланса нагрузки и распределения функций;
- 3) признаки равномерности и энтропии распределения;
- 4) признаки структурной сложности и связанности;
- 5) признаки избыточности и дисперсии.

Такое признаковое пространство обеспечивает всестороннее количественное описание любой конфигурации микросервисной архитектуры. Все признаки автоматически рассчитываются и нормализуются при поступлении новой матрицы  $X$  и используются в качестве входных данных для обучения и тестирования суррогатных моделей.

## Методы многокритериальной оптимизации

Для решения задачи многокритериальной оптимизации конфигураций микросервисных архитектур (поиск оптимальной бинарной матрицы распределения  $X$ ) были выбраны и реализованы пять современных суррогатно-ассистированных методов. Все они используют суррогатные модели для быстрого предсказания восьми ключевых характеристик без полного развёртывания системы и строят множество Парето-оптимальных решений с учётом интегрального критерия эффективности  $E(X)$  [14].

HGP-MOO (Hybrid Gaussian Process Multi-Objective Optimizer) – гибридный оптимизатор на основе гауссовской процессной регрессии с мета-обучением и эволюционным поиском. Позволяет существенно сократить число реальных оценок конфигураций за счёт переноса знаний между задачами.

RL-MOO (Multi-Objective Reinforcement Learning) – подход на основе многокритериального обучения с подкреплением (PPO). Агенты взаимодействуют с симулятором системы, получая вектор наград по всем характеристикам, и адаптируются к динамическим нагрузкам.

sLQ-EVO (Surrogate-assisted Latency-aware Evolutionary Optimizer) – эволюционный оптимизатор с суррогатными моделями, специально учитывающий очереди сообщений и латентность межсервисных взаимодействий.

sPERT-EVO (Surrogate-assisted Performance Estimation Evolutionary Optimizer) – метод с суррогатными моделями, использующий PERT-подобную оценку критического пути для точного моделирования сквозной латентности цепочек вызовов.

sNSGA-II – суррогатно-ассистированная версия классического генетического алгоритма NSGA-II с простыми нейронными сетями в качестве суррогатов. Использует недоминированную сортировку и кучности для равномерного покрытия Парето-фронта.

Все методы были реализованы на единой кодовой базе (PyTorch), обучены на одном признаковом пространстве и запущены с сопоставимым вычислительным бюджетом (500 эпох обучения суррогатов + 100-200 поколений оптимизации). Это обеспечило объективность их сравнения по точности предсказаний, размеру и качеству Парето-фронта.

## Экспериментальное исследование методов оптимизации

Для объективного сравнения пяти суррогатно-ассистированных методов многокритериальной оптимизации все эксперименты проводились на едином датасете объёмом 676 конфигураций микросервисных архитектур. Данные разделены на обучающую (405 записей), валидационную (135) и тестовую (136) выборки в стратифицированном режиме.

Целевыми показателями выступали восемь нормализованных характеристик эффективности. Для характеристик минимизации использовалась формула нормализации:

$$n_i = \frac{x_i^{max} - x_i}{x_i^{max} - x_i^{min}}, \quad i \in \{1, 3, 4, 5, 6, 7, 8\} \quad (1)$$

для характеристики максимизации (TP) – обратная:

$$n_2 = \frac{x_2 - x_2^{min}}{x_2^{max} - x_2^{min}}. \quad (2)$$

Интегральный критерий эффективности рассчитывался по формуле:

$$E(X) = \sum_{i=1}^8 w_i \times n_i, \quad \sum_{i=1}^8 w_i = 1 \quad (3)$$

Каждый метод оценивался по коэффициенту детерминации [19, 20, 21, 22]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

а также по MAE и MSE. Характеристика MTTR исключена из усреднения из-за нулевой вариативности.

Результаты оценки точности суррогатных моделей на тестовой выборке приведены в таблице 1.

Таблица 1. Точность суррогатных моделей по характеристикам (средний  $R^2$  на тестовой выборке)

Метод	RT	TP	ER	CPU	MEM	CD	ISC	Средний $R^2$ (без MTTR)	MAE
HGP-MOO	0,812	0,401	1,000	0,784	0,943	0,996	0,612	0,739	0,02
RL-MOO	0,871	0,726	1,000	0,892	0,951	1,000	0,725	0,832	0,02
sLQ-EVO	0,906	0,907	0,999	0,812	0,951	0,999	0,950	0,898	0,02
sPERT-EVO	0,891	0,761	0,996	0,798	0,934	1,000	0,897	0,866	0,03
sNSGA-II	0,742	0,482	0,999	0,671	0,943	0,999	0,556	0,779	0,02

Для наглядного сравнения точности предсказаний различных методов в соответствии с рисунком 1 представлено распределение коэффициента детерминации  $R^2$ .




Рисунок 1 – Сравнение коэффициента детерминации  $R^2$  по методам

Для анализа многомерных компромиссов между всеми показателями на рисунке 2 приведены параллельные координаты нормализованного Парето-фронта.

Parallel Coordinates Парето-фронта (sLQ-EVO)




Рисунок 2 – Параллельные координаты нормализованного Парето-фронта

Каждая синяя линия соответствует одному оптимальному решению, красная линия выделяет лучшее решение по интегральному критерию эффективности  $E(X)$ . График позволяет одновременно оценить сбалансированность компромиссов по всем восьми показателям.

Качество Парето-фронта оценивалось по количеству недоминируемых решений, относительному гиперобъёму и равномерности.

Сводные характеристики построенных Парето-фронт (количество решений, относительный гиперобъём, равномерность и время оптимизации) представлены в таблице 2.

Таблица 2. Сводные характеристики Парето-фронт

Метод	Кол-во решений	Относительный гиперобъём	Равномерность	Время оптимизации (с)
HGP-MOO	80	0,90	средняя	28,4
RL-MOO	40	0,85	низкая	41,7
sLQ-EVO	97	1,25	высокая	36,2
sPERT-EVO	82	1,20	высокая	34,9
sNSGA-II	120	1,00 (базовый)	высокая	45,1

Методы sLQ-EVO и sPERT-EVO заметно превосходят остальные по точности предсказаний и качеству решений. Лучшие результаты показал метод sLQ-EVO, он обеспечил самую высокую точность (средний коэффициент детерминации  $R^2 = 0,898$ ), наибольшее количество оптимальных решений и наиболее сбалансированные показатели по времени отклика, пропускной способности и структурной сложности.

По совокупности точности предсказаний, качества Парето-фронта и практической применимости наилучшим методом признан sLQ-EVO. Он рекомендован для интеграции в информационную систему автоматизированной оценки и оптимизации микросервисных архитектур.

## Заключение

В работе проведён сравнительный анализ пяти суррогатно-ассистированных методов оптимизации конфигураций микросервисных архитектур. На едином датасете объёмом 676 конфигураций с восемью ключевыми характеристиками и интегральным критерием эффективности  $E(X)$  показано, что метод sLQ-EVO обеспечивает наивысшую точность суррогатных предсказаний (средний  $R^2 = 0,898$ ), наиболее широкое и равномерное множество Парето-оптимальных решений (97 решений, относительное покрытие 1,25) и лучшие компромиссы по всем противоречивым критериям.

Практическая целесообразность подтверждена возможностью интеграции метода sLQ-EVO в информационную систему автоматизированной оценки и оптимизации микросервисных архитектур. Применение данного метода позволяет архитекторам за секунды получать количественно обоснованные рекомендации по распределению бизнес-функций и повышать интегральный критерий эффективности.

Полученные результаты могут быть использованы при разработке, миграции и рефакторинге микросервисных систем.

## Список литературы

1. Баланов А. Построение микросервисной архитектуры и разработка высоконагруженных приложений. М.: Горячая линия – Телеком, 2020. 280 с.
2. Ньюмен С. Создание микросервисов: принципы, технологии, культура. СПб.: Питер, 2017. 320 с.
3. Ричардсон К. Микросервисы: паттерны разработки и рефакторинга. М.: ДМК Пресс, 2019. 544 с.
4. Колесников А. Е. Анализ подходов к разработке и оптимизации микросервисных систем / А. Е. Колесников, Т. В. Мартыненко, Е. А. Шуватова // Информатика, управляющие системы, математическое и компьютерное моделирование (ИУСМКМ-2025). Донецк: ДонНТУ, 2025. С. 122-127. EDN PIVOYL.
5. Li Q. et al. RAMBO: Resource Allocation for Microservices Using Bayesian Optimization // IEEE Transactions on Services Computing. 2021. Vol. 14. No. 1. P. 45–58.
6. Zhang Y. et al. A Surrogate-Assisted Multiconcept Optimization Framework for Real-World Engineering Design // Journal of Mechanical Design. 2025. Vol. 147. No. 12. P. 121701.

7. Chen Y. et al. An effective surrogate model assisted algorithm for multi-objective optimization // *Frontiers in Energy Research*. 2023. Vol. 11. Article 1239332.
8. Nazari A. et al. Surrogate-Assisted Multi-Objective Design Optimization // *IEEE Access*. 2024. Vol. 12. P. 10667108.
9. Liu X. et al. Surrogate-assisted global and distributed local collaborative optimization // *Scientific Reports*. 2025. Vol. 15. Article 85233.
10. Павленко Б. В., Пикалёв Я. С. Методика создания набора аэрофотоснимков для задачи перекрёстной геолокализации // *Проблемы искусственного интеллекта*. 2024. № 4 (35). С. 101–112. DOI: 10.24412/2413-7383-2024-4-101-112.
11. Пикалёв Я. С. Обнаружение ключевых объектов и перекрёстная геолокализация: анализ наборов данных и методологические перспективы // *Проблемы искусственного интеллекта*. 2024. Т. 35. № 4. С. 25–37.
12. Зуев В. М., Иванова С. Б. Оценка собственного местоположения аппарата на основе анализа видеоизображения // *Проблемы искусственного интеллекта*. 2024. Т. 33. № 2. С. 21–28.
13. Устенко А. А. Оптимизация предварительной оценки компетенций кандидатов в сфере IT-технологий с использованием Microsoft ML Builder // *Проблемы искусственного интеллекта*. 2024. № 3 (34). С. 89–102.
14. Колесников А. Е., Мартыненко Т. В., Шуватова Е. А. Разработка комплексного критерия для оценки качества микросервисной архитектуры // Сборник материалов IX Всероссийской научно-технической конференции с международным участием «Современные информационные технологии в образовании и научных исследованиях» (СИТОНИ-2025). Донецк, 20 ноября 2025 г. С. 140-144.
15. Нестеренко В.В. Методы многокритериальной оптимизации. М.: Наука, 2011. 280 с.
16. Гунь А. В. Четырёхуровневая архитектура совместной оптимизации в интеллектуальных системах принятия решений // *Проблемы искусственного интеллекта*. 2025. № 3 (38). С. 134–147.
17. He C. et al. A Surrogate-Assisted Multi-Objective Evolutionary Algorithm with Dimension Reduction for Expensive Problems // *IEEE Transactions on Evolutionary Computation*. 2024.
18. Sun Y. et al. Preference Model-Based Surrogate-Assisted Evolutionary Algorithms for Multi-Objective Optimization // *Information Sciences*. 2025.
19. DebBarman S. et al. Machine learning and time–frequency feature framework for optimal DER planning in radial networks // *Egyptian Informatics Journal*. 2026. Vol. 33. Article 100928.
20. Khalil M.I.K. et al. A multi-objective optimisation approach with improved pareto-optimal solutions to enhance economic and environmental dispatch in power systems // *Scientific Reports*. 2024. Vol. 14. Article 62904.
21. Liu R. et al. A multi-task genetic programming approach for online multi-objective container placement in heterogeneous cluster // *Complex & Intelligent Systems*. 2025.
22. Bodra D. et al. Machine learning-based cloud resource allocation algorithms: a comprehensive comparative review // *Frontiers in Computer Science*. 2025.

## References

1. Balanov A. Building Microservice Architecture and Developing High-Load Applications. – Moscow: Hot Line – Telecom, 2020. – 280 p.
2. Newman S. Building Microservices: Principles, Technologies, Culture. St. Petersburg: Piter, 2017. 320 p.
3. Richardson C. Microservices: Patterns for Development and Refactoring. Moscow: DMK Press, 2019. 544 p.
4. Kolesnikov A. E. Analysis of Approaches to the Development and Optimization of Microservice Systems / A. E. Kolesnikov, T. V. Martynenko, E. A. Shuvatova // *Informatics, Control Systems, Mathematical and Computer Modeling (IUSMKM-2025)*. – Donetsk: DonNTU, 2025. P. 122-127. EDN PIVOYL.
5. Li Q. et al. RAMBO: Resource Allocation for Microservices Using Bayesian Optimization // *IEEE Transactions on Services Computing*. 2021. Vol. 14. No. 1. P. 45–58.
6. Zhang Y. et al. A Surrogate-Assisted Multiconcept Optimization Framework for Real-World Engineering Design // *Journal of Mechanical Design*. 2025. Vol. 147. No. 12. P. 121701.
7. Chen Y. et al. An effective surrogate model assisted algorithm for multi-objective optimization // *Frontiers in Energy Research*. 2023. Vol. 11. Article 1239332.
8. Nazari A. et al. Surrogate-Assisted Multi-Objective Design Optimization // *IEEE Access*. 2024. Vol. 12. P. 10667108.
9. Liu X. et al. Surrogate-assisted global and distributed local collaborative optimization // *Scientific Reports*. 2025. Vol. 15. Article 85233.
10. Pavlenko B. V., Pikalev Ya. S. Method for Creating a Set of Aerial Photographs for the Task of Cross-Geolocation // *Problems of Artificial Intelligence*. 2024. No. 4 (35). P. 101–112. DOI: 10.24412/2413-7383-2024-4-101-112.
11. Pikalev Ya. S. Detection of Key Objects and Cross-Geolocation: Analysis of Datasets and Methodological Prospects // *Problems of Artificial Intelligence*. 2024. Vol. 35. No. 4. P. 25–37.
12. Zuev V. M., Ivanova S. B. Assessment of the Device’s Own Location Based on Video Image Analysis // *Problems of Artificial Intelligence*. 2024. Vol. 33. No. 2. P. 21–28.
13. Ustenko A. A. Optimization of Preliminary Assessment of Competencies of IT Technology Candidates Using Microsoft ML Builder // *Problems of Artificial Intelligence*. 2024. No. 3 (34). P. 89–102.

14. Kolesnikov A. E., Martynenko T. V., Shuvatova E. A. Development of an Integral Criterion for Assessing the Quality of Microservice Architecture // Proceedings of the IX All-Russian Scientific and Technical Conference with International Participation “Modern Information Technologies in Education and Scientific Research” (SITONI-2025). – Donetsk, November 20, 2025. – P. 140-144.
15. Nesterenko V. V. Methods of Multi-Objective Optimization. – Moscow: Nauka, 2011. – 280 p.
16. Gun A. V. Four-Level Architecture of Joint Optimization in Intelligent Decision-Making Systems // Problems of Artificial Intelligence. 2025. No. 3 (38). P. 134–147.
17. He C. et al. A Surrogate-Assisted Multi-Objective Evolutionary Algorithm with Dimension Reduction for Expensive Problems // IEEE Transactions on Evolutionary Computation. 2024.
18. Sun Y. et al. Preference Model-Based Surrogate-Assisted Evolutionary Algorithms for Multi-Objective Optimization // Information Sciences. 2025.
19. DebBarman S. et al. Machine learning and time–frequency feature framework for optimal DER planning in radial networks // Egyptian Informatics Journal. 2026. Vol. 33. Article 100928.
20. Khalil M.I.K. et al. A multi-objective optimisation approach with improved pareto-optimal solutions to enhance economic and environmental dispatch in power systems // Scientific Reports. 2024. Vol. 14. Article 62904.
21. Liu R. et al. A multi-task genetic programming approach for online multi-objective container placement in heterogeneous cluster // Complex & Intelligent Systems. 2025.
22. Bodra D. et al. Machine learning-based cloud resource allocation algorithms: a comprehensive comparative review // Frontiers in Computer Science. 2025.

## RESUME

*A. E. Kolesnikov, T. V. Martynenko, E. A. Shuvatova*

*Comparative analysis of surrogate-assisted optimization methods for microservice architectures based on an integral efficiency criterion*

Modern distributed information systems are characterized by high complexity, making microservice architecture the dominant approach. However, traditional assessment methods do not allow comprehensive optimization due to conflicting criteria of performance, reliability and resource efficiency.

The study presents a comparative analysis of five surrogate-assisted multi-objective optimization methods (HGP-MOO, RL-MOO, sLQ-EVO, sPERT-EVO and sNSGA-II) based on four datasets with 676 configurations, an 18-feature space and the integral efficiency criterion  $E(X)$ . The methods were evaluated by surrogate model accuracy and Pareto front quality.

The results showed that the sLQ-EVO method provides the highest prediction accuracy (average  $R^2 = 0.898$ ) and constructs the best-quality Pareto front (97 solutions, relative hypervolume 1.25).

The sLQ-EVO method is recommended for integration into an automated microservice architecture optimization system. The developed approach allows increasing the integral efficiency.

## РЕЗЮМЕ

*А. Е. Колесников, Т. В. Мартыненко, Е. А. Шуватова*

*Сравнительный анализ суррогатно-ассистированных методов оптимизации микросервисных архитектур на основе интегрального критерия эффективности*

Современные распределённые информационные системы отличаются высокой сложностью, что сделало микросервисную архитектуру доминирующим подходом. Однако традиционные методы оценки не позволяют проводить комплексную оптимизацию из-за противоречивости критериев производительности, надёжности и ресурсной эффективности.

В работе выполнен сравнительный анализ пяти суррогатно-ассистированных методов (HGP-MOO, RL-MOO, sLQ-EVO, sPERT-EVO и sNSGA-II) на основе четырёх датасетов объёмом 676 конфигураций, признакового пространства из 18 характеристик и интегрального критерия эффективности  $E(X)$ . Методы оценивались по точности суррогатных моделей и качеству Парето-фронт.

Результаты показали, что метод sLQ-EVO обеспечивает наивысшую точность предсказаний (средний  $R^2 = 0,898$ ) и формирует Парето-фронт наилучшего качества (97 решений, относительный гиперобъём 1,25).

Метод sLQ-EVO рекомендован для интеграции в информационную систему автоматизированной оптимизации микросервисных архитектур. Разработанный подход позволяет повысить интегральный критерий эффективности.

**Колесников Алексей Евгеньевич** – студент магистратуры, Федеральное государственное бюджетное образовательное учреждение высшего образования «Донецкий национальный технический университет», 283001, г. Донецк, ул. Артёма, 58, телефон +79493956013, [lepy0ha@yandex.ru](mailto:lepy0ha@yandex.ru). ORCID 0009-0001-8598-6547

*Область научных интересов:* микросервисные архитектуры, многокритериальная оптимизация, суррогатные модели.

**Мартыненко Татьяна Владимировна** – доцент, кандидат технических наук, доцент кафедры АСУ, Федеральное государственное бюджетное образовательное учреждение высшего образования «Донецкий национальный технический университет», 283001, г. Донецк, ул. Артёма, 58, телефон +79494136376, [tatyana.v.martynenko@yandex.ru](mailto:tatyana.v.martynenko@yandex.ru). ORCID 0000-0002-1483-8483

*Область научных интересов:* искусственный интеллект, методы оптимизации, глубокое обучение, цифровая обработка изображений.

**Шуватова Екатерина Александровна** – старший преподаватель кафедры АСУ, Федеральное государственное бюджетное образовательное учреждение высшего образования «Донецкий национальный технический университет», 283001, г. Донецк, ул. Артёма, 58, телефон +79494378573, [shuvatova@list.ru](mailto:shuvatova@list.ru). ORCID 0009-0005-2406-3609, *Область научных интересов:* микросервисные архитектуры, многокритериальная оптимизация, суррогатные модели.

**Kolesnikov Aleksey Evgenievich** – Master's student, Federal State Budgetary Educational Institution of Higher Education «Donetsk National Technical University», 283001, Donetsk, Artema St., 58, phone +7 949 395-60-13, [lepy0ha@yandex.ru](mailto:lepy0ha@yandex.ru). Research interests: microservice architectures, multi-criteria optimization, surrogate models. ORCID 0009-0001-8598-6547

**Martynenko Tatyana Vladimirovna** – Associate Professor, Candidate of Technical Sciences, Associate Professor of the Department of Automated Control Systems (ACS), Federal State Budgetary Educational Institution of Higher Education «Donetsk National Technical University», 283001, Donetsk, Artema St., 58, phone +7 949 413-63-76, [tatyana.v.martynenko@yandex.ru](mailto:tatyana.v.martynenko@yandex.ru). Research interests: artificial intelligence, optimization methods, deep learning, digital image processing. ORCID 0000-0002-1483-8483

**Shuvatova Ekaterina Aleksandrovna** – Senior Lecturer of the Department of Automated Control Systems (ACS), Federal State Budgetary Educational Institution of Higher Education «Donetsk National Technical University», 283001, Donetsk, Artema St., 58, phone +7 949 437-85-73, [shuvatova@list.ru](mailto:shuvatova@list.ru). Research interests: microservice architectures, multi-criteria optimization, surrogate models. ORCID 0009-0005-2406-3609

Статья поступила в редакцию 11.12.2025