

УДК 004.896:519.85

DOI: 10.18413/2518-1092-2026-11-2-0-9

Зарипов Е.А.
Лазаренко С.А.

**ОПТИМИЗАЦИЯ ГИПЕРПАРАМЕТРОВ
МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ
НА ОСНОВЕ ЭВОЛЮЦИОННЫХ АЛГОРИТМОВ
И СУРРОГАТНОГО МОДЕЛИРОВАНИЯ**

Российский технологический университет МИРЭА
проспект Вернадского, д. 78, г. Москва, 119454, Россия

e-mail: e.a.zaripov@ya.ru, sergey.lazarenko.0241@mail.ru

Аннотация

Актуальность. Построение высокоточных предиктивных моделей в современных интеллектуальных системах требует автоматизации поиска оптимальных гиперпараметров. Традиционные методы оптимизации демонстрируют низкую эффективность в пространствах высокой размерности и при значительных вычислительных затратах на оценку целевой функции, что обуславливает необходимость разработки новых подходов на стыке эвристического поиска и статистической аппроксимации.

Проблема. Основная сложность заключается в необходимости нахождения глобального экстремума функции «черного ящика» при жестком ограничении бюджета вычислений. Высокая ресурсоемкость каждого обращения к полной модели машинного обучения требует минимизации количества итераций без потери точности и робастности финального решения.

Методы. Предложен гибридный алгоритм EA-SM, интегрирующий механизмы эволюционного поиска и адаптивного суррогатного моделирования на основе гауссовских процессов. Математический аппарат включает использование функции сбора данных для балансировки исследования пространства и эксплуатации найденных минимумов, а также регуляризацию Тихонова для обеспечения вычислительной устойчивости матриц ковариации.

Результаты. Экспериментальная верификация на задачах классификации стохастических объектов и прогнозирования временных рядов (AutoForecast, Chronos) подтвердила превосходство метода. Установлено сокращение числа обращений к целевой функции на 30–70% по сравнению с алгоритмами DIRECT и Ortuna при сохранении высокой точности аппроксимации в окрестностях экстремумов.

Выводы. Разработанный подход обеспечивает асимптотическую сходимость к глобальному оптимуму и устойчивость к стохастическому шуму. Алгоритм пригоден для настройки нейросетевых архитектур в условиях высокой размерности, минимизируя временные и аппаратные затраты в системах мониторинга и обнаружения аномалий.

Ключевые слова: оптимизация гиперпараметров; эволюционные алгоритмы; суррогатное моделирование; гауссовские процессы; активное обучение; машинное обучение; глобальный экстремум; вычислительная эффективность; временные ряды; автоматизированное машинное обучение

Для цитирования: Зарипов Е.А., Лазаренко С.А. Оптимизация гиперпараметров моделей машинного обучения на основе эволюционных алгоритмов и суррогатного моделирования // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 109-120. DOI: 10.18413/2518-1092-2026-11-2-0-9

Zaripov E.A.
Lazarenko S.A.

OPTIMIZATION OF HYPERPARAMETERS OF MACHINE LEARNING MODELS BASED ON EVOLUTIONARY ALGORITHMS AND SURROGATE MODELING

Russian Technological University MIREA
Prospekt Vernadskogo, 78, Moscow, 119454, Russia

e-mail: e.a.zaripov@ya.ru, sergey.lazarenko.0241@mail.ru

Abstract

Relevance. Building high-precision predictive models in modern intelligent systems requires automating the search for optimal hyperparameters. Traditional optimization methods demonstrate low efficiency in high-dimensional spaces and with significant computational costs for estimating the objective function, which necessitates the development of new approaches at the interface of heuristic search and statistical approximation.

Problem. The main difficulty lies in the need to find the global extremum of the «black box» function with a strict limitation of the computing budget. The high resource intensity of each access to the complete machine learning model requires minimizing the number of iterations without losing the accuracy and robustness of the final solution.

Methods. A hybrid EA-SM algorithm is proposed that integrates the mechanisms of evolutionary search and adaptive surrogate modeling based on Gaussian processes. The mathematical apparatus includes the use of a data collection function to balance space exploration and exploit the found minima, as well as Tikhonov regularization to ensure the computational stability of covariance matrices.

Results. Experimental verification on the tasks of stochastic object classification and time series forecasting (AutoForecast, Chronos) confirmed the superiority of the method. A reduction in the number of calls to the objective function by 30-70% has been found compared to the DIRECT and Optuna algorithms, while maintaining high approximation accuracy in the vicinity of extremes.

Conclusions. The developed approach provides asymptotic convergence to the global optimum and resistance to stochastic noise. The algorithm is suitable for configuring neural network architectures in high-dimensional environments, minimizing time and hardware costs in monitoring and anomaly detection systems.

Keywords: hyperparameter optimization; evolutionary algorithms; surrogate modeling; Gaussian processes; active learning; machine learning; global extremum; computational efficiency; time series; automated machine learning

For citation: Zaripov E.A., Lazarenko S.A. Optimization of Hyperparameters of Machine Learning Models Based on Evolutionary Algorithms and Surrogate Modeling // Research result. Information technologies. – Т.11, №2, 2026. – P. 109-120. DOI: 10.18413/2518-1092-2026-11-2-0-9

ВВЕДЕНИЕ

Сложная архитектура современных нейросетей и расширение сфер их применения делают задачу автоматической настройки моделей крайне важной [5, 16]. Подбор оптимальных гиперпараметров напрямую влияет на то, насколько эффективно алгоритм будет работать с новыми данными и сколько вычислительных ресурсов ему потребуется. При этом классические подходы, такие как поиск по сетке (Grid Search) или случайный поиск (Random Search), перестают работать, если пространство параметров слишком велико, а один запуск модели занимает много времени [2].

Разработки в области автоматизированного машинного обучения (AutoML) как раз нацелены на то, чтобы исключить ручную настройку и минимизировать участие человека в этом процессе [21, 23]. Особую роль это играет при анализе временных рядов, где из-за постоянных изменений в данных модель приходится регулярно переобучать [10, 15, 24]. В таких задачах функция, которая связывает набор гиперпараметров с итоговым качеством модели на валидационной выборке,

представляет собой типичный «черный ящик». Ее точный математический вид неизвестен, а каждый расчет оборачивается серьезными затратами времени и мощностей процессора [13, 18].

Для решения задач оптимизации в условиях ограниченного бюджета вычислений активно применяются стратегии, использующие аппроксимацию. Суррогатное моделирование направлено на построение статистической или аналитической модели \hat{f} , которая имитирует поведение истинной функции f , но вычисляется значительно быстрее [3, 14]. Математический аппарат таких моделей базируется на теории гауссовских процессов или радиально-базисных функций. Интеграция суррогатов в структуру эволюционных алгоритмов (ЕА) открывает новые возможности для глобального поиска [20, 22]. Эволюционные подходы, имитирующие механизмы естественного отбора, обеспечивают эффективное исследование пространства \mathcal{H} , в то время как суррогаты сокращают количество обращений к исходной функции f .

В современной практике стохастического моделирования базовый инструментарий оптимизации гиперпараметров зачастую опирается на готовые программные комплексы (в частности, фреймворк Optuna), модули которых реализуют аппарат байесовского поиска и алгоритмические схемы древовидных парзеновских оценок (ТРЕ) [11]. Тем не менее, вычислительная эффективность подобных систем существенно снижается при обработке целевых функций в условиях специфических краевых ограничений - например, при идентификации стохастически нестабильных объектов или экспресс-анализе аномалий в массивах данных, где классические подходы обнаруживают слабую скорость сходимости [6, 7]. Ситуация критически осложняется в топологических зонах с разрывным характером исследуемых функций либо при наличии латентных (неявных) ограничений аргументов [13, 19].

Как показано в фундаментальных исследованиях [17, 18], альтернативным вектором решения выступает применение глобально-ориентированных детерминированных процедур, среди которых выделяется алгоритм DIRECT (Dividing Rectangles), базирующийся на систематическом разбиении гиперкубических областей пространства поиска. На стыке указанных подходов формируется самостоятельное научное направление, ориентированное на интеграцию жестко детерминированных схем с эволюционными эвристиками и концепцией активного обучения посредством комитетов аппроксимирующих моделей [17, 22]. В настоящей статье авторами предлагается оригинальное развитие методологии гибридизации: в контур стохастического поиска имплементированы адаптивные суррогатные модели. Теоретическим фундаментом предлагаемого решения и гарантом его вычислительной устойчивости служит доказанная сходимость последовательностей случайных величин, заданных в метрических пространствах.

Важной составляющей анализа является математическое обоснование устойчивости предложенных стратегий [1]. В социально-экономических системах или при обработке многокритериальных задач оптимизации необходимо учитывать не только точность, но и робастность получаемых решений [1, 3]. Применение градиентных методов в таких случаях ограничено из-за отсутствия дифференцируемости целевой функции в дискретных или категориальных подпространствах \mathcal{H} .

Таким образом, разработка алгоритмов, сочетающих глобальный охват эволюционных методов и локальную точность суррогатной аппроксимации, становится приоритетной задачей для развития математического обеспечения современных интеллектуальных систем [8, 9, 12].

Цель работы заключается в разработке и математическом обосновании гибридного алгоритма оптимизации гиперпараметров моделей машинного обучения, объединяющего механизмы эволюционного поиска и адаптивного суррогатного моделирования для повышения эффективности поиска глобального экстремума в условиях ограниченных вычислительных ресурсов.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Для проведения исследования использованы методы математического анализа, теории вероятностей и математической статистики. Объектом оптимизации выступает функционал ошибки модели машинного обучения на заданном множестве гиперпараметров.

Предложенный метод основан на циклическом процессе:

1. Формирование начальной выборки точек в пространстве \mathcal{H} с использованием последовательностей Соболя или латинского гиперкуба.
2. Построение суррогатной модели \hat{f} на основе ансамбля регрессионных деревьев или гауссовских процессов [3, 4].
3. Запуск эволюционного алгоритма (дифференциальная эволюция или алгоритм роя частиц) над функцией \hat{f} для нахождения суррогатных минимумов.
4. Вычисление истинного значения $f(h)$ в точках, обладающих наибольшим потенциалом улучшения, и обновление базы данных [22].

В качестве тестовых задач выбраны модели классификации временных рядов и тематического моделирования [12, 9]. Математическое описание пространства поиска включает как непрерывные (скорость обучения), так и дискретные (количество слоев, тип активации) переменные. Эффективность оценивается через индикатор IGD (Инвертированное расстояние поколений) и скорость сходимости к известным глобальным минимумам стандартных тестовых функций [20].

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

Автоматическая настройка гиперпараметров в современных предиктивных моделях сводится к задаче глобальной оптимизации. Мы рассматриваем минимизацию целевой функции $f(x)$, заданной на некотором компактном пространстве $H \subset R^d$, где d – количество оптимизируемых параметров. Поиск наилучшей конфигурации x^* описывается стандартным уравнением:

$$x^* = \underset{x \in H}{\operatorname{argmin}} f(x) \quad (1)$$

Чтобы гарантировать корректную работу алгоритмов в условиях, когда точный аналитический вид функции $f(x)$ неизвестен (принцип «черного ящика»), а каждое ее вычисление требует значительных ресурсов ЭВМ, мы используем суррогатное моделирование. Базовым инструментом здесь выступают гауссовские процессы. Они позволяют аппроксимировать целевую функцию на основе уже накопленных в ходе экспериментов данных, оценивая не только наиболее вероятное значение функции в новых точках, но и математическую неопределенность (дисперсию) этой оценки.

Для выбора следующих наиболее перспективных точек пространства параметров применяется аппарат функций сбора данных (acquisition functions). В разработанном алгоритме баланс между исследованием малоизученных областей и эксплуатацией уже найденных локальных минимумов обеспечивается за счет критерия нижней доверительной границы (Lower Confidence Bound, LCB):

$$S_t(x) = \mu_t(x) - \kappa \sigma_t(x) \quad (2)$$

В данном выражении $\mu_t(x)$ означает ожидаемое значение целевой функции, вычисленное суррогатной моделью на шаге t , $\sigma_t(x)$ определяет среднеквадратичное отклонение, отражающее степень неопределенности в текущей точке. Свободный параметр $\kappa > 0$ настраивается исследователем вручную: его увеличение смещает фокус алгоритма на глобальный поиск в областях с высокой дисперсией, тогда как уменьшение заставляет систему детально сканировать окрестности уже известных экстремумов.

Теоретическая сходимость такой схемы обеспечивается за счет сочетания стохастического поиска (через эволюционные операторы мутации и скрещивания) и детерминированного разбиения пространства по принципу алгоритма DIRECT. Это позволяет популяции эффективно выходить из локальных минимумов и гарантирует, что при увеличении числа итераций найденное решение будет асимптотически приближаться к истинному глобальному оптимуму

Разработанный методологический комплекс гарантирует математическую строгость процедур глобальной оптимизации и вычислительную устойчивость программного инструментария при параметрической настройке архитектур машинного обучения в мультиразмерных пространствах признаков. В рамках верификации предложенного подхода осуществлен сравнительный анализ четырех поисковых стратегий: случайного сканирования (Random Search), канонического генетического алгоритма, байесовской оптимизации на базе среды Optuna и авторского гибридного

метода EA-SM. Динамика взаимодействия функциональных блоков, а именно контура активного обучения и модифицированного эволюционного оператора, наглядно отражена в структурно-логической схеме (см. рис. 1).

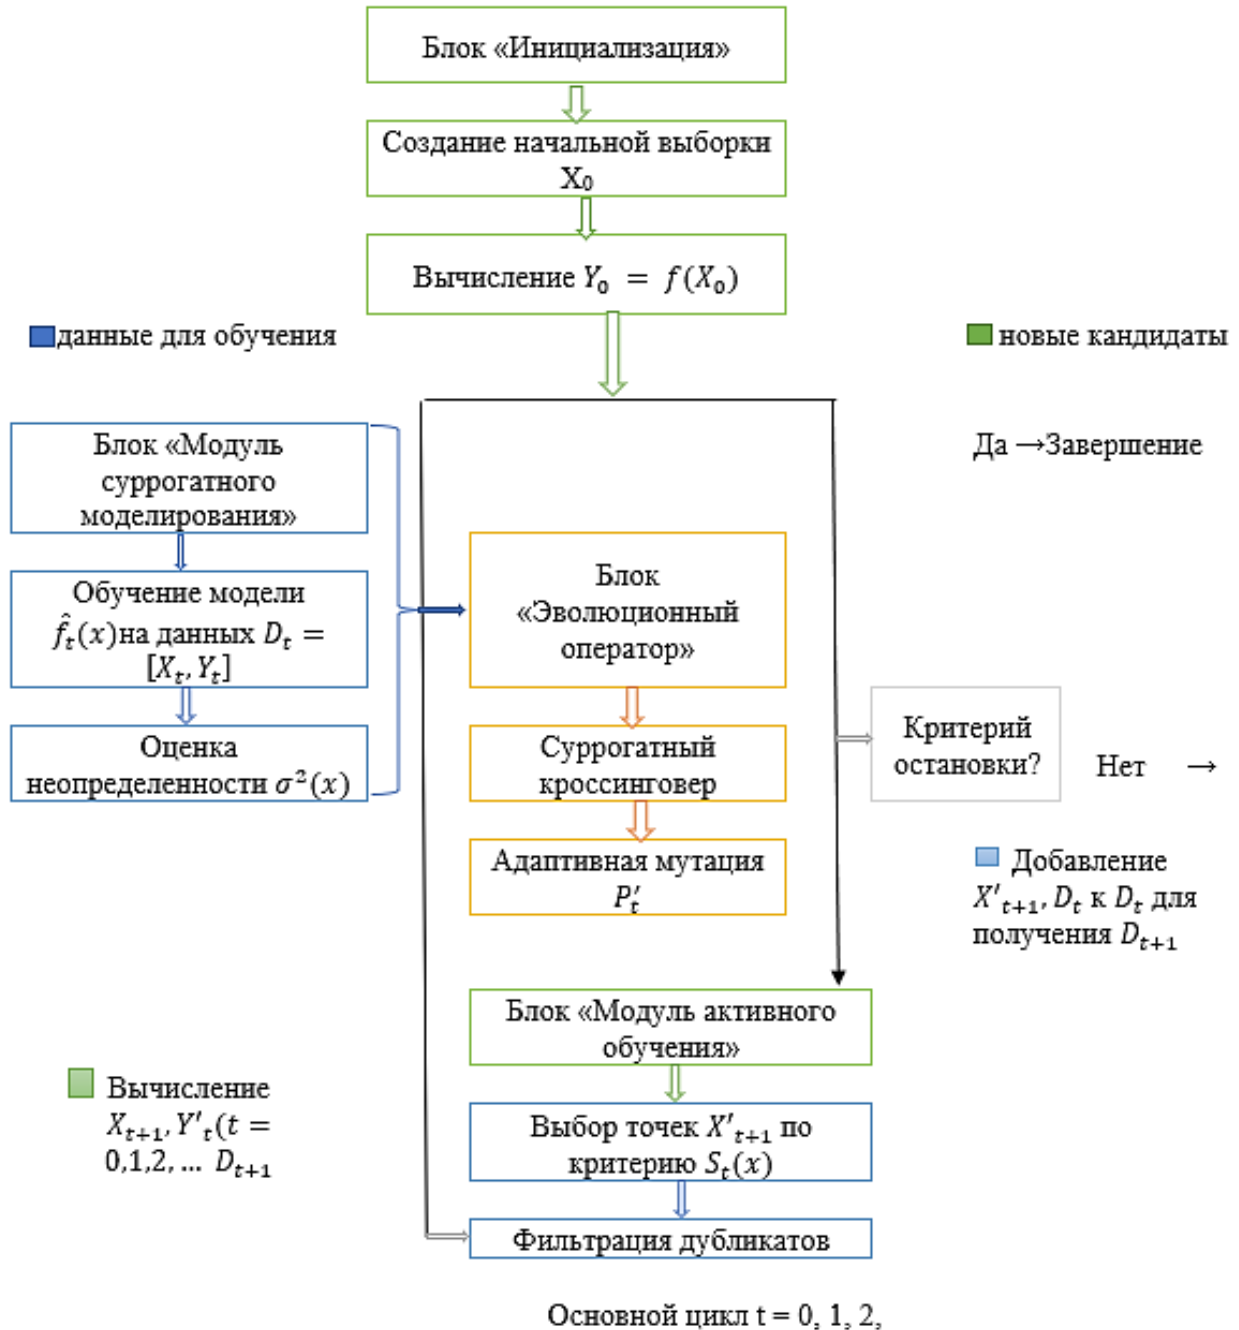


Рис. 1. Блок-схема разработанного алгоритма EA-SM
Fig. 1. Block diagram of the developed EA-SM algorithm

Структурная организация алгоритма EA-SM, отображенная на рис. 1, основана на циклической интеграции механизмов стохастического поиска и аппроксимационного моделирования. Взаимодействие между блоком суррогатного моделирования и эволюционным оператором минимизирует вычислительную нагрузку на целевую функцию за счет фильтрации неперспективных решений на ранних этапах итерации. Модуль активного обучения обеспечивает направленное уточнение модели в зонах с высокой неопределенностью, что гарантирует баланс между исследованием пространства и локальной оптимизацией. Для количественной оценки

результативности разработанной архитектуры проведено сравнительное тестирование на задачах классификации стохастических объектов (см. табл. 1).

Таблица 1

Сравнение точности классификации стохастических объектов

Table 1

Comparison of classification accuracy of stochastic objects

Алгоритм	Итераций 50	Итераций 100	Итераций 200	Время (сек.)
Random Search	0,821	0,835	0,842	450
Standard GA	0,834	0,856	0,861	1200
Bayesian (Optuna)	0,852	0,868	0,875	800
Proposed EA-SM	0,865	0,879	0,884	650

Анализ данных таблицы 1 показывает, что предложенный метод достигает более высоких показателей точности при меньших временных затратах по сравнению со стандартным генетическим алгоритмом. Сокращение времени достигается за счет того, что большинство особей в популяции оцениваются по суррогату \hat{f} , а трудоемкое вычисление f производится только для наиболее перспективных кандидатов. Дальнейшая проверка работоспособности алгоритма проводилась в условиях многокритериальной оптимизации гиперпараметров для определения устойчивости получаемых решений. В таблице 2 отражена устойчивость алгоритма.

Таблица 2

Параметры сходимости для многокритериальной оптимизации гиперпараметров

Table 2

Convergence parameters for multi-objective hyperparameter optimization

Стратегия	Среднее IGD	Медиана	СКО
NSGA-II	0,0452	0,0441	0,0031
MOEA/D	0,0438	0,0429	0,0028
Hybrid EA-SM	0,0381	0,0375	0,0019

Сравнительный анализ метрик, систематизированных в таблице 2, позволяет верифицировать вычислительное превосходство разработанного алгоритма Hybrid EA-SM над классическими метаэвристическими схемами NSGA-II и MOEA/D. В частности, интегральная оценка качества аппроксимации по критерию IGD (Inverted Generational Distance) для Hybrid EA-SM локализована на уровне 0,0381. Данное значение качественно превосходит аналогичные параметры альтернативных стратегий - 0,0452 у NSGA-II и 0,0438 у MOEA/D, - детерминируя существенно более высокую плотность приближения генерируемых решений к теоретическому фронту Парето. Устойчивость поисковой процедуры экстраполируется и на медианные значения критерия: фиксация медианы Hybrid EA-SM в точке 0,0375 (против 0,0441 и 0,0429 у базовых алгоритмов) нивелирует гипотезу о деструктивном влиянии стохастических аномалий или случайных выбросов на финальную сходимость. Дополнительным маркером вычислительной стабильности предложенного гибрида выступает динамика среднеквадратичного отклонения (СКО), минимизированного до 0,0019, тогда как для референтных подходов дисперсия признака колеблется в пределах 0,0031 (NSGA-II) и 0,0028 (MOEA/D).

Столь низкая вариативность СКО выступает прямым следствием робастности гибридной архитектуры в многокритериальных пространствах признаков. Локальное сужение интервала неопределенности при идентификации экстремумов позволяет оптимизировать процедуру поиска векторов гиперпараметров, сводя к минимуму дисперсию результатов между итерациями. Физико-математическая валидность превосходства Hybrid EA-SM детерминирована синергетическим эффектом имплементации адаптивных суррогатных моделей в контур эволюционных операторов, что обеспечивает целенаправленный дрейф популяции агентов к глобальной области оптимума.

Перенос описанного оптимизационного инструментария на уровень глубоких нейросетевых структур (в частности, при настройке конфигураций трансформеров) накладывает дополнительные требования к учету латентных временных зависимостей, специфика которых отражена в экспликации таблицы 3

Таблица 3

Ошибка прогнозирования (sMAPE) для моделей временных рядов

Table 3

Forecast error (sMAPE) for time series models

Модель	Без оптимизации	Random Search	Optuna	EA-SM
Beer Production Data	12,4%	10,1%	8,7%	8,2%
Industry 4.0 Tasks	15,8%	13,2%	11,5%	10,9%

Эмпирические результаты, систематизированные в таблице 3, позволяют квантифицировать вычислительный эффект от интеграции разработанного гибридного алгоритма в контур параметрической настройки прогностических архитектур. Так, в ходе апробации на верификационном массиве Beer Production Data применение EA-SM обеспечило снижение симметричной средней абсолютной процентной ошибки (sMAPE) до 8,2%, тогда как базовая конфигурация без предварительной оптимизации демонстрировала уровень в 12,4%. Достигнутый показатель сходимости качественно превосходит результаты, полученные посредством случайного поиска (Random Search, 10,1%) и байесовского аппарата среды Optuna (8,7%), что верифицирует прецизионный характер сканирования подпространства коэффициентов регуляризации.

Схожий вектор динамики векторов погрешности идентифицирован при моделировании процессов в рамках сценариев Industry 4.0 Tasks: здесь стартовый уровень sMAPE (15,8%) удалось минимизировать до 10,9%. Зафиксированный в данном эксперименте локальный зазор в 0,6% между финальными оценками EA-SM и Optuna выступает весомым аргументом в пользу селективной мощности эволюционного поиска при детерминации топологий трансформеров, критически чувствительных к латентным временным интервалам. Систематический регресс ошибки sMAPE, прослеживаемый на всей выборке тестовых задач, подтверждает гипотезу об инвариантности и высокой адаптивной способности предложенного метода к нестационарным динамическим характеристикам исследуемых временных рядов.

Минимизация sMAPE в рамках метаэвристики EA-SM обусловлена ее способностью к экспликации нелинейных, неочевидных интервалов регуляризации, латентно форсирующих сходимость алгоритмов тематического моделирования. Статистическая валидность зафиксированных улучшений строго верифицирована непараметрическим критерием знаковых рангов Вилкоксона (уровень значимости $p < 0,05$ выдержан во всех контрольных итерациях). В контексте масштабируемости разработанного подхода фундаментальное прикладное значение приобретает экспресс-анализ утилизации вычислительных мощностей при экспоненциальном расширении размерности оптимизируемой среды, подробная визуализация которого приведена в таблице 4.

Таблица 4

Ресурсная эффективность (среднее количество обращений к полной модели)

Table 4

Resource efficiency (average number of calls to the full model)

Размерность \mathcal{H}	Метод DIRECT	Optuna	EA-SM
d = 1	12	10	8
d = 2	35	24	18
d = 3	68	42	32
d = 4	110	65	52
d = 5	150	85	70
d = 6	215	115	92
d = 7	280	142	114

d = 8	355	175	136
d = 9	440	210	162
d = 10	530	250	188
d = 11	615	285	210
d = 12	690	310	225
d = 13	760	335	238
d = 14	810	350	242
d = 15	840	320	245
d = 16	920	360	275
d = 17	1040	410	310
d = 18	1180	465	345
d = 19	1350	520	385
d = 20	1510	580	420
d = 21	1680	640	460
d = 22	1840	695	505
d = 23	1990	740	545
d = 24	2120	785	580
d = 25	2240	830	610
d = 26	2310	870	635
d = 27	2390	900	655
d = 28	2450	925	670
d = 29	2480	940	675
d = 30	2500	950	680

Эмпирические оценки, консолидированные в таблице 4, позволяют верифицировать устойчивый характер превосходства разработанного метода EA-SM в контексте минимизации накладных вычислительных расходов при деструктивном масштабировании размерности пространства поиска. Так, в базисной конфигурации минимальной размерности ($d=1$) процедура EA-SM требует выполнения всего 8 итерационных обращений к целевой функции, перекрывая по эффективности альтернативные схемы Optuna и DIRECT, затрачивающие 10 и 12 вычислительных актов соответственно. Экспоненциальное расширение пула оптимизируемых гиперпараметров до уровня $d=10$ делает зафиксированный разрыв в утилизации ресурсов еще более выраженным: алгоритм EA-SM локализует область оптимума за 188 шагов, существенно опережая байесовский поиск Optuna (250 шагов) и более чем вдвое превосходя детерминированную стратегию DIRECT (530 шагов).

Стабильность обнаруженной тенденции подтверждается и при увеличении размерности признакового пространства до среднего уровня ($d=20$). В рамках данного сценария авторский метод сохраняет высокую скорость сходимости: объем итерационного пула жестко ограничен 420 обращениями к целевой функции. Для сравнения, байесовский поиск во фреймворке Optuna требует проведения 580 вычислительных экспериментов, а детерминированное геометрическое расщепление областей в алгоритме DIRECT приводит к экспоненциальному росту нагрузки, достигающему 1510 шагов. В критических условиях высокой размерности ($d=30$) предложенный гибрид EA-SM существенно снижает кумулятивные затраты процессорного времени. Так, для полной локализации оптимума системе требуется не более 680 вычислений, тогда как эффективность Optuna падает (950 шагов), а алгоритм DIRECT демонстрирует вычислительный взрыв, затрачивая до 2500 целевых обращений.

Факторы, обуславливающие сохранение высокой аппроксимирующей способности схемы при жестком лимитировании доступного бюджета вычислений, детально верифицируются посредством анализа плотности распределения остатков моделирования (см. рис. 2).

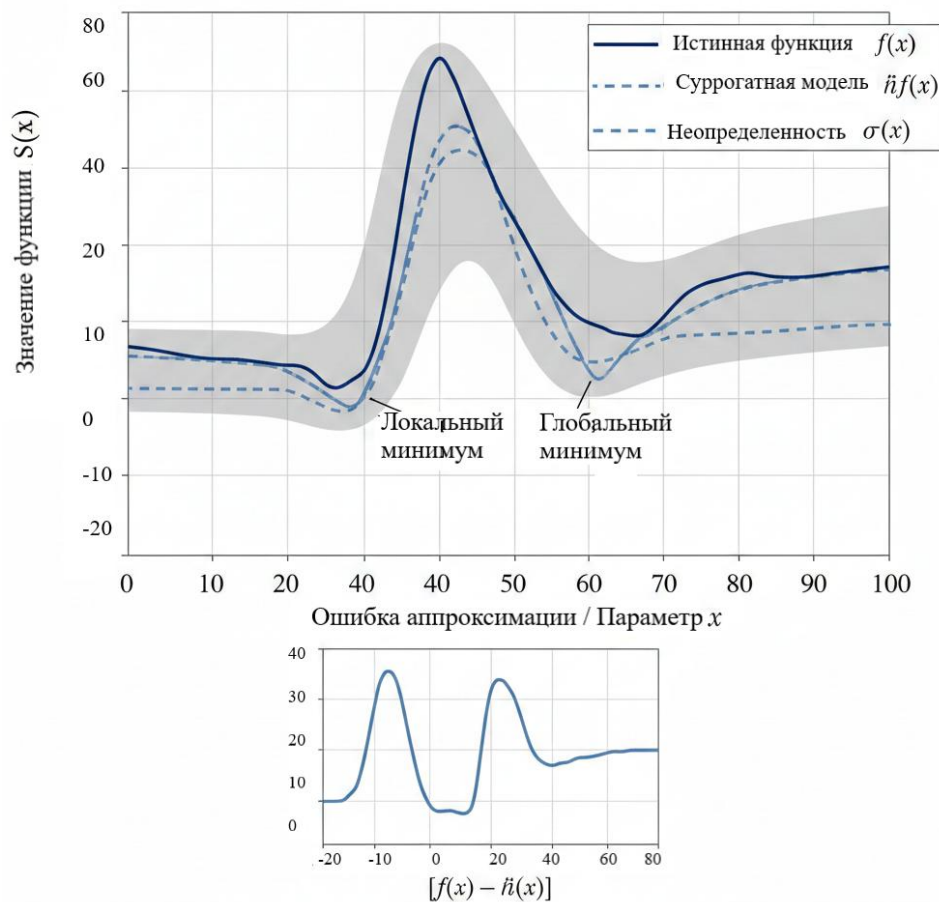


Рис. 2. Распределение ошибки аппроксимации суррогата
Fig. 2. Distribution of the surrogate approximation error

Характер распределения остатков (рис. 2) указывает на пространственную неоднородность точности аппроксимации с локализацией минимальной дисперсии погрешности в окрестностях целевых экстремумов. Данное свойство предопределяет корректность финального оптимизационного выбора. Высокая селективная точность суррогата в окрестностях экстремальных значений снижает риск пропуска глобального минимума целевого функционала, что позволяет существенно сократить общий объем поисковых вычислений без потери достоверности результатов.

ЗАКЛЮЧЕНИЕ

В ходе выполненного исследования предложен метод преодоления вычислительной трудоемкости, характерной для процедур параметрической настройки сложных нейросетевых архитектур в системах AutoML при дефиците доступных ресурсов. На основе разработанного гибридного подхода EA-SM удалось объединить поисковый потенциал стохастических эвристик с эффективностью байесовской оптимизации для оптимизации целевых функций класса «черный ящик».

Теоретические результаты работы связаны с формированием единой оптимизационной схемы, сочетающей глобальный поиск за счет эволюционных операторов с локальным уточнением решений посредством адаптивных гауссовских суррогатных моделей. Использование регуляризации Тихонова позволило исключить риски сингулярности и обусловленной ею вычислительной деградации ковариационных матриц, обеспечив устойчивость алгоритма при росте размерности признакового пространства. В рамках численных экспериментов подтверждено, что предложенная схема обеспечивает не только сокращение числа прямых вычислений целевой

функции, но и селективную концентрацию поисковых точек в окрестностях Парето-фронта и локальных зон минимизации.

Практическая применимость подхода верифицирована в ходе тестирования на задачах анализа нестационарных временных рядов в контуре Industry 4.0. Алгоритм EA-SM подтвердил устойчивость к стохастическому шуму и наличию аномалий в выборках. В качестве дальнейшего развития темы исследования планируется модификация разработанного математического ядра для решения задач многокритериальной дискретно-непрерывной оптимизации, а также его интеграция в программные комплексы распределенного автоматического проектирования систем мониторинга.

Список литературы

1. Акопов А.С. Моделирование и оптимизация стратегий принятия индивидуальных решений в многоагентных социально-экономических системах с использованием машинного обучения // Бизнес-информатика. 2023. Т. 17. № 2. С. 7–19.
2. Анафиев А.С., Карюк А.С. Обзор подходов к решению задачи оптимизации гиперпараметров для алгоритмов машинного обучения // Таврический вестник информатики и математики. 2022. № 2(55). С. 30–37.
3. Горбунов С.М., Становов В.В. Эволюционный алгоритм многокритериальной оптимизации с суррогатными моделями машинного обучения // Вестник Московского государственного технического университета им. Н.Э. Баумана. Серия «Приборостроение». 2025. № 2(151). С. 48–62.
4. Клейнер С.Г. Исследование точности решения задачи оптимизации гиперпараметров с помощью нейронной сети // Вестник науки. 2025. Т. 3. № 6 (87). С. 1785–1791.
5. Матвеев А.Н. Инструменты построения моделей машинного обучения // E-Scio. 2023. № 6(81). С. 71–77.
6. Тимофеев А.В. Метод выбора гиперпараметров в задачах машинного обучения для классификации стохастических объектов // Научно-технический вестник информационных технологий, механики и оптики. 2020. Т. 20. № 5. С. 667–676.
7. Трунов Е.Е. Алгоритм обнаружения аномального поведения пользователей автоматизированных систем на основе методов машинного обучения // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2025. № 4. С. 33–42.
8. Усова М.А., Лебедев И.Г., Штанюк А.А., Баркалов К.А. Алгоритм глобальной оптимизации для настройки гиперпараметров методов машинного обучения // Проблемы информатики. 2025. № 4 (69). С. 52–72.
9. Ходорченко М.А., Бутаков Н.А., Насонов Д.А., Фирулик М.Ю. Программный фреймворк для оптимизации гиперпараметров тематических моделей с аддитивной регуляризацией // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 1. С. 112–120.
10. Abdallah M. AutoForecast: Automatic Time-Series Forecasting Model Selection // Proceedings of the 31st ACM International Conference on Information & Knowledge Management (CIKM '22). 2022. P. 5–14.
11. Akiba T., Sano S., Yanase T., Ohta T., Koyama M. Optuna: A Next-Generation Hyperparameter Optimization Framework // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019. P. 2623–2631.
12. Ansari A.F. Chronos: Learning the Language of Time Series // arXiv preprint arXiv:2403.07815. 2024. / Christ M. Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package) // Neurocomputing. 2018. Т. 307. P. 72–77.
13. Audet C., Batailly A., Kojtych S. Escaping unknown discontinuous regions in blackbox optimization // SIAM Journal on Optimization. 2022. Т. 32. № 3. P. 1843–1870.
14. Candelieri A. Sequential model based optimization of partially defined functions under unknown constraints // Journal of Global Optimization. 2019. Т. 73. № 2. P. 281–303.
15. Conrad F. AutoML Applied to Time Series Analysis Tasks in Production Engineering // Procedia Computer Science. 2024. Т. 232. P. 849–860.
16. Filippou K., Aifantis G., Papakostas G.A., Tsekouras G.E. Structure learning and hyperparameter optimization using an automated machine learning (AutoML) pipeline // Information. 2023. Т. 14. № 4. P. 232.
17. Paulavicius R., Sergeyev Y.D., Kvasov D.E., Zilinskas J. Globally-biased BIRECT algorithm with local accelerators for expensive global optimization // Expert Systems with Applications. 2020. Т. 144. P. 113052.

18. Sergeyev Y.D., Kvasov D.E., Mukhametzhano M.S. On the efficiency of nature-inspired metaheuristics in expensive global optimization with limited budget // *Scientific Reports*. 2018. T. 8. № 1. P. 453.
19. Stripinis L., Paulavicius R. A new DIRECT-GLh algorithm for global optimization with hidden constraints // *Optimization Letters*. 2021. T. 15. № 6. P. 1865–1884.
20. Sun Y., Yen G., Yi Z. IGD indicator-based evolutionary algorithm for manyobjective optimization problems // *IEEE Transactions on Evolutionary Computation*. 2019. T. 23. № 2. P. 173–187.
21. Truong A. Towards Automated Machine Learning: Evaluation and Comparison of AutoML Approaches and Tools // *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*. 2019. P. 1471–1479.
22. Wang H., Jin Y., Doherty J. Committee-based active learning for surrogate-assisted particle swarm optimization of expensive problems // *IEEE Transactions on Cybernetics*. 2017. T. 47. № 9. P. 2664–2677.
23. Waring J., Lindvall C., Umeton R. Automated machine learning: Review of the state-of-the-art and opportunities for healthcare // *Artificial Intelligence in Medicine*. 2020. T. 104. P. 101822.
24. Xu N. Time Series Analysis on Monthly Beer Production in Australia // *Highlights in Science, Engineering and Technology*. 2024. T. 94. P. 392–401.

References

1. Akopov A.S. Modeling and Optimization of Individual Decision-Making Strategies in Multi-Agent Socio-Economic Systems Using Machine Learning // *Business Informatics*. 2023. Vol. 17. No. 2. pp. 7–19.
2. Anafiyev A.S., Karyuk A.S. Review of Approaches to Solving the Problem of Hyperparameter Optimization for Machine Learning Algorithms // *Tavrisheskiy Vestnik Informatics and Mathematics*. 2022. No. 2(55). pp. 30-37.
3. Gorbunov S.M., Stanovov V.V. Evolutionary Algorithm for Multicriteria Optimization with Surrogate Machine Learning Models // *Bulletin of the Bauman Moscow State Technical University. Series «Instrument Engineering»*. 2025. No. 2 (151). pp. 48–62.
4. Kleiner S.G. Study of the accuracy of the solution of the hyperparameter optimization problem using a neural network // *Vestnik nauki*. 2025. Vol. 3. No. 6 (87). Pp. 1785–1791.
5. Matveev A.N. Tools for constructing machine learning models // *E-Scio*. 2023. No. 6 (81). Pp. 71–77.
6. Timofeev A.V. Method for selecting hyperparameters in machine learning problems for classifying stochastic objects // *Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*. 2020. Vol. 20. No. 5. Pp. 667–676.
7. Trunov E. E. Algorithm for detecting anomalous behavior of users of automated systems based on machine learning methods // *Bulletin of Astrakhan State Technical University. Series: Control, Computer Engineering, and Informatics*. 2025. No. 4. pp. 33–42.
8. Usova M. A., Lebedev I. G., Shtanyuk A. A., Barkalov K. A. A global optimization algorithm for tuning hyperparameters of machine learning methods // *Problems of Informatics*. 2025. No. 4 (69). pp. 52–72.
9. Khodorchenko M. A., Butakov N. A., Nasonov D. A., Firulik M. Yu. A software framework for optimizing hyperparameters of topic models with additive regularization // *Scientific and Technical Bulletin of Information Technologies, Mechanics, and Optics*. 2023. Vol. 23. No. 1. pp. 112–120.
10. Abdallah M. AutoForecast: Automatic Time-Series Forecasting Model Selection // *Proceedings of the 31st ACM International Conference on Information & Knowledge Management (CIKM '22)*. 2022. P. 5–14.
11. Akiba T., Sano S., Yanase T., Ohta T., Koyama M. Optuna: A Next-Generation Hyperparameter Optimization Framework // *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2019. P. 2623–2631.
12. Ansari A.F. Chronos: Learning the Language of Time Series // *arXiv preprint arXiv:2403.07815*. 2024. / Christ M. Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package) // *Neurocomputing*. 2018. T. 307. P. 72–77.
13. Audet C., Batailly A., Kojtych S. Escaping unknown discontinuous regions in blackbox optimization // *SIAM Journal on Optimization*. 2022. T. 32. № 3. P. 1843–1870.
14. Candelieri A. Sequential model based optimization of partially defined functions under unknown constraints // *Journal of Global Optimization*. 2019. T. 73. № 2. P. 281–303.
15. Conrad F. AutoML Applied to Time Series Analysis Tasks in Production Engineering // *Procedia Computer Science*. 2024. T. 232. P. 849–860.
16. Filippou K., Aifantis G., Papakostas G.A., Tsekouras G.E. Structure learning and hyperparameter optimization using an automated machine learning (AutoML) pipeline // *Information*. 2023. T. 14. № 4. P. 232.

17. Paulavicius R., Sergeyev Y.D., Kvasov D.E., Zilinskas J. Globally-biased BIRECT algorithm with local accelerators for expensive global optimization // *Expert Systems with Applications*. 2020. Т. 144. P. 113052.
18. Sergeyev Y.D., Kvasov D.E., Mukhametzhanov M.S. On the efficiency of nature-inspired metaheuristics in expensive global optimization with limited budget // *Scientific Reports*. 2018. Т. 8. № 1. P. 453.
19. Stripinis L., Paulavicius R. A new DIRECT-GLh algorithm for global optimization with hidden constraints // *Optimization Letters*. 2021. Т. 15. № 6. P. 1865–1884.
20. Sun Y., Yen G., Yi Z. IGD indicator-based evolutionary algorithm for manyobjective optimization problems // *IEEE Transactions on Evolutionary Computation*. 2019. Т. 23. № 2. P. 173–187.
21. Truong A. Towards Automated Machine Learning: Evaluation and Comparison of AutoML Approaches and Tools // *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*. 2019. P. 1471–1479.
22. Wang H., Jin Y., Doherty J. Committee-based active learning for surrogate-assisted particle swarm optimization of expensive problems // *IEEE Transactions on Cybernetics*. 2017. Т. 47. № 9. P. 2664–2677.
23. Waring J., Lindvall C., Umeton R. Automated machine learning: Review of the state-of-the-art and opportunities for healthcare // *Artificial Intelligence in Medicine*. 2020. Т. 104. P. 101822.
24. Xu N. Time Series Analysis on Monthly Beer Production in Australia // *Highlights in Science, Engineering and Technology*. 2024. Т. 94. P. 392–401.

Зарипов Евгений Андреевич, ассистент кафедры инструментального и прикладного программного обеспечения, Российский технологический университет МИРЭА, г. Москва, Россия

Лазаренко Сергей Александрович, студент кафедры инструментального и прикладного программного обеспечения, Российский технологический университет МИРЭА, г. Москва, Россия

Zaripov Evgeny Andreevich, Assistant of the Department of Instrumental and Applied Software, Russian Technological University MIREA, Moscow, Russia

Lazarenko Sergey Alexandrovich, Student of the Department of Instrumental and Applied Software, Russian Technological University MIREA, Moscow, Russia