

Научная статья

Статья в открытом доступе

УДК 004.8

doi: 10.30987/2658-6436-2026-2-78-84

ИНТЕЛЛЕКТУАЛЬНАЯ АВТОМАТИЗИРОВАННАЯ СИСТЕМА УПРАВЛЕНИЯ ПОТОКАМИ ЗАЯВОК ПЛАТФОРМЫ ЦЕЛЕВОГО ВОЗНАГРАЖДЕНИЯ

Никита Олегович Щербачев¹, Дуань Юй², Татьяна Васильевна Карлова³

^{1, 2, 3} Институт конструкторско-технологической информатики Российской академии наук,
г. Москва, Россия

¹ llocker59@gmail.com

² dy2802371190@gmail.com

³ karlova-t@yandex.ru

Аннотация. Целью исследования является разработка архитектуры интеллектуальной автоматизированной системы управления потоками заявок на платформе целевого вознаграждения (CPA-платформе), объединяющей четыре функциональных модуля в замкнутый контур. Решаемая задача – комплексная автоматизация управления, включающая обнаружение мошеннического трафика, оптимизацию назначения кликов на офферы, адаптивную корректировку ставок и прогнозирование объёмов трафика. Используемые методы: каскадный антифрод на основе экспертных правил и градиентного бустинга LightGBM; оптимизатор маршрутизации, сочетающий линейное программирование и ML-предсказание конверсии; адаптивное ценообразование на базе алгоритмов многоруких бандитов (Thompson Sampling, ϵ -greedy, UCB1); ансамблевый прогнозист объёмов трафика на основе моделей ARIMA и Хольта–Уинтерса. Научная новизна работы заключается в том, что впервые четыре разнородных по методологии модуля интегрированы в единый последовательный конвейер обработки заявок CPA-платформы и протестированы на общем наборе данных. Полученные результаты на синтетическом наборе из 200 000 кликов показали: каскадный антифрод обеспечивает $F_1 = 0,787$ при $Precision = 0,992$; LP-маршрутизация увеличивает ожидаемую выручку на 122 %; адаптивные алгоритмы бандитов дают прирост 11...12 %; ансамблевый прогноз обеспечивает $MAPE = 0,66$ %. Реализован программный прототип на Python 3.13 объёмом 3298 строк кода, верифицированный набором из 202 автоматических тестов.

Ключевые слова: автоматизированная система управления, CPA-платформа, обнаружение фрода, машинное обучение, линейное программирование, многорукие бандиты, прогнозирование временных рядов, ARIMA

Для цитирования: Щербачев Н.О., Дуань Юй, Карлова Т.В. Интеллектуальная автоматизированная система управления потоками заявок платформы целевого вознаграждения // Автоматизация и моделирование в проектировании и управлении. 2026. №2 (32). С. 78-84. doi: 10.30987/2658-6436-2026-2-78-84.

Original article

Open Access Article

INTELLIGENT AUTOMATED SYSTEM FOR MANAGING APPLICATION FLOWS OF THE TARGETED REWARD PLATFORM

Nikita O. Shcherbachev¹, Duan Yu², Tatyana V. Karlova³

^{1, 2, 3} Institute for Design-Technological Informatics of the Russian Academy of Sciences, Moscow,
Russia

¹ llocker59@gmail.com

² dy2802371190@gmail.com

³ karlova-t@yandex.ru

Abstract. The aim of this study is to design the architecture of an intelligent automated system for managing application flows of the targeted reward (CPA) platform, integrating four functional modules into a closed-loop system. The objective is to achieve comprehensive automation of management, including fraudulent traffic detection, optimization of click assignment to offers, adaptive bid adjustments, and traffic volume forecasting. The methods used include cascade antifraud based on expert rules and LightGBM gradient boosting; a routing optimizer combining linear programming and ML conversion forecasting; adaptive pricing based on multi-armed bandit algorithms (Thompson Sam-

pling, ϵ -greedy, UCB1); an ensemble forecaster of traffic volume based on the ARIMA and Holt-Winters models. The scientific novelty of the work lies in the fact that for the first time four modules, heterogeneous in their methodology, have been integrated into a unified sequential pipeline for processing applications of a CPA platform and tested on a common data set. The results obtained on a synthetic data set of 200,000 clicks show that cascade antifraud provides $F_1 = 0.787$ with Precision = 0.992; LP routing increases the expected revenue by 122%; adaptive bandit algorithms provide an increase of 11...12%; the ensemble forecast provides MAPE = 0.66%. A software prototype is implemented in Python 3.13, comprising 3,298 lines of code, verified by a set of 202 automated tests.

Keywords: automated management system, CPA platform, fraud detection, machine learning, linear programming, multi-armed bandits, time series forecasting, ARIMA

For citation: Shcherbachev N.O., Duan Yu, Karlova T.V. Intelligent Automated System For Managing Application Flows of the Targeted Reward Platform. Automation and modeling in design and management, 2026, no. 2 (32). pp. 78-84. doi: 10.30987/2658-6436-2026-2-78-84.

Введение

Глобальный рынок партнёрского (аффилиатного) маркетинга в 2024-м году оценивался в 17,5 млрд долларов, а к 2027-му, по прогнозам *Statista*, приблизится к 27,8 млрд [1]. Ядро экосистемы – CPA-платформы (*Cost-Per-Action*), на которых рекламодатель платит партнёру только за целевое действие пользователя: покупку, регистрацию, заполнение формы. Модель привлекательна тем, что переносит риск некачественного трафика с покупателя рекламы на партнёрскую сеть.

Согласно ГОСТ 34.003-90, автоматизированная система управления – это «система, состоящая из персонала и комплекса средств автоматизации его деятельности, реализующая информационную технологию выполнения установленных функций» [2]. В контексте CPA-платформы персоналом выступают менеджеры партнёрской сети, а комплексом средств автоматизации – программные модули обнаружения фрода, оптимизации маршрутизации, адаптивного ценообразования и прогнозирования объёмов. Как показано в работе Ду Цзинь-тао, Дуань Юй и Михайловой, инженерно-психологические параметры человеко-машинного взаимодействия существенно влияют на эффективность управления, а учёт когнитивных ограничений оператора повышает надёжность принимаемых решений [6].

Перенос риска порождает и перенос мотивации к злоупотреблениям. Кликфрод – один из видов сетевого мошенничества, представляющий собой обманные клики на рекламную ссылку лицом, не заинтересованным в рекламном объявлении [3]. По данным *Juniper Research*, ущерб от рекламного мошенничества в 2023-м году превысил 84 млрд долларов [4]; в CPA-сегменте типичные атаки (кликфлуд, бот-трафик, *cookie stuffing*, гео-мисматч) приводят к тому, что до 15...30 % бюджета уходит на фиктивные конверсии. По оценкам аналитиков, 10...15 % кликов на рекламу являются ложными [5]. Ручная модерация при объёме 200...500 тысяч кликов в сутки физически неосуществима: аналитик способен проверить порядка 50...100 подозрительных случаев за рабочий день. Проблема не ограничивается фильтрацией фрода: даже после очистки трафика остаются взаимосвязанные задачи маршрутизации заявок, адаптивного ценообразования и прогнозирования объёмов.

Подавляющая часть исследований по перечисленным направлениям выполнена зарубежными авторами; отечественная литература крайне ограничена [7, 8], что объясняется преимущественным распространением CPA-модели на западных рынках – российские исследовательские группы концентрировались на смежных задачах контекстной рекламы и поведенческого таргетинга. Вместе с тем, проблематика инженерно-психологического обеспечения АСУ в отечественной науке разработана глубоко, о чём свидетельствуют работы школы ИКТИ РАН [6].

Цель работы – спроектировать и экспериментально проверить архитектуру интеллектуальной АСУ CPA-платформы, в которой четыре модуля образуют замкнутый конвейер обработки заявок: каскадный антифрод; оптимизатор маршрутизации; адаптивное ценообразование; ансамблевый прогнозист объёмов. Научная новизна состоит в интеграции разнородных по методологии модулей – экспертных правил, градиентного бустинга, линейного программирования, байесовских алгоритмов принятия решений и ансамблевого прогнозирования временных рядов – в единый последовательный конвейер, протестированный на общем наборе данных.

Материалы и методы

Архитектура системы. Предлагаемая АСУ состоит из пяти последовательных этапов обработки, образующих замкнутый конвейер: генератор данных → антифрод → маршрутизация → ценообразование → прогнозирование (рис. 1). На вход системы поступают клики – записи о визитах пользователей на лендинги рекламодателей, несущие метаданные: идентификатор вебмастера и оффера, *IP*, географию, тип устройства, время на странице, глубину прокрутки. Каждый модуль получает данные от предыдущего и передаёт результаты следующему; прогноз объёмов замыкает контур, влияя на пересмотр дневных лимитов.




Рис. 1. Архитектура замкнутого конвейера АСУ CPA-платформы
Fig. 1. Architecture of the closed-loop CPA platform control pipeline

Антифрод-модуль. Двухэтапная каскадная система: пять статических правил (эвристики кликфлуда, бот-паттерна, гео-мисматча, *cookie stuffing*, ночного трафика низкого качества) формируют скор S_{rules} как нормализованную долю сработавших правил; *ML*-классификатор *LightGBM* обучен на 20 признаках клика. Алгоритм *LightGBM* (*Light Gradient Boosting Machine*) – реализация градиентного бустинга от компании *Microsoft*, способная обрабатывать большие наборы данных при сохранении высокой точности; ключевые особенности – стратегия *leaf-wise growth* и гистограммный метод разбиения признаков [9]. Итоговый скор каскада – выпуклая комбинация:

$$S(x) = \alpha \cdot P_{ML}(x) + (1 - \alpha) \cdot S_{rules}(x), \alpha = 0,7,$$

где α – вес *ML*-компонента; порог бинаризации τ ансамбля оптимизируется по F_1 -мере на валидационной выборке.

Оптимизатор маршрутизации. Линейное программирование – математическая дисциплина, посвящённая методам решения экстремальных задач с линейной целевой функцией при линейных ограничениях [10]. Для каждого дня d решается задача:

$$\max \sum_{i=1}^{N_o} p_i \cdot CR_i \cdot x_i, \quad 0 \leq x_i \leq cap_i, \quad \sum x_i = C_d,$$

где p_i – выплата оффера, CR_i – коэффициент конверсии, cap_i – дневной лимит, C_d – число кликов за день. Задача решается симплекс-методом через программный пакет *HiGHS*. Гибридная модификация заменяет исторические CR_i на *ML*-предсказания, получаемые *LightGBM*-моделью по 12-ти признакам пары (клик, оффер).

Адаптивное ценообразование. Задача о многоруком бандите – одна из основных задач теории принятия решений в условиях неопределённости: агент последовательно выбирает действие, получает случайное вознаграждение и стремится максимизировать суммарную награду, балансируя исследование (*exploration*) и эксплуатацию (*exploitation*) [11]. Для каждого оффера задано $K = 5$ дискретных уровней множителя ставки $m_k \in \{0,5; 0,75; 1,0; 1,25; 1,5\}$. Реализованы три алгоритма: *Thompson Sampling*, ϵ -greedy ($\epsilon = 0,1$), *UCB1*. Награда учитывает штраф за стоимость:

$$r = c - \lambda \cdot m_k, \quad c \in \{0,1\}, \quad \lambda = 0,3.$$

Прогнозирование объёмов. *ARIMA* (*autoregressive integrated moving average*) – интегрированная модель авторегрессии – скользящего среднего, или модель Бокса-Дженкинса –

комбинация моделей AR и MA , расширенная для нестационарных рядов через взятие разностей [12]. Запись $ARIMA(p, d, q)$ означает, что разности порядка d подчиняются модели $ARMA(p, q)$. Использованы: $ARIMA(1, 1, 1)$; метод Хольта-Уинтерса с аддитивной сезонностью периода $s = 7$; ансамблевый прогнозист – равновесная комбинация $\hat{y}_{ens} = 0,5 \cdot \hat{y}_{ARIMA} + 0,5 \cdot \hat{y}_{HW}$.

Условия эксперимента. Все модули реализованы на Python 3.13 с использованием *pandas*, *NumPy*, *SciPy*, *scikit-learn*, *LightGBM*, *statsmodels*. Синтетический датасет: 200 000 кликов, 30 офферов с выплатами 50...5000 руб., 200 веб-мастеров, 30 дней, доля фрода $\approx 15\%$, моделируется пять типов фрода (кликфлуд, бот-трафик, гео-мисматч, *cookie stuffing*, *device spoofing*). Зерно генератора = 42 для воспроизводимости. Выборка разбивалась стратифицированно (по метке *isfraud*) на обучающую (60 %), валидационную (20 %) и тестовую (20 %).

Результаты

Метрики качества классификации антифрод-модуля на тестовой выборке (40 000 кликов) приведены в табл. 1. ML -модель резко превосходит правила по *Precision* (+18,4 п.п.) и F_1 (+9,1 п.п.). Каскадный ансамбль ($\alpha = 0,7$) добавляет 0,1 п.п. к *Precision*, не теряя в остальных метриках; высокая *Precision* – критическое свойство для CPA -платформы, поскольку ложноположительное срабатывание блокирует легитимный клик.

Таблица 1
Table 1

Метрики антифрод-модуля <i>Metrics of the antifraud module</i>					
Система	<i>Precision</i>	<i>Recall</i>	F_1	<i>AUC-ROC</i>	<i>AUC-PR</i>
Правила (5 эвристик)	0,807	0,612	0,696	0,804	0,597
ML (<i>LightGBM</i>)	0,991	0,653	0,787	0,891	0,817
Каскад ($\alpha = 0,7$)	0,992	0,653	0,787	0,890	0,816

Сравнение стратегий маршрутизации по выручке относительно случайного назначения – в табл. 2. Все три метода дают прирост свыше 100 %; LP -маршрутизатор лидирует (+122 %) за счёт глобальной оптимизации с учётом всех ограничений одновременно.

Таблица 2
Table 2

Метрики маршрутизации <i>Routing metrics</i>			
Метод	Выручка (руб.)	Прирост	Ср. CR
Оригинал (случайное назначение)	28 433 221	—	0,052
LP (<i>HiGHS</i>)	63 150 891	+122,1 %	0,080
ML (<i>LightGBM greedy</i>)	61 316 973	+115,7 %	0,074
Гибрид ($ML \rightarrow LP$)	60 597 571	+113,1 %	0,072

Результаты адаптивного ценообразования (2000 раундов симуляции) собраны в табл. 3. Все три алгоритма сошлись к множителям $\approx 0,5$: при $\lambda = 0,3$ высокие множители «съедают» маржу, и агенты обучаются тому, что умеренное снижение ставки сокращает расходы быстрее, чем падает конверсия.

Таблица 3
Table 3

Метрики ценообразования (2000 раундов) <i>Pricing metrics (2000 rounds)</i>			
Метод	Прирост выручки	Ср. множитель	Офферов скоррект.
<i>Thompson Sampling</i>	+11,6 %	0,558	30/30
ϵ - <i>greedy</i>	+12,0 %	0,517	29/30
<i>UCB1</i>	+12,4 %	0,517	30/30

Метрики прогнозирования объёмов на горизонте 6 дней (обучение на 24 дня) приведены в табл. 4. Средняя абсолютная ошибка (MAE) показывает, на сколько единиц в среднем ошибается модель; корень из среднеквадратической ошибки ($RMSE$) штрафует большие от-

клонения сильнее; средняя абсолютная процентная ошибка (*MAPE*) выражает ошибку в процентах от факта [12]. Ансамблевая модель лидирует по всем метрикам; *MAPE* < 1 % достаточен для оперативного планирования мощностей. Прогноз ансамбля относительно фактических объёмов с 95 %-ным доверительным интервалом представлен на рис. 2.

Таблица 4
Table 4

Метрики прогнозирования (горизонт 6 дней)

Forecasting metrics (horizon 6 days)

Модель	<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i> , %	<i>R</i> ²
<i>ARIMA</i> (1, 1, 1)	44,2	54,8	0,67	-0,210
Хольт-Уинтерс	48,2	50,3	0,73	-0,021
Ансамбль	43,7	49,9	0,66	-0,002



Рис. 2. Прогноз объёма трафика vs факт (горизонт 6 дней) с 95 %-ным доверительным интервалом
Fig. 2. Forecast vs. actual daily traffic (6-day horizon) with 95% confidence interval

Обсуждение

Каскад vs чистый ML. Каскадный ансамбль практически не улучшает F_1 относительно чистого *LightGBM* (+0,1 п.п. *Precision*), что поднимает вопрос: оправдана ли дополнительная сложность? Мы полагаем, что да – по двум причинам. Во-первых, правила интерпретируемы: аналитик может объяснить блокировку конкретного клика, что критично для взаимодействия с веб-мастерами. Во-вторых, при деградации *ML*-модели (дрейф данных, сбой переобучения) правила продолжают работать как страховочная сеть.

LP vs гибрид в маршрутизации. Чистый *LP* показал наибольший прирост выручки, опередив гибрид на 9 п.п. Этот результат, на наш взгляд, специфичен для синтетических данных, где *CR* стабилен. На реальной платформе *CR* офферов дрейфует: новые лендинги, сезонные колебания, усталость аудитории. В таких условиях *ML*-предсказания *CR* должны дать гибриду преимущество перед историческими средними.

Множители ниже единицы. Все алгоритмы ценообразования сошлись к множителям $\approx 0,5$, снижая выплаты веб-мастерам. Для реальной платформы это допустимо лишь при достаточной конкуренции среди веб-мастеров; иначе снижение ставок приведёт к оттоку трафика. Расширение модели вознаграждения – включение фактора удержания партнёров – остаётся открытой задачей.

Человеческий фактор. Автоматизация не устраняет оператора из контура управления – она перераспределяет его роль от рутинных проверок к принятию решений на основе агрегированной информации. Как подчёркивают Ду Цзиньтао, Дуань Юй и Михайлова, «инженерно-психологические параметры, такие как порог восприятия информации, скорость принятия решений и устойчивость внимания оператора, определяют верхнюю границу эффективности человеко-машинной системы в целом» [6]. В нашей архитектуре эта граница проявляется в

модуле антифрода: сохранение интерпретируемых правил наряду с *ML*-классификатором обеспечивает возможность аудита решений аналитиком.

Ограничения. Эксперименты проводились на синтетических данных. Хотя генератор моделирует реалистичные распределения (бета-распределение качества, логнормальное распределение объёмов, суточная сезонность), перенос результатов на живой трафик требует валидации. Обратная связь от прогнозиста к генератору данных в текущей реализации носит концептуальный характер; в продуктивной системе прогноз должен влиять на лимиты и бюджеты в реальном времени. Реальные данные *CPA*-платформ подвержены дрейфу распределений: статистические характеристики трафика изменяются вследствие сезонных колебаний, появления новых типов мошеннических атак и модификации алгоритмов рекламных площадок, что требует периодического переобучения моделей или применения методов онлайн-обучения.

Заключение

В работе предложена и экспериментально проверена архитектура интеллектуальной автоматизированной системы управления для платформы целевого вознаграждения (*CPA*-платформы), объединяющей четыре функциональных модуля – обнаружение мошеннического трафика, оптимизацию маршрутизации заявок, адаптивное ценообразование и прогнозирование объёмов – в замкнутый контур управления. Разработанная система относится к классу интеллектуальных систем поддержки принятия решений, в которых методы машинного обучения и математической оптимизации применяются для автоматизации рутинных операций управления.

Каскадный антифрод, совмещающий пять экспертных правил и *LightGBM*-классификатор, достигает $F_1 = 0,787$ при $Precision = 0,992$, что минимизирует блокировку легитимного трафика. *LP*-маршрутизация перераспределяет клики по офферам с приростом ожидаемой выручки на 122 %. Алгоритмы многоруких бандитов адаптивно корректируют ставки, обеспечивая прирост 11...12 %. Ансамбль *ARIMA* и Хольта-Уинтерса прогнозирует дневные объёмы трафика с $MAPE = 0,66$ %. Программный прототип (*Python* 3.13, 3 298 строк, 202 теста) пригоден для интеграции в *backend CPA*-платформы через *REST API*.

Как отмечают Советов и Яковлев, «адекватность имитационной модели определяется степенью совпадения результатов моделирования с результатами натурального эксперимента при одинаковых условиях функционирования» [13], в связи с этим ключевым этапом дальнейшей работы является валидация прототипа на реальных данных партнёрской сети. Перспективы определяются следующими направлениями: валидация прототипа на реальных данных действующей партнёрской сети, адаптация модуля ценообразования к задаче удержания веб-мастеров через включение факторов лояльности и долгосрочной ценности партнёра, применение онлайн-обучения для антифрод-модели в условиях дрейфа распределений, расширение прогнозиста нейросетевыми моделями временных рядов (*LSTM*, *Transformer*). Практическая значимость работы заключается в возможности использования предложенной архитектуры в качестве основы для промышленной системы управления потоками заявок *CPA*-платформы.

Список источников:

1. Statista Research Department. Affiliate marketing spending in the United States from 2010 to 2025. 2024. URL: <https://www.statista.com/statistics/693438/affiliate-marketing-spending/> (дата обращения: 09.05.2026).
2. ГОСТ 34.003-90. Информационная технология. Комплекс стандартов на автоматизированные системы. Автоматизированные системы. Термины и определения. – М.: Издательство стандартов, 1990. – 16 с.
3. Mouawi R., Safa N.S., Selamat A. Click Fraud Detection: A Systematic Literature Review // Recent Advances in Information and Communication Technology // Springer. – 2019. – P. 164-174.

References:

1. Statista Research Department. Affiliate Marketing Spending in the United States from 2010 to 2025 [Internet]. 2024 [cited 2026 May 09]. Available from: <https://www.statista.com/statistics/693438/affiliate-marketing-spending>
2. GOST 34.003-90. Information Technology. Set of Standards for Automated Systems. Automated Systems. Terms and Definitions. Moscow: Izdatelstvo Standartov; 1990.
3. Mouawi R, Safa NS, Selamat A. Click Fraud Detection: A Systematic Literature Review. In: Recent Advances in Information and Communication Technology. Springer; 2019. p. 164-174.

4. Juniper Research. Online Ad Fraud: Key Trends, Segment Analysis and Market Forecasts 2023–2028. Juniper Research Ltd, 2023.
5. Kshetri N. The Economics of Click Fraud // IEEE Security and Privacy. – 2010. – Vol. 8. – No. 3. – P. 45-53.
6. Ду Цзиньтао, Дуань Юй, Михайлова М.В. Влияние инженерно-психологических параметров на оптимизацию управления производством и повышение качества выпускаемой продукции (международный опыт) // Автоматизация и моделирование в проектировании и управлении. – 2024.
7. Перов И. А., Сидоров В. Н. Архитектура интеллектуальной автоматизированной системы управления рекламной платформой // Автоматизация в промышленности. – 2021. – Т. 19. – № 3. – С. 45-52.
8. Сафонов А.В., Петров Д.А. Нечёткая экспертная система для обнаружения мошеннического трафика в контекстной рекламе // Программная инженерия. – 2019. – Т. 10. – № 5. – С. 234-242.
9. Ke G., Meng Q., Finley T., Wang T., Chen W., Ma W., Ye Q., Liu T.-Y. LightGBM: A Highly Efficient Gradient Boosting Decision Tree // Advances in Neural Information Processing Systems (NeurIPS). – 2017. – Vol. 30. – P. 3146-3154.
10. Bertsimas D., Tsitsiklis J.N. Introduction to Linear Optimization. Athena Scientific. – 1997. – 608 p.
11. Slivkins A. Introduction to Multi-Armed Bandits // Foundations and Trends in Machine Learning. – 2019. – Vol. 12. – P. 1-286.
12. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. Time Series Analysis: Forecasting and Control. 5th ed. John Wiley & Sons. – 2015. – 712 p.
13. Советов Б.Я., Яковлев С.А. Моделирование систем. 5-е изд. – М.: Высшая школа, 2006. – 343 с.
4. Juniper Research. Online Ad Fraud: Key Trends, Segment Analysis and Market Forecasts 2023-2028. Juniper Research Ltd; 2023.
5. Kshetri N. The Economics of Click Fraud. IEEE Security and Privacy. 2010;8(3):45-53.
6. Du J., Duan Yu., Mikhailova M.V. The Influence of Engineering and Psychological Parameters on Optimizing Production Management and Improving Product Quality (International Experience). Automation and Modelling in Design and Management. 2024.
7. Perov I.A., Sidorov V.N. Architecture of an Intelligent Automated System for Managing an Advertising Platform. Automation in Industry. 2021;19(3): 45-52.
8. Safonov A.V., Petrov D.A. Fuzzy Expert System for Detecting Fraudulent Traffic in Contextual Advertising. Software Engineering. 2019;10(5):234-242.
9. Ke G, Meng Q, Finley T, et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. In: Advances in Neural Information Processing Systems (NeurIPS); 2017; vol. 30. p. 3146-3154.
10. Bertsimas D., Tsitsiklis J.N. Introduction to Linear Optimization. Athena Scientific; 1997.
11. Slivkins A. Introduction to Multi-Armed Bandits. Foundations and Trends in Machine Learning. 2019;12:1-286.
12. Box GEP, Jenkins GM, Reinsel GC, et al. Time Series Analysis: Forecasting and Control. 5th ed. John Wiley & Sons; 2015.
13. Sovetov B.Ya., Yakovlev S.A. System Modeling. 5th ed. Moscow: Vysshaya Shkola; 2006.

Информация об авторах:

Щербачев Никита Олегович

аспирант Института конструкторско-технологической информатики РАН.

Дуань Юй

аспирант Института конструкторско-технологической информатики РАН.

Карлова Татьяна Васильевна

доктор социологических наук, профессор Института конструкторско-технологической информатики РАН.

Information about the authors:

Shcherbachev Nikita Olegovich

Postgraduate student of the Institute for Design-Technological Informatics of the Russian Academy of Sciences.

Duan Yu

Postgraduate student of the Institute for Design-Technological Informatics of the Russian Academy of Sciences.

Karlova Tatyana Vasilyevna

Doctor of Sociology, Professor of the Institute for Design-Technological Informatics of the Russian Academy of Sciences.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.

Contribution of the authors: the authors contributed equally to this article.

Авторы заявляют об отсутствии конфликта интересов.

The authors declare no conflicts of interests.

Статья поступила в редакцию 16.04.2026; одобрена после рецензирования 30.04.2026; принята к публикации 06.05.2026.

The article was submitted 16.04.2026; approved after reviewing 30.04.2026; accepted for publication 06.05.2026.