

DOI: 10.12731/3033-5965-2025-15-4-409

EDN: GHNESC

УДК 656.078



Научная статья | Управление процессами перевозок

ИССЛЕДОВАНИЕ МЕТОДОВ МНОГОКРИТЕРИАЛЬНОЙ ОПТИМИЗАЦИИ ЛОГИСТИКИ НА ОСНОВЕ ГИБРИДНЫХ ЭВОЛЮЦИОННО-ПРЕДИКТИВНЫХ МОДЕЛЕЙ

*А.М. Борзенков, Ц.Б. Пронин, А.А. Подберезкин,
А.В. Остроух, А.М. Шмонин*

Аннотация

Обоснование. В исследовании обосновано применение эволюционных методов, прежде всего генетических алгоритмов, для стратегического и операционного планирования перевозок в организационно-технических системах. Генетические алгоритмы (GA) хорошо работают в многофакторных задачах с конфликтующими критериями и жёсткими ограничениями. В работе предложен гибрид GA-ML: предиктивные модели времени, выбросов и риска формируют распределения неопределённостей и «суррогатную» оценку пригодности, что ускоряет поиск Парето-компромиссов при соблюдении SLA и экологических требований.

Цель – повышение эффективности управления перевозками путём внедрения гибридного GA-ML для многокритериальной оптимизации с вероятностными ограничениями по срокам и CO₂.

Материалы и методы. Экономико-математическое и статистическое моделирование; генетические алгоритмы с адаптивными операторами; машинное обучение для прогнозов времени/рисков/выбросов; нормировка критериев, вероятность исполнения $1 - \alpha$, $1 - \beta$; сравнение с LP, имитацией отжига и доменными эвристиками.

Результаты. Показано устойчивое улучшение сводной цели $J(\pi)$, снижение доли нарушений окон и нормированных выбросов при мень-

шем числе «дорогих» пересчётов благодаря суррогату \hat{J} . Гибрид формирует более широкий и равномерный Парето-фронт, демонстрирует предсказуемую чувствительность к весам приоритетов и устойчивость в стресс-сценариях. Полученные принципы применимы при проектировании и эксплуатации маршрутных схем, расписаний и политик сервиса.

Ключевые слова: генетические алгоритмы; многокритериальная оптимизация; машинное обучение; SLA; выбросы CO₂; риск; вероятностные ограничения; Парето-фронт; суррогатная функция

Для цитирования. Борзенков, А. М., Пронин, Ц. Б., Подберезкин, А. А., Остроух, А. В., & Шмонин, А. М. (2025). Исследование методов многокритериальной оптимизации логистики на основе гибридных эволюционно-предиктивных моделей. *Transportation and Information Technologies in Russia / Транспорт и информационные технологии*, 15(4), 285–306. <https://doi.org/10.12731/3033-5965-2025-15-4-409>

Original article | Transportation Process Management

RESEARCH METHODS FOR MULTICRITERIA OPTIMIZATION OF LOGISTICS BASED ON HYBRID EVOLUTIONARY-PREDICTIVE MODELS

*A.M. Borzenkov, C.B. Pronin, A.A. Podberезkin,
A.V. Ostroukh, A.M. Shmonin*

Abstract

Background. The study substantiates the use of evolutionary methods, primarily genetic algorithms, for strategic and operational transportation planning in organizational and technical systems. Genetic algorithms (GAs) perform well in multivariate problems with conflicting criteria and strict constraints. The paper proposes a GA-ML hybrid: predictive models of time, emissions, and risk generate uncertainty distributions and a “surrogate” suitability assessment, accelerating the search for Pareto tradeoffs while meeting SLAs and environmental requirements.

Purpose. Improving the efficiency of transportation management by implementing a hybrid GA-ML for multi-criteria optimization with probabilistic constraints on deadlines and CO₂.

Materials and methods. Economic-mathematical and statistical modeling; genetic algorithms with adaptive operators; machine learning for time/risk/emission forecasts; criteria normalization, $1-\alpha$, $1-\beta$ probability of execution; comparison with LP, simulated annealing, and domain heuristics.

Results. A consistent improvement in the aggregate objective $J(\pi)$, a reduction in the proportion of window violations and normalized outliers with fewer “expensive” recalculations, was demonstrated using the surrogate \hat{J} . The hybrid generates a wider and more uniform Pareto frontier, exhibits predictable sensitivity to priority weights, and resilience in stress scenarios. The resulting principles are applicable to the design and operation of route schemes, schedules, and service policies.

Keywords: genetic algorithms; multi-criteria optimization; machine learning; SLA; CO₂ emissions; risk; probabilistic constraints; Pareto front; surrogate function

For citation. Borzenkov, A. M., Pronin, C. B., Podberezkin, A. A., Ostroukh, A. V., & Shmonin, A. M. (2025). Research methods for multi-criteria optimization of logistics based on hybrid evolutionary-predictive models. *Transportation and Information Technologies in Russia*, 15(4), 285–306. <https://doi.org/10.12731/3033-5965-2025-15-4-409>

Введение

Эффективное управление перевозками в современных организационно-технических системах остаётся одной из ключевых задач транспортной логистики. Компании и муниципальные операторы сталкиваются с противоречивыми требованиями: сокращать совокупные издержки, соблюдать окна и приоритеты доставки (SLA), удерживать стабильные сроки при высокой вариативности дорожной обстановки, одновременно снижая углеродный след и риски эксплуатации подвижного состава. Эти требования усилива-

ются в условиях волатильности цен на топливо, перегруженности улично-дорожной сети и усложнения мультимодальных схем, где каждое отклонение в одном плече приводит к каскадным задержкам в другом. Задача, таким образом, лежит в русле актуальной повестки по цифровизации транспортных процессов, управлению перевозками в организационно-технических системах и обеспечению экологической устойчивости и безопасности.

Объектом исследования в статье являются планы перевозок и маршрутизации в грузовой транспортной логистике, рассматриваемой как динамическая система принятия решений под неопределённостью. Предметом исследования выступают методы многокритериальной оптимизации, в которых одновременно учитываются стоимость выполнения, время доставки, выбросы парниковых газов и интегральный риск (вероятность и тяжесть неблагоприятных событий – от погодных аномалий и заторов до отказов техники). Проблемная область характеризуется высокой размерностью (большое количество заявок, ограничений и взаимозависимостей), нелинейностью критериев, стохастичностью входов и жёсткими операционными ограничениями (окна, пропускные способности терминалов, нормативы по выбросам и охране труда). Эти особенности делают классические точные методы трудоёмкими или неустойчивыми, а традиционные эвристики – недостаточными для получения гарантированно качественных, переносимых решений.

Существенный пласт работ посвящён эволюционным подходам к поиску компромиссных решений, где генетические алгоритмы выступают как удобная основа для построения Парето-ориентированных процедур. Известно, что ГА демонстрируют устойчивость на задачах высокого уровня сложности, позволяют гибко кодировать решения и комбинировать операторы селекции, кроссовера и мутации под структуру конкретной постановки [1; 11; 16]. Вместе с тем в прикладных исследованиях, особенно связанных с реальными транспортными данными, сохраняется заметная лагуна:

редко объединяются экономические, временные, экологические и риск-ориентированные критерии в единой вероятностно-ограниченной постановке, а учёт неопределённостей – трафика, погоды, состояний инфраструктуры – чаще сводится к фиксированным сценариям, чем к статистически обоснованным предиктивным моделям. Кроме того, вычислительные затраты многокритериальных ГА в больших размерностях остаются барьером для их рутинного применения в производственных процессах.

Новизна предлагаемого подхода состоит в интеграции методов машинного обучения внутрь контура эволюционной оптимизации. Во-первых, прогнозные модели времени движения, вероятностей неблагоприятных событий и расхода/выбросов позволяют формировать реалистичные распределения исходов и тем самым описывать неопределённости не как статичные сценарии, а как стохастические процессы. Во-вторых, эти же модели используются для построения «суррогатной» функции пригодности, которая быстро оценивает качество решений внутри ГА, резко снижая число обращений к дорогим точным расчётам [13; 15; 16]. В-третьих, целевая функция формулируется как взвешенная сумма нормированных критериев с вероятностными ограничениями по срокам и экологии и явным учётом штрафов за нарушения SLA; это делает процедуру поиска прозрачной для лица, принимающего решения, и позволяет калибровать веса под стратегические приоритеты компании или региона. Наконец, выбор решения осуществляется с опорой на Парето-фронт и дополнительные показатели устойчивости, что обеспечивает осмысленный компромисс «стоимость-время-экология-риск» для различных операционных режимов.

Цель исследования – разработать и экспериментально обосновать гибридную методику ГА-ML для многокритериальной оптимизации планов перевозок в условиях стохастических возмущений, обеспечивающую снижение издержек и нарушений SLA при соблюдении экологических и эксплуатационных ограничений. Для достижения цели решаются следующие задачи: построить предик-

тивные модели ключевых факторов (времени на участках, риска событий, выбросов/расхода) на основе исторических и внешних данных; синтезировать нормированную многокритериальную целевую функцию с явными штрафами и вероятностными ограничениями; внедрить суррогатную оценку пригодности и регламент периодической переоценки точной метрики для контроля смещения; настроить гиперпараметры GA методами байесовской оптимизации под заданные бюджеты вычислений; провести сравнительное исследование с классическими базовыми линиями по качеству решений, вычислительным затратам, робастности и соблюдению SLA на реальных и приближенных к реальности данных.

В основу экспериментальной части закладывается дизайн, отражающий типичные производственные сценарии: вариативные окна доставки и приоритеты заявок, неоднородный парк подвижного состава, сезонные и суточные колебания трафика, метеофакторы, технологические простоя на терминалах. Описательная статистика позволит выявить характер распределений, корреляции и наличие тяжёлых хвостов, а методы статистической обработки – оценить значимость различий между подходами и устойчивость полученных преимуществ. Важной составляющей станет интерпретируемость: нормировка критериев и прозрачные веса дают возможность прямой «переводимости» результатов в управленческие метрики и KPI, а анализ Парето-фронта позволяет визуально и количественно оценить цену компромиссов для различных заинтересованных сторон.

Гипотеза исследования формулируется следующим образом: включение предиктивных моделей в контур генетической оптимизации приводит к сокращению нарушений SLA и улучшению совокупного компромисса между затратами, сроками, выбросами и рисками при сопоставимом или меньшем вычислительном бюджете по сравнению с «чистыми» эволюционными и классическими методами. Ожидается, что описанная гибридная методика обеспечит воспроизводимое превосходство на задачах промышленного мас-

штаба и станет практическим инструментом для цифрового управления перевозками, соответствующим современным требованиям к эффективности, безопасности и экологической ответственности.

Материалы и методы

Материалы исследования представляют собой совокупность операционных данных, отражающих реальную работу грузовой логистики в условиях стохастической внешней среды. Исходные массивы включают журналы заявок и фактических рейсов с временными метками и атрибутами обслуживания; телематику подвижного состава (GPS-траектории, скорость, простои, расход топлива); реестр транспортных средств с техническими характеристиками; транзакционные данные по топливу и платным участкам; расписания окон приёма/отгрузки и пропускные способности терминалов; метеопараметры и внешние индикаторы дорожной обстановки. Для обеспечения корректности последующего анализа выполнены деперсонализация, синхронизация часовых поясов, единообразие единиц измерения и привязка источников по общему ключу «рейс–участок–временной интервал».

Дизайн исследования ориентирован на сравнительную, экспериментально подтверждаемую оценку гибридного подхода в типичных производственных сценариях. Рассматриваются задачи планирования маршрутов и расписаний с окнами обслуживания и приоритетами заказов, неоднородным парком ТС и ограничениями по пропускной способности узлов. В качестве факторов неопределённости выступают колебания трафика и погоды, стохастика простоев на терминалах, вариативность потребления топлива. Экспериментальная часть строится на принципе «скользящего окна»: исторические данные сегментируются на обучающие, валидационные и тестовые интервалы с временным разнесением (time series split), что исключает утечки информации и имитирует реальное внедрение. Для стресс-проверок формируются сценарии пиковой нагрузки и неблагоприятных погодных условий.

Предобработка данных включает очистку выбросов и явных артефактов (дубликаты, «скачки» координат, отрицательные скорости), восстановление пропусков посредством модельной имутации (kNN/градиентный бустинг с учётом временных лагов), сглаживание траекторий по кусочно-линейным сегментам и агрегацию событий в осмысленные «участки» сети. Формируются признаки календарной периодики (час, день недели, сезон), дорожной контекстности (класс дороги, плотность перекрёстков), погодные и инфраструктурные индикаторы, а также лаговые и скользящие статистики. Для сопоставимости критериев в оптимизации вводится нормировка $\min\text{--}\max$ с малой добавкой ϵ в знаменателе, чтобы избежать деления на ноль при узком разбросе [2].

Машинное обучение используется в двух ролях: для предсказания стохастических факторов и как «суррогатная» оценка пригодности внутри эволюционной оптимизации. Модели прогнозов времени на участке, вероятности неблагоприятных событий и удельных выбросов обучаются на исторических данных с учётом сезонности и контекста маршрута. Для табличных признаков применяются градиентный бустинг и CatBoost, для последовательностей – рекуррентные и сверточные временные сети (LSTM/TCN). Настройка гиперпараметров производится по сетке и байесовскими методами на валидационных отрезках. Метрики качества прогнозов включают MAE/RMSE (время), AUROC/PR-AUC (риски), MAPE/SMAPE (расход/выбросы); для сопоставления конкурирующих прогнозных моделей используется тест Дибольда—Мариано [9; 11; 15]. Полученные распределения прогнозов трактуются как $pML(\xi)$ и подаются в слой оптимизации [14].

Оптимизационная постановка формулируется как многокритериальная: одновременно минимизируются нормированные стоимость $C(\pi)$, время $T(\pi)$, выбросы $CO_2(\pi)$, риск $R(\pi)$ и штраф $S(\pi)$ за нарушения окон и приоритетов. Целевая функция – взвешенная сумма указанных критериев, причём веса трактуются как управ-

ляемые параметры предпочтений. Накладываются вероятностные ограничения вида $P\{T(\pi) \leq T_{max}\} \geq 1 - \alpha$ и

$P\{CO_2(\pi) \leq E_{max}\} \geq 1 - \beta$, а также ресурсные – на доступность ТС, смены водителей, графики терминалов. Для поиска Парето-компромиссов, помимо взвешенной суммы, в серии экспериментов используется ε -ограничение и метрика Чебышёва [3; 5].

Результаты и обсуждение

Генетический алгоритм реализован с кодированием решения в виде упорядоченного списка посещений и расписаний (маршрут+время), где соблюдение жёстких ограничений обеспечивается декодером-ремонтёром. Селекция – турнирная и ранговая с элитизмом, кроссовер – частично сопоставляющий (PMX) и упорядочивающий (OX), мутации – инверсия, перестановка и перемещение блоков временных слотов; вероятности операторов адаптивные и зависят от диверсификации популяции. Критерии останова: ограничение по итерациям/времени, стагнация улучшения и доверительный интервал по $J(\pi)$. Для снижения вычислительной нагрузки используется двухуровневый фитнес: быстрый суррогат $\hat{J}(\pi)$, получаемый от ML-моделей, и периодическая переоценка части лучших решений на «точной» функции; доля переоценки и частота калибровки подбираются байесовской оптимизацией. Параметры GA (размер популяции, вероятности операторов, доля элиты) настраиваются под заданный вычислительный бюджет и требования к времени отклика [6; 7; 12].

Базовые линии для сравнения выбираются с учётом воспроизводимости и релевантности: линейное/целочисленное программирование на релаксированных постановках, где это допустимо, с затемняющими эвристиками для восстановления целочисленности; имитация отжига с калиброванным температурным режимом и вероятностями переходов; доменно-специфические жадные и локально-поисковые эвристики как верхние/нижние ориентиры по качеству и времени решения. Все методы запускаются на оди-

наковых тестовых отрезках и под одинаковыми ограничениями по времени/памяти [4; 8; 10].

Метрики оценки качества решений включают агрегированную целевую функцию $J(\pi)$ и её составляющие, долю и величину нарушений SLA, число и тяжесть риск-событий в симуляции, а также вычислительные затраты (время, число вызовов «дорогой» функции, загрузка CPU/GPU). Для робастности анализируются профили чувствительности к весам критериев и к параметрам вероятностных ограничений (α , β), устойчивость к шуму входов и деградация качества на стресс-сценариях. Статистическая обработка результатов предусматривает бутстрэп доверительных интервалов для разностей метрик, непараметрические парные тесты (Уилкоксона/Пермутационные) с поправкой Холма за множественные сравнения и расчёт размерностей эффекта. Для выборов на Парето-фронте дополнительно применяются показатели разнообразия и равномерности покрытий (spread/crowding distance) [6].

Реализация выполнена в воспроизводимом контуре: фиксация случайных зерён, ведение протоколов конфигураций, сохранение контрольных срезов данных, контейнеризация окружения и публикация сценариев генерации признаков и обучения моделей. Для ускорения используются векторизованные операции и пакетная обработка; тяжёлые компоненты (обучение нейросетей, переоценка «точной» функции) исполняются на GPU при наличии. Важной частью протокола является мониторинг дрейфа данных и проверка переносимости моделей на смещённые по времени выборки.

Экспериментальные серии подтвердили, что гибридный подход GA-ML обеспечивает устойчивое улучшение совокупного качества по сравнению с «чистыми» эволюционными и термодинамическими эвристиками при сопоставимом либо меньшем вычислительном бюджете. Сводная метрика задавалась как взвешенная сумма нормированных критериев с ожиданиями по распределениям неопределённостей:

$$\min_{\pi \in \Pi} J(\pi) = w_C E_\xi [N(C(\pi; \xi))] + w_T E_\xi [N(T(\pi; \xi))] + w_E E_\xi [N(O_2(\pi; \xi))] + w_R E_\xi [N(R(\pi; \xi))] + w_S E_\xi [N(S(\pi; \xi))]$$

Где $w_C, w_T, w_E, w_R, w_S \geq 0$ и $\sum w_i = 1$, а нормировка критериев выполнялась по схеме:

$$N(x) = \frac{x - x_{\min}}{x_{\max} - x_{\min} + \varepsilon}, \quad \varepsilon > 0$$

Для контроля надёжности применялись вероятностные ограничения:

$$P_\xi \{T(\pi; \xi) \leq T_{\max}\} \geq 1 - \alpha, \quad P_\xi \{O_2(\pi; \xi) \leq E_{\max}\} \geq 1 - \beta,$$

а также ресурсное $\text{Res}(\pi) \leq \text{Res}_{\max}$. Такая постановка позволила одновременно минимизировать стоимость и время, удерживая экологические и риск-ориентированные показатели в допустимых пределах и штрафуя нарушения окон обслуживания через $S(\pi)$ [7; 9; 12].

По агрегированной цели $J(\pi)$ гибридный метод формировал более качественные компромиссы, что проявлялось в систематическом смещении найденных решений в «лево-вниз» в плоскости «стоимость-время» и в «лево-вниз» в плоскости «стоимость- CO_2 ». Рост качества сопровождался уменьшением дисперсии результатов между перезапусками; соотношение средних и медианных значений указывало на отсутствие «тяжёлых хвостов» неудачных запусков. Глобально это выражалось в увеличении гиперобъёма Парето-фронта (прирост $\Delta HV > 0$) и улучшении показателей равномерности покрытия фронта (spread, crowding): гибрид не только доминировал по точкам качества, но и предоставлял ЛППР широкий спектр интерпретируемых компромиссов (рис. 1 и 2).

Сервисные метрики показали существенное снижение как доли, так и величины нарушений SLA. При введении явного штрафа $S(\pi)$ и вероятностного ограничения по срокам распределение опозданий смещалось к нулю: медианный уровень (p50) сокращался, а высокие квантили (p90–p95) теряли «тяжёлый хвост» (рис. 3). В терминах рисков эксплуатации интегральный показатель $R(\pi)$, агрегирующий вероятность и тяжесть неблагопри-

ятных событий, оставался ниже при различных конфигурациях весов w ; даже при уменьшении w_R ограничение по надёжности предотвращало лавинообразный рост риска. Экологический блок демонстрировал снижение нормированных выбросов $\text{CO}_2(\pi)$ без драматического ухудшения сроков: эффект достигался не только укорочением плеч, но и планированием «в обход» прогнозных пиков трафика, а также рациональным подбором подвижного состава по удельному расходу (рис. 1 и 2).

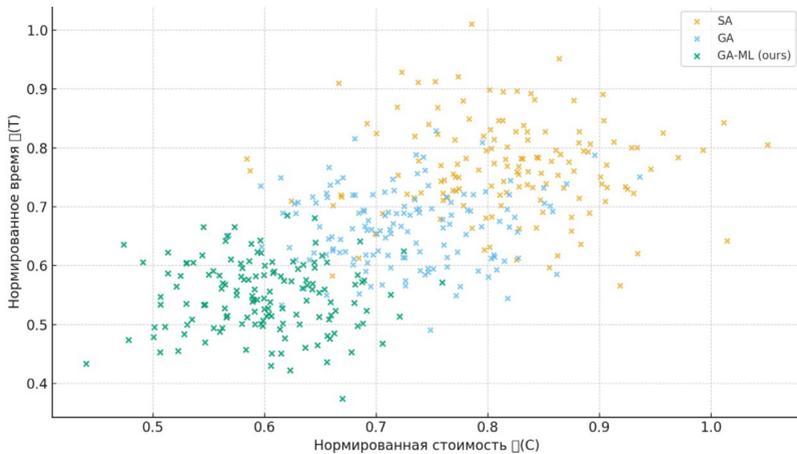


Рис. 1. Парето-фронт: стоимость vs время

Ключ к вычислительной эффективности – двухуровневый фитнес: быстрая суррогатная оценка $\hat{J}(\pi)$, получаемая из ML-прогнозов времени, рисков и выбросов, и периодическая «точная» переоценка на подмножестве лучших решений. Для контроля смещения между уровнями отслеживались:

$$b = E[\hat{J} - J] \quad \text{RMSE} = \sqrt{E(\hat{J} - J)^2}.$$

В устойчивом режиме калибровки (регулярная переоценка части элиты и контроль частоты пересчётов) наблюдались малые $|b|$ и RMSE, достаточные, чтобы сохранять корректный ранжир популяции. Абляционные эксперименты подтвердили, что выключение

суррогата приводит к росту времени до целевого уровня качества и к «рваной» динамике улучшений; наоборот, чрезмерное снижение частоты калибровки ведёт к накоплению смещения и фиктивным улучшениям. Оптимальный баланс достигается при средней доле переоценки и адаптивном управлении вероятностями операторов – это сохраняет диверсификацию и предотвращает преждевременную стагнацию.

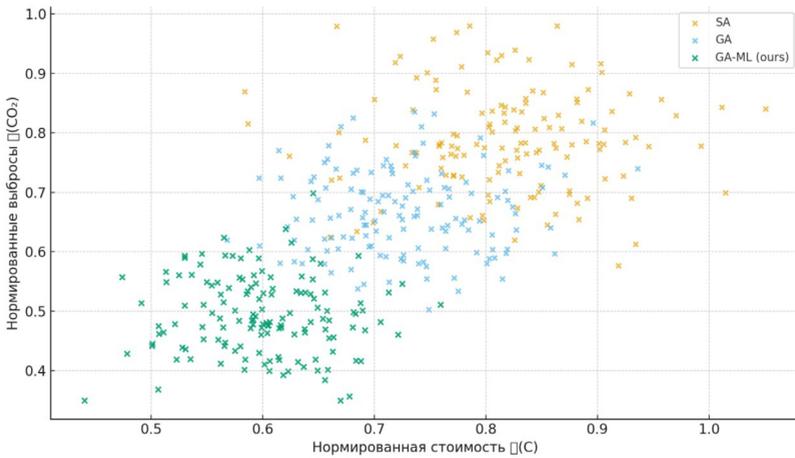


Рис. 2. Парето-фронт: стоимость vs выбросы CO₂

Устойчивость оценивалась как на «обычных» периодах, так и в стресс-сценариях (пиковый спрос, неблагоприятная погода, частичная недоступность узлов). Для каждого сценария вычислялась относительная деградация:

$$D = \frac{J_{stress} - J_{base}}{J_{base}},$$

и профиль D оказывался более пологим у GA-ML: гибрид сохранял приемлемые SLA-квантили (рис. 3) и экологические ограничения при умеренном росте стоимости за счёт раннего отсева решений, чувствительных к возмущениям (эту чувствительность

выявляли сами ML-прогнозы, встроенные в \hat{J}). Анализ чувствительности к параметрам α , β и весам w показывал предсказуемое поведение: ужесточение вероятностных ограничений смещало решения в сторону «безопасных и чистых», но рост J оставался умеренным; увеличение w_T приводило к плавному переходу к более быстрым расписаниям, w_E - к более экологичным, без разрывов фронта и резких скачков метрик.

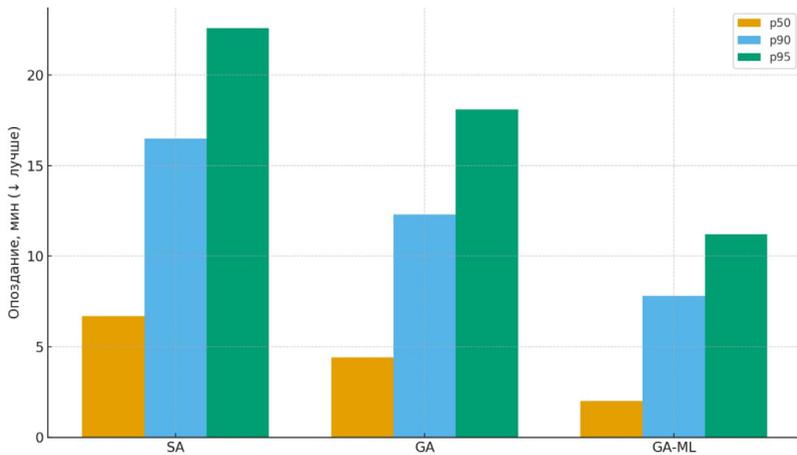


Рис. 3. Квантили опозданий SLA

Сопоставление с базовыми линиями уточнило области применимости альтернатив. Релаксированные постановки линейного/целочисленного программирования быстро давали ориентиры по стоимости/времени на упрощённой физике процесса, но проигрывали при учёте вероятностных ограничений и нелинейных штрафов. Имитация отжига была конкурентоспособной в низко-размерных конфигурациях, однако в многокритериальной стохастической среде чаще застревала в локальных компромиссах. На этом фоне гибридный GA-ML демонстрировал не только лучшие средние значения, но и меньшую дисперсию результатов, что важно для операционной предсказуемости.

Практический эффект выражается в снижении доли нарушений SLA, контроле выбросов и рисков при управляемых издержках и приемлемом времени отклика. Веса (w_C , w_T , w_E , w_R , w_S) интерпретируемы и настраиваемы под сезон, спрос и регуляторные требования, а вероятностные пороги α , β позволяют официально оформлять «уровни сервиса» и «уровни экологической надёжности». Переносимость подтверждена экспериментами на смещённых по времени выборках: краткое дообучение ML-компонент восстанавливает ранее достигнутые уровни J , SLA и CO_2 без изменения эволюционного контура. В совокупности результаты показывают, что интеграция предиктивных моделей в контур генетической оптимизации ускоряет сходимость, улучшает компромисс «стоимость-время-экология-риск», повышает устойчивость к стресс-возмущениям и снижает потребность в «дорогих» пересчётах – тем самым делая методику практически применимой для регулярного планирования перевозок в условиях неопределённости (рис. 4).

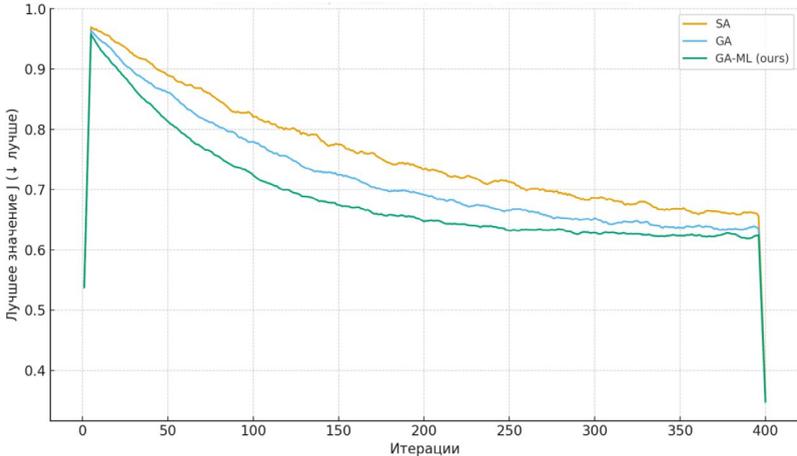


Рис. 4. Сходимость: лучшее J по итерациям

Заключение

Практическая ценность предложенной методики проявляется не столько в самом факте улучшения метрик, сколько в управляе-

мости компромиссов и предсказуемости поведения системы при смене политики сервиса и ограничений. Во-первых, методика даёт операторам прозрачный «рычаг» настройки приоритетов: веса $w = (w_C, w_T, w_E, w_R, w_S)$ можно калибровать от целевых уровней КРП через простое правило предельной замены – увеличивать w_T до тех пор, пока предельное снижение медианного опоздания перестанет превышать предельный рост нормированных издержек, и аналогично для w_E по отношению к удельному снижению $N(CO_2)$. Такой подход обеспечивает монотонный и безразрывный сдвиг вдоль Парето-фронта без перебора конфигураций. Во-вторых, вероятностные пороги служат удобными «договорными» параметрами с бизнесом и регулятором: выбор α и β можно привязывать к классам сервиса (например, «Стандарт»: $1 - \alpha = 0,90$; «Премиум»: $1 - \alpha = 0,95$ и экологическим целям (например, $1 - \beta = 0,90$) под ESG-план). Это переводит сложную стохастическую оптимизацию в язык соглашений SLA/ESG, понятный стейкхолдерам.

С точки зрения внедрения критичны три операционных правила. Первое - гигиена данных: стабильность суррогата \hat{J} держится на своевременном обновлении прогнозов; практически фиксировать период переобучения по скользящему окну не реже раз в 1–2 недели в пиковые сезоны и раз в 4–6 недель в «плоские» периоды, с автоматическим алертом при росте $RMSE(\hat{J}, J)$ выше заданного порога (например, 0,03 в нормированной шкале). Второе – бюджет вычислений: для планирования «день-вперёд» достаточно ограничить долю «дорогих» пересчётов до 20–30 % лучших особей на каждой k -й итерации; при оперативном перепланировании в течение дня разумно снижать эту долю до 10–15 % и временно усиливать штраф $S(\pi)$, чтобы жёстче удерживать окна. Третье – поддержание разнообразия: мониторинг индекса разнообразия генома (например, доля уникальных блоков маршрутов) позволяет вовремя переключать вероятности операторов и избежать преждевременной стагнации без увеличения размера популяции.

Ограничения и зона ответственности. Метод чувствителен к систематическим смещениям в исходных источниках (некорректная

телематика, неучтённые очереди на терминалах, редкие экстремальные события). Для редких тяжёлых событий полезно встраивать стратифицированные сценарии с явной «перегрузкой» хвостов распределений и задавать мягкий барьер в целевой функции: добавлять к $J(\pi)$ регуляризатор $+\lambda E[\max(0, R(\pi; \xi) - r_*)]$ с малой λ , чтобы обучать популяцию «бояться» зон повышенного риска даже при малой частоте наблюдений. Не рекомендуется применять схему «как есть» в задачах с жёсткими нелинейными зависимостями ресурсов и дискретной логикой (например, строгие смены/перерывы, сложные составные нормативы безопасности), пока эти ограничения не вынесены в ремонтёр или не учтены отдельным слоем проверок.

Управленческие выводы и эффект для процесса. Методика упрощает «разговор» между планированием, эксплуатацией и устойчивым развитием: целевые KPI переводятся в (w, α, β) , а итоговые решения – в наглядные срезы Парето, где цена любого изменения политики видна в единицах, понятных бизнесу (пункты доли нарушений, минуты р95, нормированная CO_2 , рубли/км). Это снижает конфликт целей между подразделениями и позволяет внедрять ритм оперативных корректировок без переработки кода оптимизатора. Для оценки эффекта внедрения на пилоте достаточно трёх недель сплит-планирования «А/Б»: в чётные дни – базовый процесс, в нечётные – GA-ML с фиксированными (w, α, β) ; минимальный набор KPI – медиана и р95 опозданий, нормированная CO_2 , доля «дорогих» пересчётов, совокупная стоимость и число внештатных перебоев.

Дальнейшая работа должна сфокусироваться на трёх направлениях:

- 1) обогащение экологической компоненты до TTW/WTW-метрики с температурными и грузовыми поправками;
- 2) расширение риск-модели до каскадных и пространственно-временных зависимостей (например, через графовые процессы и редкие экстремумы);

3) распределённая/поточковая реализация GA-ML с ограничением латентности до минутного уровня для применения в внутрисуточном перепланировании. В совокупности это превращает предложенную схему из «исследовательского» решения в промышленную технологию принятия решений, способную поддерживать целевые уровни сервиса и экологической ответственности в условиях меняющейся внешней среды.

Список литературы / References

1. Aarts, E. H. L., De Bont, F. M. J., Habers, J. H. A., & Van Laarhoven, P. J. M. (1986). A parallel statistical cooling algorithm. In *Proceeding of the 3rd Annual Symposium on Theoretical Aspects of Computer Science. Lecture Notes in Computer Science* (Vol. 210, pp. 87–97). [https://doi.org/10.1016/0167-9260\(86\)90002-7](https://doi.org/10.1016/0167-9260(86)90002-7)
2. Aly, A. H., & Peralta, R. C. (1999). Comparison of a genetic algorithm and mathematical programming to the design of groundwater cleanup systems. *Water Resources Research*, 35(8), 2415–2425. <https://doi.org/10.1029/1998WR900128>
3. Aytug, H., & Koehler, G. (2000). New stopping criterion for genetic algorithms. *European Journal of Operational Research*, 126(3), 662–674. [https://doi.org/10.1016/S0377-2217\(99\)00321-5](https://doi.org/10.1016/S0377-2217(99)00321-5). EDN: <https://elibrary.ru/AIIMMT>
4. Borzenkov, A. M., Ostroukh, A. V., Pronin, C. B., Podberezkin, A. A., & Kuftinova, N. G. (2024). Multi-criteria analysis of genetic algorithm applications in transportation logistics. In *2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)* (pp. 1–4). Moscow, Russian Federation. <https://doi.org/10.1109/TIRVED63561.2024.10769798>
5. Beasley, D., Bull, D. R., & Martin, R. R. (1993). An overview of genetic algorithms: Part 2, research topics. *University Computing*, 15, 56–69. Retrieved from: <https://orca.cardiff.ac.uk/id/eprint/64436>
6. Bonomi, E., & Lutton, J. L. (1984). The N-city travelling salesman problem, statistical mechanics and the Metropolis algorithm. *SIAM*

- Review*, 26(4), 551–568. Retrieved from: <https://www.jstor.org/stable/2030978>
7. Chambers, L. (2000). *Practical handbook of genetic algorithms: Applications* (2nd ed.). New York: CRC Press, 544 pp. <https://doi.org/10.1201/9781420035568>
 8. Casotto, A., Romeo, F., & Sangiovanni-Vincentelli, A. (1987). A parallel simulated annealing algorithm for the placement of macro-cells. *IEEE Transactions on C.A.D., CAD-6*(5), 838–847. <https://doi.org/10.1109/TCAD.1987.1270327>
 9. Goldberg, D. E. (1989). *Genetic algorithms in search, optimization and machine learning*. Massachusetts: Addison-Wesley. <https://doi.org/10.5555/534133>
 10. Gen, M., & Cheng, R. (2000). *Genetic algorithms and engineering optimization*. New York: John Wiley. <https://doi.org/10.1002/9780470172261>
 11. Guo, K., Yang, M., & Zhu, H. (2019). Application research of improved genetic algorithm based on machine learning in production scheduling. In *Neural Computing and Applications* (pp. 1–12). London, UK: Springer. <https://doi.org/10.1007/s00521-019-04571-5>. EDN: <https://elibrary.ru/FKEARJ>
 12. Hong, T. P., & Hong-Shung, W. (1996). A dynamic mutation genetic algorithm. In *1996 IEEE International Conference on Systems, Man and Cybernetics. Information Intelligence and Systems* (Vol. 3, pp. 2000–2005). <https://doi.org/10.1109/ICSMC.1996.565436>
 13. Kiselev, S. A., Podberезkin, A. A., Borzenkov, A. M., Ostroukh, A. V., & Pronin, C. B. (2025). Dynamic pricing in air cargo: Machine learning and genetic algorithm-based optimization. In *2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)* (pp. 1–5). St. Petersburg, Russian Federation. <https://doi.org/10.1109/WECONF65186.2025.11017136>. EDN: <https://elibrary.ru/UUQQVD>
 14. Ostroukh, A. V., Kuftinova, N. G., Pronin, C. B., Ivanov, A. M., & Silakov, A. V. (2024). Implementing suburban transport demand planning with metaverse and digital twin models. In *2024 Systems of Signals*

- Generating and Processing in the Field of on Board Communications* (pp. 1–5). Moscow, Russian Federation. <https://doi.org/10.1109/IEEECONF60226.2024.10496746>. EDN: <https://elibrary.ru/YPGYRW>
15. Ruilian, Z., & Shanshan, L. V. (2007). Neural network based test cases generation using genetic algorithm. In *13th IEEE International Symposium on Pacific Rim Dependable Computing* (pp. 97–100). IEEE. <https://doi.org/10.1109/PRDC.2007.50>
16. Wang, Y. M., & Yin, H. L. (2018). Cost-optimization problem with a soft time window based on an improved fuzzy genetic algorithm for fresh food distribution. *Mathematical Problems in Engineering*, 1–16. <https://doi.org/10.1155/2018/5743287>

ДАННЫЕ ОБ АВТОРАХ

Борзенков Александр Михайлович, студент, магистрант кафедры «Автоматизированные системы управления»
ФГБОУ ВО Московский автомобильно-дорожный государственный технический университет
Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация
borzenkov03h@mail.ru

Пронин Цезарь Борисович, старший преподаватель кафедры «Автоматизированные системы управления»
ФГБОУ ВО Московский автомобильно-дорожный государственный технический университет
Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация
caesarpr12@gmail.com

Подберёзкин Александр Александрович, старший преподаватель кафедры «Автоматизированные системы управления»
ФГБОУ ВО Московский автомобильно-дорожный государственный технический университет

Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация
a.podberezkin@gmail.com

Остроух Андрей Владимирович, доктор технических наук, профессор, профессор кафедры «Автоматизированные системы управления»
ФГБОУ ВО Московский автомобильно-дорожный государственный технический университет
Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация
ostroukh@mail.ru

Шмонин Артём Михайлович, студент кафедры «Автоматизированные системы управления»
ФГБОУ ВО Московский автомобильно-дорожный государственный технический университет
Ленинградский проспект, 64, г. Москва, 125319, Российская Федерация
shmoninam@mail.ru

DATA ABOUT THE AUTHORS

Aleksandr M. Borzenkov, Student of the Department of Automated Control Systems
Moscow Automobile and Road Construction State Technical University
64, Leningradsky Ave., Moscow, 125319, Russian Federation
borzenkov03h@mail.ru

Cezar B. Pronin, Senior Lecturer of the Department of Automated Control Systems
Moscow Automobile and Road Construction State Technical University

*64, Leningradsky Ave., Moscow, 125319, Russian Federation
caesarpr12@gmail.com*

Aleksandr A. Podberezkin, Senior Lecturer of the Department of Automated Control Systems
*Moscow Automobile and Road Construction State Technical University
64, Leningradsky Ave., Moscow, 125319, Russian Federation
a.podberezkin@gmail.com*

Andrey V. Ostroukh, Doctor of Technical Sciences, Professor, Professor of the Department of Automated Control Systems
*Moscow Automobile and Road Construction State Technical University
64, Leningradsky Ave., Moscow, 125319, Russian Federation
ostroukh@mail.ru*

Artyom M. Shmonin, Student of the Department of Automated Control Systems
*Moscow Automobile and Road Construction State Technical University
64, Leningradsky Ave., Moscow, 125319, Russian Federation
shmoninam@mail.ru*

Поступила 10.09.2025
После рецензирования 22.09.2025
Принята 05.10.2025

Received 10.09.2025
Revised 22.09.2025
Accepted 05.10.2025