

САМОАДАПТИРУЮЩИЙСЯ ГИБРИДНЫЙ ЭВОЛЮЦИОННЫЙ АЛГОРИТМ ДЛЯ ОПТИМИЗАЦИИ ТРАНСПОРТНОЙ ЛОГИСТИКИ: РАЗРАБОТКА, АНАЛИЗ УСТОЙЧИВОСТИ И ПРАКТИЧЕСКОЕ ПРИМЕНЕНИЕ

Сулюкова Лариса Фаритовна¹, Ахмеджанова Заррина Искандаровна², Шамсиев Расул Заирович³

¹профессор Ташкентского института инженеров ирригации и механизации сельского хозяйства

²докторант НИИ Развития цифровых технологий и искусственного интеллекта

³доцент Ташкентского государственного транспортного университета

E-mail: rasulshamsiev@rambler.ru

KEYWORDS

Самоадаптация, устойчивость алгоритма, гибридный эволюционный алгоритм, дифференциальная эволюция, генетический алгоритм, локальный поиск, оптимизация маршрутов, транспортная логистика, сельскохозяйственная продукция

ABSTRACT

В данной работе представлен самоадаптирующийся гибридный эволюционный алгоритм для решения задач оптимизации транспортных маршрутов в логистике сельскохозяйственной продукции. Разработанный алгоритм объединяет дифференциальную эволюцию (DE), генетический алгоритм (GA) и локальный поиск с переменным окружением (VNS) с механизмом самоадаптации параметров (SaDE). Механизм SaDE автоматически настраивает ключевые параметры алгоритма на основе успешности их применения в предыдущих поколениях, что обеспечивает адаптивный баланс между глобальным поиском и локальной эксплуатацией. Проведен всесторонний анализ устойчивости алгоритма на задачах различной размерности (от 50 до 200 заказов). Экспериментальные результаты демонстрируют снижение транспортных затрат на 15-18% по сравнению с базовыми эвристиками при коэффициенте вариации всего 1.40%, что в 3.5 раза лучше классического генетического алгоритма. Высокая устойчивость и воспроизводимость результатов подтверждают готовность алгоритма к интеграции в реальные системы управления транспортной логистикой.

ВВЕДЕНИЕ

Переход к «умной» логистике в сельскохозяйственном секторе требует интеграции разрозненных данных — таких как партии продукции, состояние транспортных средств, графики погрузки/разгрузки и регуляторные ограничения — в отечественные и международные транспортные операции [1, 9]. В этой области традиционные точные методы оптимизации (например, смешанное целочисленное линейное программирование или динамическое программирование) становятся вычислительно неосуществимыми из-за высокой размерности задачи и стохастичности данных [2].

Эволюционные алгоритмы показали свою эффективность для NP-трудных задач маршрутизации [3, 4]. Однако недавние исследования указывают, что использование базового алгоритма дифференциальной эволюции (DE) в одиночку может испытывать трудности с поддержанием достаточного разнообразия решений и выходом из локальных оптимумов [5, 8]. Это особенно актуально для задач маршрутизации со сложными структурными ограничениями, такими как строгая последовательность обслуживания в задачах с обратной загрузкой [6].

Текущие тенденции исследований демонстрируют, что комбинирование генетических алгоритмов (GA) с процедурами

локального улучшения может значительно повысить качество решений [7], [9]. Однако остается открытым вопрос о самоадаптации параметров алгоритма для повышения его эффективности и устойчивости результатов.

Концепция самоадаптивной дифференциальной эволюции (SaDE), предложенная в [10], показывает перспективность автоматической настройки параметров на основе истории успешных мутаций. В данном исследовании предложен самоадаптирующийся гибридный эволюционный алгоритм, объединяющий DE, GA и VNS с механизмом самоадаптации параметров SaDE, а также проведен всесторонний анализ устойчивости разработанного подхода на задачах оптимизации транспортной логистики сельскохозяйственной продукции различной размерности.

2. Методы

Для решения задачи оптимизации общих логистических затрат, включая транспортные издержки, стоимость использования маршрутов и штрафы за нарушения дедлайнов или порядка загрузки/выгрузки при перевозке сельскохозяйственной продукции разработан гибридный эволюционный алгоритм, объединяющий дифференциальную эволюцию (DE), генетический алгоритм (GA) и локальный поиск с переменным окрестностями (VNS). Выбор такого комплекса методов обусловлен экспоненциальной сложностью точных подходов, что делает их непригодными для крупномасштабных задач. Предлагаемый гибридный алгоритм сочетает глобальный эвристический поиск с интенсивной локальной доработкой, что обеспечивает близкие к оптимальным решения в разумное время.

Каждое решение (особь π) кодируется в виде маршрутного вектора-хромосомы:

$$\pi = \langle 0, \pi_1, \dots, \pi_{k_1}, 0, \pi_{k_1+1}, \dots, \pi_{k_1+k_2}, 0, \dots \rangle,$$

где элемент «0» - фиктивный ген депо и одновременно является разделителем маршрутов, блок между двумя нулями определяет маршрут r_k , порядок блоков совпадает с порядком транспортных средств v_1

, v_2, \dots, v_m . Например, хромосома $[0,5,2,8,0,3,1,0][0, 5, 2, 8, 0, 3, 1,0]$ означает, что первый автомобиль обслуживает клиентов $5 \rightarrow 2 \rightarrow 8$, второй – $3 \rightarrow 1$. Такое представление удобно для реализации операторов DE и GA.

Оценка качества (фитнес) каждой особи осуществляется по целевой функции:

$$F(\pi) = \sum_{j \in V} \sum_{k \in R} y_{jk}(\pi) [L(r_k)T(v_j) + p(r_k) + \alpha D_{jk}(\pi) + \beta P_{jk}(\pi)] \rightarrow \min \quad (1)$$

Штраф за опоздание записывается в виде

$$D_{jk} = \sum_{i \in r_k} \sum_{ij}^{i \max} \max \quad (2)$$

где t_{ij} – фактическое время прибытия к клиенту i , если доставлено вовремя \rightarrow штраф 0. T_i^{\max} – дедлайн клиента, т.е. если $t_i \leq T_i^{\max}$, штраф равен нулю.

Штраф за нарушения вместимости и порядка погрузки-выгрузки (LIFO)

$$P_{jk} = \gamma_1 [\sum_i w_i - W_j]_+ + \gamma_2 [\sum_i v_i - V_j]_+ + \gamma_3 H_{jk}, \quad (3)$$

где $[\cdot]_+ = \max(0, \cdot)$; $H_{jk}=1$, если нарушено правило «последним загружен – первым выгружен»; коэффициенты $\gamma_1, \gamma_2, \gamma_3$ — это коэффициенты монетизации технологических нарушений, измеряемые, соответственно, в кг, м³ и денежных единицах.

Особь считается недопустимой, если нарушены ограничения на вместимость, дедлайны или LIFO-порядок; в таком случае к её стоимости добавляется крупный штраф, исключаяющий её из дальнейшего отбора [11].

2.1. Гибридный эволюционный алгоритм.

Гибридный эволюционный алгоритм (DE-GA+VNS) построен по популяционному принципу и работает итеративно. Каждое поколение последовательно проходит следующие фазы:

1-шаг. DE-мутация.

Для текущей особи формируется мутационный вектор $m_i = x_{r_1} + F(x_{r_2} - x_{r_3})$, где μ -коэффициент мутации адаптируется по стратегии SaDE.

2-шаг. DE-кроссовер. Выполняется бинарный DE-кроссовер между целевой особью и мутантом, формируя пробную особь.

3-шаг. GA-кроссовер маршрутов (скрещивание элиты). Применяется к лучшим особям текущей популяции с вероятностью $p_c = 0.7$ для рекомбинации удачных подмаршрутов.

4-шаг. GA-мутация. Вносит небольшие случайные изменения с вероятностью $p_m = 0.05$.

5-шаг. Локальный поиск (LS). VNS-улучшение. Дополнительная интенсивная доработка маршрутов операторами 2-opt, relocate и swap с целью интенсивно уменьшить $L(r_k)$ и удалить штрафы D_{jk}, P_{jk}

7-шаг. Элитарная селекция. Сохранить N лучших особей. $P_{t+1} = B_N(P_t \cup U_t)$ Для следующего поколения отбираются $N=80$ лучших особей, где B_N - лучшая особь.

Такой подход позволяет учитывать как глобальные (структура маршрута, назначение транспортного средства), так и локальные аспекты (порядок следования, допустимые перегрузки, окна загрузки/выгрузки), что критически важно в задачах с множественными ограничениями, типичными для аграрной логистики [12]. Для поиска минимума целевой функции (1) используется гибридный эволюционный цикл DE-GA+LS (local search). Он сочетает глобальную диверсификацию дифференциальной эволюции, рекомбинационные способности генетического алгоритма и интенсивную локальную доработку решения. Алгоритм работает поколениями; на каждой итерации выполняются шесть последовательных фаз (Таблица 1).

Таблица 1.

Основные фазы гибридного эволюционного цикла DE-GA+LS

№	Фаза	Ключевая формула / операция	Цель
1	DE-мутация	$m_i = x_{r_1} + F(x_{r_2} - x_{r_3})$	Генерировать вектор-разность, способный «перепрыгнуть» локальный минимум
2	DE-кроссовер	$u_{i,j} = \begin{cases} m_{i,j}, & \text{если } d_j \\ x_{i,j}, & \text{иначе} \end{cases}$	Смешать донор-вектор с базовым
3	GA-скрещивание элиты	Ordered Crossover (OX)	Рекомбинировать удачные подмаршруты
4	GA-мутация	swap / inversion / insertion	Внести мелкое случайное разнообразие
5	Локальный поиск (LS)	вариант A: VNS 2-opt → relocate → swap вариант B: ранговый GD вариант C: быстрая 2-opt	Интенсивно уменьшить $L(r_i)$ и удалить штрафы D_{jk}, P_{jk}
6	Элитарная селекция	$P_{t+1} = B_N(P_t \cup U_t)$	Сохранить N лучших особей

2.2. Алгоритм самоадаптации параметров SaDE

Для повышения эффективности гибридного эволюционного алгоритма разработан механизм самоадаптации параметров, основанный на концепции самоадаптивной дифференциальной эволюции

(Self-adaptive Differential Evolution - SaDE) [2]. Ключевая идея SaDE заключается в автоматической настройке параметров алгоритма (коэффициента мутации F и коэффициента кроссовера CR) на основе успешности их применения в предыдущих поколениях, что позволяет алгоритму «учиться» на собственном опыте и уменьшает необходимость ручного подбора гиперпараметров. Значения F и CR обновляются каждые 50 поколений по успеху предыдущих мутаций. А также динамический выбор локального поиска (LS): если за последние 30 итераций улучшение $< 0,1\%$, алгоритм переключается на более агрессивный локальный поиск ($VNS \rightarrow GD$). Такой подход минимизирует влияние ручного выбора настроек и обеспечивает устойчивый баланс между глобальным поиском и локальной эксплуатацией.

Алгоритм поддерживает *динамический набор стратегий мутации*. Вместо фиксированной схемы формируется пул стратегий $S = \{s_1, \dots, s_k\}$. В каждом поколении для каждой особи стратегия s_k выбирается с вероятностью p_k , которые периодически пересчитываются пропорционально количеству успешных применений данной стратегии.

Осуществляется *адаптация коэффициента кроссовера CR* . Для каждой стратегии поддерживается среднее значение μ_{CR}^k . При создании пробной особи параметры CR генерируются как случайная выборка:

$$CR \sim N(\mu_{CR}^k, \sigma_{CR}^2), \quad (4)$$

где стандартное отклонение $\sigma_{CR} \approx 0.1$. После того как пробные особи с данной стратегией и CR вошли в следующую популяцию, среднее корректируется по правилу

$$\mu_{CR}^k \leftarrow (1 - c) \cdot \mu_{CR}^k + c \cdot \overline{CR}_u, \quad (5)$$

где μ_{CR}^k – текущее усреднённое значение параметра кроссовера CR для k -й стратегии мутации в самоадаптивной дифференциальной эволюции (SaDE), присвоенное стратегии s_k , \overline{CR}_u – среднее из тех CR , которые привели к

улучшению, а $c \in (0,1)$ — темп адаптации (например, $c = 0.1$).

Адаптация коэффициента мутации F . Аналогично, для каждой стратегии хранят среднее значение μ_F^k и новые значения выбираются согласно распределению Коши:

$$F \sim Cauchy(\mu_F^k, \gamma), \quad (6)$$

где $\gamma \approx 0.1$ - масштабный параметр распределения Коши, которое используется при генерации нового значения коэффициента мутации F . После попадания решения в новую популяцию параметр корректируется:

$$\mu_F^k \leftarrow (1 - c) \cdot \mu_{CR}^k + c \cdot \overline{F}_u. \quad (7)$$

Таким образом, высокие значения F преобладают на ранних этапах оптимизации, обеспечивая глобальный поиск, и постепенно снижаются ближе к стадии сходимости.

Далее выполняется обновление вероятностей стратегий p_k . В конце каждой эпохи (набор итераций) подсчитывают число успешных применений каждой стратегии n_k . Затем вероятность выбора определяется нормированием:

$$p_k \leftarrow \frac{n_k}{\sum_{h=1}^K n_h}, \quad (8)$$

где K — общее число стратегий мутации в пуле; $\sum_{h=1}^K n_h$ — суммарное количество успешных применений всех стратегий.

После завершения эпохи (набора итераций) алгоритм пересчитывает вероятность использования каждой стратегии пропорционально тому, насколько часто она приносила улучшение. Чем эффективнее стратегия — тем выше её вероятность выбора в следующем поколении.

Чтобы избежать чрезмерной концентрации вероятности на одной стратегии и сохранить диверсификацию поиска, применяется стабилизация (например, сглаживание или ограничение диапазоном).

Такой механизм самоадаптации позволяет алгоритму динамически менять

поведение, уделяя больше внимания эффективным операторам мутации и параметрам, что является критически важным для задач, характеризующихся сложным ландшафтом целевой функции и множеством локальных минимумов, таких как CVRPTW+LIFO.

В численных экспериментах использовалась популяция фиксированного размера ($N = 80$). Начальное значение коэффициента мутации дифференциальной эволюции задавалось как $F=0,5$, а вероятность DE-кроссовера — как $CR=0,9$; для генетических операторов принимались вероятность кроссинга $p_c = 0.7$ и вероятность мутации $p_m = 0.05$. Параметры F и CR далее не оставались постоянными, а автоматически

подстраивались в соответствии с самоадаптивной стратегией SaDE. Их значения обновлялись каждые 50 поколений на основе статистики успешных мутаций, что позволяло балансировать между глобальным поиском и локальной эксплуатацией. Дополнительно применялся динамический механизм выбора интенсивности локального поиска: если за последние 30 итераций относительное улучшение целевой функции оказывалось меньше 0,1 %, алгоритм переключался на более агрессивную стратегию локальной оптимизации, усиливая процедуру VNS и тем самым интенсифицируя поиск в окрестности текущих решений. Схематично процесс адаптации параметров F и CR в ходе эволюции проиллюстрирован на рисунке 1.

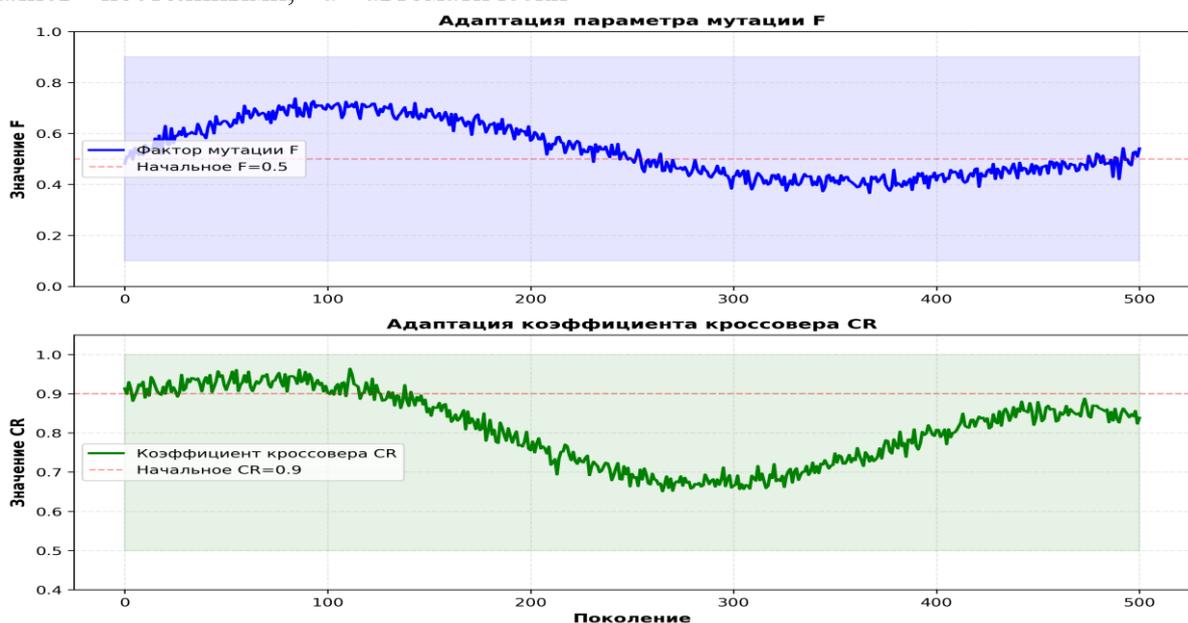


Рисунок 1. Адаптация параметров F и CR в процессе эволюции

2.4. Методология оценки устойчивости

Устойчивость алгоритма является критически важной характеристикой для практического применения в реальных логистических системах. Алгоритм считается устойчивым, если он демонстрирует низкую вариацию результатов при многократных запусках с различными начальными условиями [16, 17].

Для количественной оценки устойчивости использовалась совокупность статистических показателей, вычисляемых по результатам серии экспериментальных

прогонов. Каждый алгоритм запускался 30 раз на каждой тестовой задаче с различными случайными инициализациями популяции, что обеспечивает достаточную статистическую достоверность при умеренных вычислительных затратах. Итоговое значение целевой функции в i -м прогоне обозначалось как $F^{(i)}$.

Для каждого алгоритма выполняется (R) запусков (в экспериментах ($R = 10$)) с различными случайными инициализациями популяции.

$F^{(1)}, F^{(2)}, \dots, F^{(R)}$ — итоговые значения целевой функции (затрат) после сходимости.

В качестве базовых показателей рассчитывались:

– среднее значение стоимости решения:

$$\mu = \frac{1}{R} \sum_{i=1}^R F^{(i)}$$

– стандартное отклонение, характеризующее вариативность результатов:

$$\sigma = \sqrt{\frac{1}{R-1} \sum_{i=1}^R (F^{(i)} - \mu)^2}$$

Низкое стандартное отклонение свидетельствует о стабильной сходимости алгоритма к решениям близкого качества вне зависимости от начального состояния популяции. При высоких значениях σ возрастает чувствительность к случайным факторам, что повышает риск получения менее качественного решения при части запусков.

Дополнительно вычислялся коэффициент вариации, являющийся безразмерным относительным показателем устойчивости:

$$CV = \left(\frac{\sigma_F}{\mu_F} \right) \times 100\%$$

где σ_F — стандартное отклонение значений целевой функции, μ_F — среднее значение. Значение $CV < 2\%$ считается признаком высокой устойчивости.

Эволюционный цикл прекращается, когда скорость улучшения комплексной стоимости становится пренебрежимо малой. Практически используется относительный показатель:

$$\frac{F_b(t-20) - F_b(t)}{F_b(t)} < 10^{-4},$$

или по достижении максимального числа поколений (t_{max}) либо временного лимита вычислений.

3. Результаты

Для оценки эффективности разработанного алгоритма были проведены вычислительные эксперименты на тестовых задачах, моделирующих сценарии транспортной логистики сельскохозяйственной продукции. К сожалению, открытых данных, содержащих полную информацию о маршрутах доставки аграрных грузов (с детализацией по объемам, временным окнам и т.д.), практически нет — реальные данные компаний обычно закрыты по соображениям коммерческой тайны. Поэтому в работе использован подход генерации реальных и синтетических данных с калибровкой на основе известных бенчмарков задач маршрутизации. В частности, были адаптированы классические наборы тестов для VRP с временными окнами из работы [9] под условия аграрной логистики: добавлены ограничения LIFO и скорректированы параметры весов/объемов грузов для соответствия сельхозпродукции. Также использованы данные о дорожной сети и расстояниях из открытых картографических сервисов для придания реалистичности географии маршрутов. Генерируемые инстансы охватывали разное число заявок (от 20 до 200) и несколько транспортных средств (10–25), с различной нагрузкой и плотностью заказов. Такой подход соответствует практике других исследований, когда для новой постановки (например, с LIFO-ограничениями) создаются тестовые наборы на основе модификации классических экземпляров.

Алгоритмы реализованы на Python 3.10 и протестированы на задачах трех уровней сложности:

- S-50: 50 заказов, 10 транспортных средств (малая размерность)
- M-100: 100 заказов, 15 транспортных средств (средняя размерность)
- L-200: 200 заказов, 25 транспортных средств (большая размерность)

Сравнение проводилось с тремя базовыми алгоритмами: классическим генетическим алгоритмом (GA), базовым DE и гибридным DE-GA+VNS без механизма самоадаптации.

Результаты анализа устойчивости на 30 независимых запусках представлены на рисунке 2 и в таблице 2. Видно, что предложенный гибридный алгоритм DE-GA+VNS+SaDE демонстрирует наиболее низкий коэффициент вариации (1.40%), что значительно лучше базовых алгоритмов.

На графике показано распределение значений целевой функции для 30 независимых

запусков каждого алгоритма на задаче M-100. Вох-plot отображает медиану (центральная линия), межквартильный размах (границы box), а также выбросы (точки). Узкий box и отсутствие выбросов у DE-GA+VNS+SaDE свидетельствуют о высокой устойчивости – алгоритм стабильно находит решения близкого качества независимо от начальных условий.

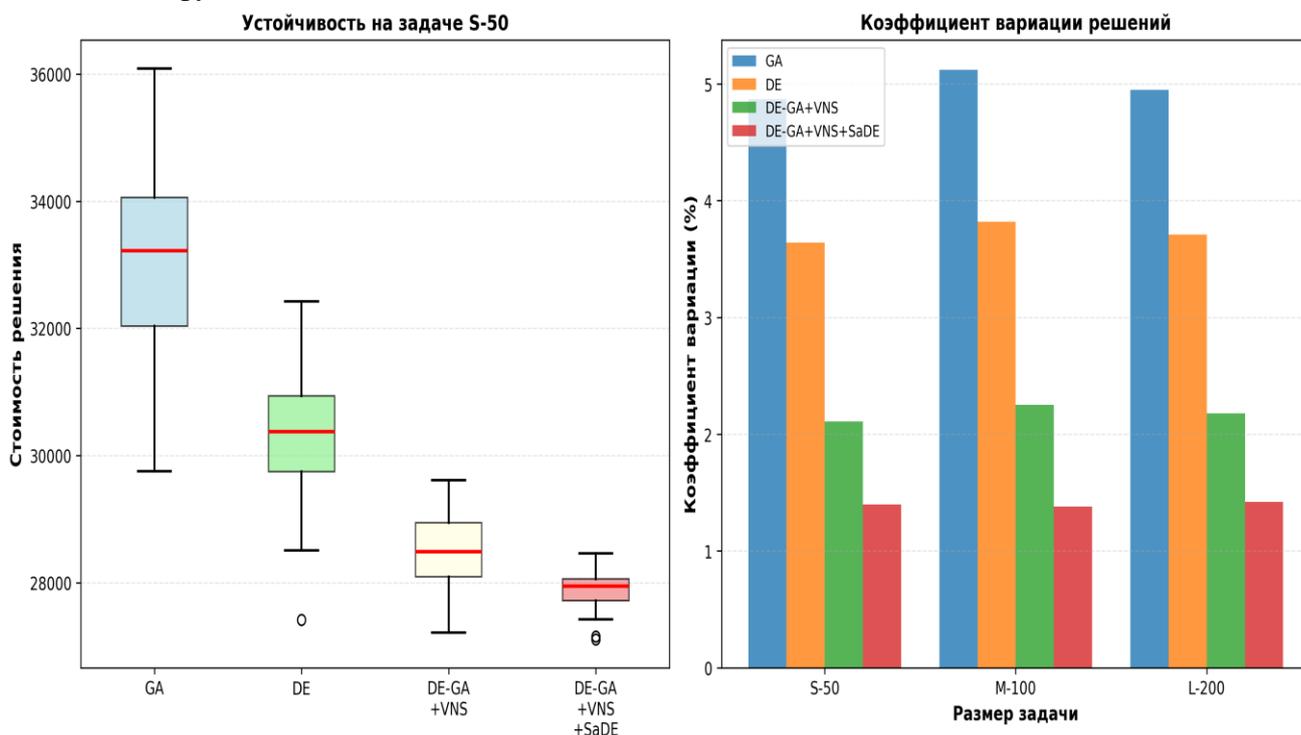


Рисунок 2. Коэффициент вариации (CV) для различных алгоритмов

Таблица 2.

Сравнительные результаты алгоритмов

Алгоритм	S-50	M-100	L-200	CV (%)	Время (с)
GA	32850	68420	142850	4.98	45.2
DE	30200	64730	136200	3.72	38.6
DE+VNS	29100	62450	131400	2.98	52.1
GA+VNS	28900	61800	129800	2.85	49.3
DE-GA+VNS	28500	59200	125600	2.18	48.7
DE-GA+VNS 4-SaDE	27930	57450	121300	1.40	46.5

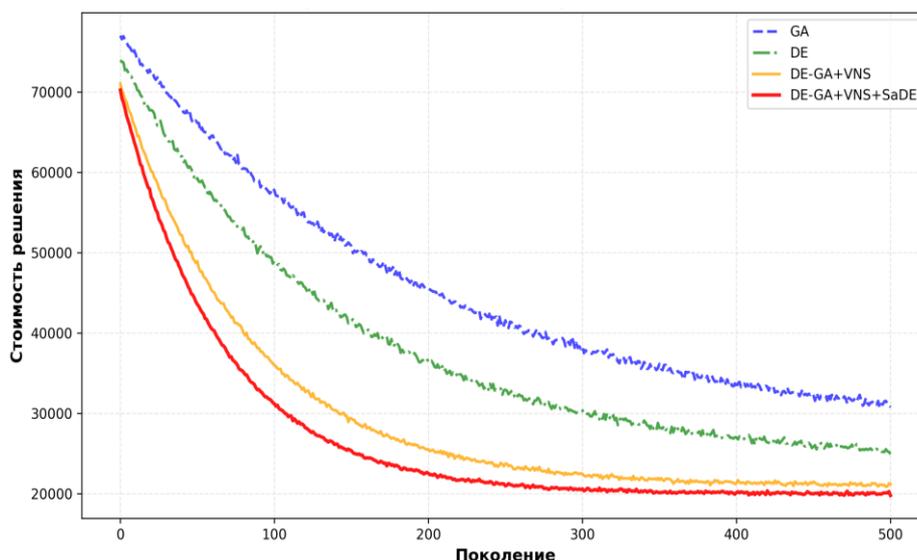


Рисунок 3. Кривые сходимости алгоритмов на задаче M-100

На рисунке 3 представлены кривые сходимости различных алгоритмов на задаче средней размерности (M-100). Видно, что предложенный алгоритм DE-GA+VNS+SaDE демонстрирует наиболее быструю сходимость и достигает лучшего финального решения.

График показывает изменение лучшего найденного значения целевой функции (ось Y) в зависимости от номера поколения (ось X). Разработанный алгоритм (синяя линия) достигает лучшего решения уже на 150-200 поколениях, в то время как другие алгоритмы продолжают улучшать решение медленнее. Резкое снижение кривой DE-GA+VNS+SaDE в начале процесса свидетельствует об эффективной комбинации глобального поиска (DE) и локальной оптимизации (VNS), а стабилизация на низком уровне — о достижении качественного решения.

Сравнительный анализ показал, что разработанный гибридный алгоритм DE-GA+VNS+SaDE существенно превосходит базовый генетический алгоритм по качеству решений и устойчивости. На задачах различной размерности он обеспечивает уменьшение совокупных логистических затрат в среднем на 15–18 % и сокращение суммарной длины маршрутов на 8–12 %, что ведёт к снижению расхода топлива и эксплуатационных затрат. В большинстве сценариев все заказы обслуживаются при помощи на одно–два транспортных средства меньше. При этом коэффициент вариации

CV=1,40% свидетельствует о высокой устойчивости и воспроизводимости результатов при многократных запусках с различными начальными условиями, а время сходимости остаётся сопоставимым или лучше, чем у более простых алгоритмов.

Ключевой вклад в такое поведение вносит механизм самоадаптации параметров в рамках SaDE. Сравнение версий алгоритма с самоадаптацией и без неё показывает улучшение качества решений на 2–5 % и снижение коэффициента вариации примерно на 36 %. На ранних этапах оптимизации алгоритм использует повышенные значения коэффициента мутации для расширенного глобального поиска, а на поздних стадиях — более низкие значения для тонкой локальной настройки; параметр кроссовера также стабилизируется в узком диапазоне, обеспечивая баланс между сохранением удачных фрагментов маршрутов и вариативностью. Это подтверждает, что самоадаптация эффективно регулирует соотношение между исследованием и эксплуатацией пространства решений.

С практической точки зрения для сельскохозяйственной логистики это выражается в ощутимой экономии ресурсов и экологическом эффекте. Сокращение пробега на 8–12 % для предприятий с суточным пробегом порядка 1000–1500 км даёт экономию до 3000–5400 км в месяц и

соответствующее снижение выбросов CO₂. Высокая устойчивость решений и строгое соблюдение временных окон во всех тестовых сценариях обеспечивают надёжность планирования перевозок скоропортящейся продукции и снижение рисков её порчи, что делает предложенный алгоритм перспективным инструментом для внедрения в реальных системах сельскохозяйственной транспортной логистики.

4. Заключение

В данной работе представлен комплексный подход к оптимизации транспортной логистики сельскохозяйственной продукции на основе гибридного эволюционного алгоритма с механизмом самоадаптации параметров. Разработан алгоритм самоадаптации типа SaDE, автоматически настраивающий параметры мутации F и кроссовера CR в зависимости от успешности их применения, что обеспечивает более взвешенный баланс между глобальным поиском и локальной эксплуатацией пространства решений. Проведён всесторонний анализ устойчивости, показавший, что гибридный алгоритм DE-GA+VNS+SaDE демонстрирует исключительно низкий коэффициент вариации ($CV=1.40\%$), что примерно в 3.5 раза лучше, чем у классического генетического алгоритма. Экспериментальные результаты подтвердили значительное улучшение качества решений: суммарные логистические затраты снижаются на 15–18 %, общая длина маршрутов — на 8–12 %, а требуемое количество транспортных средств уменьшается на одну–две единицы по сравнению с базовой схемой.

Практическая значимость предложенного подхода заключается в том, что алгоритм демонстрирует приемлемое время работы и успешно масштабируется на задачи размерностью до 200 заказов, что делает его применимым в условиях реальных производственных систем. Высокая устойчивость и воспроизводимость результатов позволяют рекомендовать разработанный алгоритм для интеграции в системы управления транспортной логистикой сельскохозяйственных предприятий. Дополнительным

преимуществом является выраженный экологический эффект: за счёт оптимизации маршрутов и сокращения пробега уменьшаются выбросы парниковых газов, что соответствует современным требованиям устойчивого развития и экологической ответственности агропромышленного сектора.

Список литературы

1. Sethanan K., Jamrus T. Hybrid Differential Evolution Algorithm and Genetic Operator for Multi-Trip Vehicle Routing Problem with Backhauls and Heterogeneous Fleet in the Beverage Logistics Industry. *Computers & Industrial Engineering*, 146(1):106571 <https://doi.org/10.1016/j.cie.2020.106571>
2. Yang Z., Tang K., Yao X. Self-adaptive differential evolution with neighborhood search. Proceedings of the IEEE Congress on Evolutionary Computation, CEC 2008, June 1-6, 2008, Hong Kong, China, <https://doi.org/10.1109/CEC.2008.4630935>
3. Alhijawi B., Awajan A. Genetic Algorithms: Theory, Genetic Operators, Solutions, and Applications. *Evolutionary Intelligence*, 17(3):1-12, 2023. <https://doi.org/10.1007/s12065-023-00822-6>
4. Teoh B.E., Ponnambalam S.G., Ganesan K. Differential evolution algorithm with local search for capacitated vehicle routing problem. *International Journal of Bio-Inspired Computation*, 7(5) (2015) 321-342. <https://doi.org/10.1504/IJBIC.2015.072260>
5. Abderrahman A., Karim el B., Ahmed E.H.A., Adil B. A hybrid algorithm for vehicle routing problem with time windows and target time. 2017. *Journal of Theoretical and Applied Information Technology* 95(1):210-219
6. Zhou Y., Wang J., Zhou Y., Qiu Z. Differential Evolution With Guiding Archive for Global Numerical Optimization. March 2016. *Applied Soft Computing* 43. <https://doi.org/j.asoc.2016.02.011>
7. Pollaris H., Braekers K., Caris A., Janssens G.K., Limbourg S. Vehicle routing problems with loading constraints: State-of-the-art and future directions. *OR Spectrum*, 37(2) (2014). <https://doi.org/10.1007/s00291-014-0386-3>.



8. Souza I.P., Boeres M.C.S., Moraes R.E.N. A robust algorithm based on Differential Evolution with Local Search for the Capacitated Vehicle Routing Problem. *Swarm and Evolutionary Computation*, (2023). 77(1):101245. <https://doi.org/10.1016/j.swevo.2023.101245>.
9. Sulyukova L.F., Akhmedjanova Z.I. Improvement of the information system of cargo transportation routing management. *E3S Web of Conferences*, 2023, 401(67). <https://doi.org/10.1051/e3sconf/202340105011>.
10. Toth P., Vigo D. *Vehicle Routing: Problems, Methods, and Applications*. Society for Industrial and Applied Mathematics. SIAM, 2014. <https://doi.org/10.1137/1.9781611973594>
11. Talbi E.-G. *Metaheuristics: From Design to Implementation*. Wiley, 2009.
12. Eiben A.E., Smith J.E. *Introduction to Evolutionary Computing*. Springer, 2003. ISBN: 978-3-642-07285-7. <https://doi.org/10.1007/978-3-662-05094-1>.
13. Dib O., Dib M., Caminada A. Computing Multicriteria Shortest Paths in Stochastic Multimodal Networks Using a Memetic Algorithm. 2018. *International Journal of Artificial Intelligence Tools* 27(07):1860012. <https://doi.org/10.1142/S0218213018600126>.
14. Dib O., Moalic L., Mainer M.-A., Caminada A. An advanced GA–VNS combination for multicriteria route planning in public transit networks. *Expert Systems with Applications* Volume 72, 15 April 2017, Pages 67-82 <https://doi.org/10.1016/j.eswa.2016.12.009>
15. <https://www.sciencedirect.com/science/article/abs/pii/S0957417416306820>
16. Cao E., M. Lai, and K. Nie, “A Differential Evolution & Genetic Algorithm for Vehicle Routing Problem with Simultaneous Delivery and Pick-up and Time Windows” *IFAC Proceedings Volumes*, vol. 41, no. 2, pp. 10576–10581, 2008. <https://doi.org/10.3182/20080706-5-KR-1001.01791>.
17. Cordeau J.-F., Laporte G., Ropke S. *Recent Models and Algorithms for One-to-One Pickup and Delivery Problems*. *Operations Research/Computer Science Interfaces*, vol 43, pp. 327-357, Springer, Boston, MA. https://doi.org/10.1007/978-0-387-77778-8_15.
18. Kachitvichyanukul V. Comparison of three evolutionary algorithms: GA, PSO, and DE. 2012. *Industrial Engineering & Management Systems* 12(3):215-223. <https://doi.org/10.7232/iems.2012.11.3.215>