

**В.И. Данильченко, В.В. Бова****ИНТЕЛЛЕКТУАЛЬНЫЕ МЕТОДЫ ПАРАМЕТРИЧЕСКОГО ПРОГНОЗИРОВАНИЯ И ОПТИМИЗАЦИИ ТРАЕКТОРИИ ДВИЖЕНИЯ БАС**

*Рассматривается задача интеллектуального параметрического прогнозирования и оптимизации траектории движения беспилотной авиационной системы (БАС) с применением эволюционных алгоритмов и методов машинного обучения. Актуальность исследования обусловлена многокритериальностью и высокой сложностью процессов формирования траектории движения БАС, а также необходимостью точной и своевременной оценки её полётных параметров. Это особенно важно для обеспечения надёжности, безопасности и эффективного выполнения полётных задач в условиях эксплуатации БАС, включая сценарии, связанные с функционированием критически значимых объектов инфраструктуры. Цель исследования заключается в повышении точности диагностики траекторных параметров и надёжности параметрического прогнозирования траекторий движения БАС в условиях неопределённости и многокритериальности рассматриваемой задачи. В работе предлагается гибридный подход, включающий генетический алгоритм (ГА), алгоритм роя частиц (PSO) с моделью машинного обучения XGBoost, обеспечивающей адаптивную оценку качества формируемых решений. Реализован вычислительный программный комплекс, включающий механизмы селекции, рекомбинации, мутации и элитного наследования, а также модуль машинного обучения для валидации траектории маршрута и связанных параметров. Проведён вычислительный эксперимент, в рамках которого выполнен сравнительный анализ эффективности ГА и PSO при различных сценариях их работы. Тестирование выполнялось на отраслевых наборах данных при различном количестве итераций. В ходе вычислительного эксперимента выявлено преимущество генетического алгоритма, а именно повышение качества проектных решений на 14–17%. Результаты исследования демонстрируют высокую адаптивность и практическую применимость в задачах моделирования, параметрического прогнозирования и маршрутизации, а также указывают на потенциал интеграции с интеллектуальными системами навигации и мониторинга БАС. Материалы статьи представляют практический интерес для специалистов в области разработки и эксплуатации БАС, а также для исследователей, занимающихся задачами многокритериального планирования маршрутов, параметрического прогнозирования и повышения надёжности функционирования БАС.*

*Генетический алгоритм; алгоритм роя частиц; эволюционные вычисления; машинное обучение; XGBoost; маршрутизация; параметрическое прогнозирование; интеллектуальные алгоритмы.*

**V.I. Danilchenko, V.V. Bova****INTELLIGENT METHODS OF PARAMETRIC FORECASTING AND OPTIMIZATION OF UAV TRAJECTORIES**

*This paper examines the problem of intelligent parametric forecasting and trajectory optimization for unmanned aircraft systems (UAS) using evolutionary algorithms and machine learning methods. The relevance of the study stems from the multi-criteria and high complexity of UAS trajectory generation processes, as well as the need for accurate and timely assessment of its flight parameters. This is particularly important for ensuring the reliability, safety, and efficient performance of flight missions in UAS operating conditions, including scenarios related to the operation of critical infrastructure facilities. The objective of the study is to improve the accuracy of trajectory parameter diagnostics and the reliability of parametric forecasting of UAS trajectories under conditions of uncertainty and the multi-criteria nature of the problem. The paper proposes a hybrid approach incorporating a genetic algorithm (GA), a particle swarm algorithm (PSO), and an XGBoost machine learning model that provides adaptive assessment of the quality of the generated solutions. A computational software package has been implemented, including selection, recombination, mutation, and elite inheritance mechanisms, as well as a machine learning module for validating route trajectories and associated parameters. A computational experiment was conducted, which compared the effectiveness of GA and PSO under various operating scenarios. Testing was performed on industry-specific datasets with varying numbers of iterations. The computational experiment revealed the advantage of the genetic algorithm, namely, a 14–17% improvement in the quality of design solutions. The results of the study demonstrate high adaptability and practical applicability in modeling, parametric forecasting, and routing tasks, and also indicate the potential for integration with intelligent UAS navigation and monitoring systems. The article's materials are of practical interest to specialists in the field of UAS development and operation, as well as to researchers working on multi-criteria route planning, parametric forecasting, and improving the reliability of UAS operations.*

*Genetic algorithm; particle swarm optimization; evolutionary computation; machine learning; XGBoost; Routing; parametric forecasting; intelligent algorithms.*

**Введение.** Современные БАС демонстрируют устойчивую тенденцию к усложнению архитектуры и взаимодействующих компонентов, одновременно предъявляя высокие требования к ключевым эксплуатационным характеристикам – надёжности, устойчивости функционирования и согласованности траекторных параметров в динамически изменяющейся среде [1–3].

Особую актуальность интеллектуальные методы приобретают в транспортных системах, включая применение БАС, где сложность процессов, масштаб взаимодействующих объектов и высокая динамичность эксплуатационных условий формируют повышенные требования к прогнозированию траекторных параметров и мониторингу состояния полётной среды [4–6]. В условиях динамично изменяющейся полётной среды беспилотные авиационные системы сталкиваются с неопределённостью, влияющей на точность заданной траектории и устойчивость выполнения миссии. Изменения метеоусловий, вариативность внешних факторов и ограничения полётного пространства усложняют процесс выбора оптимальных параметров движения. В таких сценариях требуется применение интеллектуальных методов, способных обеспечивать точное параметрическое прогнозирование и корректировку траектории в реальном времени.

Традиционные методы анализа, основанные на детерминированных моделях и жёстких формализациях, оказываются недостаточно эффективными в условиях реальных полётных сценариев, которые характеризуются высокой неопределённостью, неполнотой исходных данных и выраженными нелинейными взаимосвязями между параметрами движения БАС [7–9]. Актуальность разработки новых подходов обусловлена комплексом взаимосвязанных факторов. В процессе мониторинга формируются нечеткие, частично противоречивые и неоднородные данные, поступающие от разнородных сенсорных и измерительных подсистем, что существенно осложняет формирование достоверной оценки. Многокритериальный характер задач анализа траекторных параметров БАС требует одновременного учёта показателей безопасности полёта, энергоресурса и эксплуатационных ограничений, влияющих на устойчивость и надёжность выполнения миссии [10, 11]. Дополнительные трудности обусловлены тем, что процессы формирования траектории протекают в динамически изменяющихся условиях эксплуатации, где переменные внешние факторы существенно влияют на параметры полёта и устойчивость движения БАС. Ещё одним критически важным аспектом является сложность формализации экспертных знаний специалистов, обладающих значительным практическим опытом, но выражающих свои оценки преимущественно в качественной форме. Рациональным механизмом компенсации выявленных ограничений является использование современных интеллектуальных методов анализа и прогнозирования, способных работать с неполными, неоднородными и статистически нестабильными данными. В отличие от классических детерминированных моделей, основанных на четко фиксированных зависимостях и предположении о стационарности параметров, интеллектуальные методы обеспечивают учёт неопределённости, адаптацию к динамическим изменениям и выявление скрытых функциональных связей в многомерных выборках [1, 6]. Эти свойства определяют применимость интеллектуальных методов в задачах диагностики, прогнозирования и анализа параметров полёта, включая сценарии, связанные с мониторингом объектов транспортной инфраструктуры. В подобных условиях особую значимость приобретают современные интеллектуальные технологии, обеспечивающие обработку разнородных данных и повышение качества принимаемых решений.

При решении задач прогнозирования и оценки траекторных параметров БАС особую значимость приобретают современные интеллектуальные технологии, применяемые для обработки полётных данных и поддержки решений, связанных с безопасностью и устойчивостью движения. Одним из эффективных инструментов является нечёткая логика (Fuzzy Logic), позволяющая формализовать качественные экспертные суждения, такие как «высокий уровень риска отклонения», «средняя степень нестабильности траектории» или «незначительное влияние внешних факторов». Механизмы нечёткого вывода дают возможность учитывать субъективный опыт операторов и специалистов, что особенно важно при анализе полётных ситуаций, параметры которых не всегда поддаются строгому количественному описанию [7].

Наряду с нечёткими моделями применяются нейронные сети (Artificial Neural Networks), которые благодаря способности к самообучению и выявлению скрытых нелинейных зависимостей позволяют решать задачи прогнозирования траекторных параметров БАС и оценки устойчивости полёта. Использование исторических данных о параметрах движения, внешних воздействиях и условиях эксплуатации даёт возможность формировать устойчивые предиктивные модели, обеспечивающие высокую точность оценки вероятности отклонений траектории и поддерживающие переход к проактивным стратегиям управления полётом [8].

В задачах, требующих поиска квазиоптимальных решений в сложных многомерных пространствах, используются эволюционные алгоритмы, в частности генетические алгоритмы (ГА), представляющие собой класс метаэвристических поисковых методов, основанных на принципах естественного отбора. Популяционный подход, основанный на применении операторов селекции, скрещивания и мутации, позволяет генетическим алгоритмам эффективно решать многокритериальные задачи с различными ограничениями. Так же анализ нескольких альтернатив повышает вероятность нахождения квазиоптимальных решений в сложном поисковом пространстве [9]. Особую практическую значимость ГА приобретают в задачах планирования траектории, распределения ресурсов и оптимизации параметров полёта БАС. За счёт способности выполнять глобальный поиск в сложном пространстве параметров ГА позволяет формировать квазиоптимальные решения с учётом множества критериев, таких как снижение рисков, повышение уровня безопасности и сокращение времени выполнения миссии. Такие возможности генетических алгоритмов делают перспективным их комбинирование, гибридизацию и интеграцию с другими методами, объединяя их преимущества и обеспечивая более высокое качество решений. Одним из распространённых подходов являются нейро-нечёткие модели (например, ANFIS) [10], которые совмещают обучающие возможности нейронных сетей с интерпретируемостью нечётких правил. Такая интеграция генетического алгоритма, выполняющего глобальный поиск оптимальных параметров, с нечёткими моделями, обрабатывающими экспертные знания, позволяет формировать устойчивые и адаптивные системы поддержки принятия решений при построении траекторий БАС [11, 12].

Таким образом, применение современных интеллектуальных методов анализа и прогнозирования открывает новые возможности для повышения качества и эффективности решения задач, связанных с формированием и оптимизацией траектории движения БАС. Данные методы обеспечивают переход от реактивных форм управления к проактивным стратегиям, основанных на раннем выявлении потенциальных отклонений, оценке рисков и прогнозировании поведения системы в условиях неопределённости.

В рамках данной работы решается комплексная научно-техническая задача, включающая формализацию проблемы прогнозирования параметров траектории движения БАС, разработку гибридного генетического алгоритма с интегрированной моделью XGBoost для динамической оценки качества решений, создание специализированного программного комплекса, а также проведение серии верификационных вычислительных экспериментов, подтверждающих работоспособность и эффективность предложенного решения.

Разработка и внедрение данного интеллектуального программного комплекса прогнозирования и оптимизации траектории БАС позволит повысить уровень эксплуатационной безопасности, снизить затраты и обеспечить устойчивое выполнение полётных задач в долгосрочной перспективе. Перспективные направления дальнейших исследований включают развитие адаптивных гибридных моделей, расширение методов интеграции разнородных данных и использование технологий обработки больших массивов информации для повышения качества траекторных решений и эффективности автономного управления.

**Актуальность проблемы.** Многокритериальный характер рассматриваемой задачи, осложнённый необходимостью обработки значительных объёмов полётных данных в режиме, близком к реальному времени, существенно снижает эффективность традиционных поисковых методов. Классические подходы не обладают достаточной гибкостью и устойчивостью при изменении условий эксплуатации, что ограничивает их примени-

мость в реальных сценариях управления БАС. Это обуславливает активное развитие интеллектуальных методов, способных учитывать множество взаимосвязанных параметров, адаптироваться к динамике исходных данных и обеспечивать более качественные и эффективные траекторные решения.

**Постановка задачи.** Проблема определения оптимальных параметров полётного задания формулируется как многокритериальная задача, требующая обработки больших объёмов данных и выбора системы оценочных критериев. Целью является получение квазиоптимальной комбинации управляющих переменных, обеспечивающей выполнение миссии в заданных ограничениях. Математическая постановка сводится к определению набора управляющих параметров [7, 18]:

$$M = \{a, s, p, e, r\}, \quad (1)$$

где  $a$  – рабочая высота полёта (м),  $s$  – скорость полёта (м/с),  $p$  – коэффициент приоритета траектории,  $e$  – прогнозируемый энергобаланс (%),  $r$  – индекс угроз безопасности.

Для формулирования задачи и оценки ее результатов определим критерии и целевую функцию. Целевая функция представляет собой аддитивную свертку частных критериев:

$$F(M) = \lambda_1 \cdot Q_{\text{fitness}} + \lambda_2 \cdot E_{\text{energy}} + \lambda_3 \cdot S_{\text{safety}} + \lambda_4 \cdot T_{\text{time}}, \quad (2)$$

где  $\lambda_i$  – нормированные весовые коэффициенты, отражающие приоритет каждого критерия,  $Q$  – комплексный показатель качества маршрута,  $E$  – относительное энергопотребление (%),  $S$  – индекс риска (нормированный от 0 до 1),  $T$  – затраченное время на полет (мин).

Общая математическая формулировка задачи выражается следующим образом [7, 18]:

$$\begin{aligned} \min_m F(M) \text{ при условиях: } & g_i(\vec{M}) \leq 0, i = 1, \dots, m \\ & h_j(\vec{M}) = 0, j = 1, \dots, p, \end{aligned} \quad (3)$$

где  $g_i$  – функции ограничений в форме неравенств, задающие эксплуатационные, конструктивные и регламентные требования к маршруту, включая предельные значения высоты и скорости полёта, ограничения по энергобалансу, параметры метеорологической обстановки и условия безопасного удаления от зон повышенного риска,  $h_j$  – функции ограничений в форме равенств, задающие дополнительные жёсткие требования, такие как фиксированная геометрическая конфигурация траектории, обязательные точки входа и выхода маршрута и другие параметры, обусловленные спецификой решаемой задачи.

**Метод решения поставленной задачи.** Рассмотрим метод решения, включающий используемые алгоритмы и принципы формирования оптимальных траекторий движения БАС. Выделим систему ограничений, включающую комплекс эксплуатационных и технических условий, которым должен удовлетворять формируемый маршрут. К числу таких условий относятся конструктивные лимиты, определяющие допустимые диапазоны высот и скоростей полёта; атмосферные факторы, описываемые параметрами ветра, видимости и интенсивности осадков; регламенты воздушного пространства, задающие зональные ограничения на использование определённых участков территории; энергетические ограничения, связанные с допустимым уровнем расхода и текущей ёмкостью источников питания; а также временные рамки выполнения задания, определяемые максимальной продолжительностью полёта. В совокупности эти условия формализуются через функции ограничений вида  $g_i(\vec{M}) \leq 0$  и  $h_j(\vec{M}) = 0$ , обеспечивая физическую реализуемость и безопасность решения [8, 13, 18].

Комплекс используемых оценочных показателей формируется на основе нескольких ключевых метрик, интегрируемых в целевую функцию. В их числе: комплексный показатель качества маршрута  $Q$ , отражающий рациональность построенной траектории; относительное энергопотребление  $E$ , характеризующее долю расходуемого ресурса; нормированный индекс риска  $S$ , (в диапазоне [0; 1]) определяющий степень приближения к потенциально опасным зонам; а также итоговое значение целевой функции  $F$ , фиксируемое после завершения процедуры поиска на каждой итерации. Комплексное использова-

ние указанных метрик обеспечивает объективную и сбалансированную оценку эффективности найденных решений. Полученная оценочная модель требует применения эффективного поискового инструмента.

Одним из таких инструментов является генетический алгоритм [14], который относится к классу эвристических поисковых методов, основанных на принципах эволюции и механизмах наследования признаков. ГА в задаче параметрического прогнозирования маршрутов реализует последовательный вычислительный процесс, включающий формирование исходной популяции, каждая из которых кодируется комбинацией параметров траектории и вычислением функции приспособленности с использованием предварительно обученной модели XGBoost [15]. В предложенном ГА в качестве процедуры отбора реализуется механизм «турнира», в результате которого лучшие особи выбираются для последующего скрещивания на основе значений целевой функции. Данный механизм представлен в виде псевдокода 1:

---

Псевдокод 1. Механизм турнирного отбора

---

```
def selection(self) -> List[RouteParameters]:
    selected = []
    for _ in range(self.population_size):
        tournament = random.sample(self.population, 3)
        winner = max(tournament, key=lambda x: self.fitness_function(x))
        selected.append(winner)
    return selected
```

---

После выполнения процедуры отбора, на следующем этапе, применяется оператор рекомбинации, обеспечивающий объединение генетической информации родительских особей и формирование нового потомства [16]. Программная реализация оператора рекомбинации представлена в виде псевдокода 2:

---

Псевдокод 2. Оператор рекомбинации

---

```
def mutate(self, route: RouteParameters) -> RouteParameters:
    if random.random() > self.mutation_rate:
        return route
    new_altitude = max(self.min_altitude, min(self.max_altitude,
        route.altitude + random.uniform(-1.0, 1.0)))
    new_speed = max(self.min_speed, min(self.max_speed,
        route.speed + random.uniform(-0.5, 0.5)))
    return RouteParameters(
        waypoints=route.waypoints,
        altitude=new_altitude,
        speed=new_speed,
        priority=route.priority if random.random() < 0.95 else random.choice(['safety', 'distance', 'time', 'shortest']),
        battery_usage=route.battery_usage )
```

---

Дополнительно в структуру ГА включён механизм сохранения элитных решений, обеспечивающий формирование новой популяции с обязательным их учетом [17]. На практике это реализуется путём выделения фиксированной доли лучших решений в соответствии со значениями целевой функции, после чего они без изменений включаются в состав следующего поколения. Программная реализация данного механизма приведена в виде псевдокода 3:

---

Псевдокод 3. Механизм сохранения элитных решений

---

```
elite_size = max(1, int(self.population_size * 0.05))
elites = [route for route, score in scored_population[:elite_size]]
```

---

Такая стратегия позволяет избежать потери наиболее качественных траекторий вследствие случайных эффектов рекомбинации и мутации, повышает устойчивость сходимости и ускоряет поиск квазиоптимальных решений. Завершающим этапом работы ГА является система условий терминации, определяющая момент завершения эволюционного процесса. Как правило, остановка вычислений осуществляется при достижении максимального числа итераций, либо требуемого значения целевой функции, а в отдельных случаях применяется дополнительный критерий, основанный на отсутствии заметного улучшения качества решений на протяжении нескольких поколений. Применение механизма элитного наследования и системы терминации обеспечивают устойчивую сходимость алгоритма, что и подтверждает его практическую эффективность для решения сложных многокритериальных задач.

Ещё одним из распространённых и эффективных подходов к решению многокритериальных задач оптимизации является алгоритм роя частиц (PSO) [18], который относится к классу метаэвристических методов, основанных на моделировании коллективного поведения множества взаимодействующих агентов. В отличие от эволюционных алгоритмов, основанных на механизмах наследования и генетической вариативности, PSO использует динамическое обновление состояний частиц на основе индивидуального опыта и коллективной информации, что обеспечивает высокую скорость сходимости и позволяет эффективно исследовать пространство решений [19].

Каждая частица в алгоритме характеризуется позицией  $\vec{x}_i(t)$  и скоростью  $\vec{v}_i(t)$  в момент времени  $t$ , а также сохраняет лучшую найденную позицию  $p_i^{best}$ . А также, весь рой отслеживает глобальную квазиоптимальную позицию  $g_i^{best}$ . Обновление скорости и позиции частиц осуществляется по классическим рекуррентным выражениям [20]:

$$\vec{v}_i(t+1) = \omega \vec{v}_i + c_1 r_1 (\vec{p}_i^{best} - \vec{x}_i(t)) + c_2 r_2 (\vec{g}_i^{best} - \vec{x}_i(t)), \quad (4)$$

$$\vec{x}_i(t+1) = \vec{x}_i(t) + \vec{v}_i(t+1),$$

где  $\omega$  – инерционный коэффициент, регулирующей роль предыдущей скорости;  $c_1 c_2$  – когнитивный и социальный коэффициенты;  $r_1 r_2 \in [0; 1]$  – случайные числа, обеспечивающие стохастичность поиска. Определение перечисленных коэффициентов задаёт поведение частиц в пространстве поиска, что становится основой для анализа полного цикла работы PSO.

Алгоритм роя частиц основан на механизме коллективного поиска, при котором каждая частица учитывает как собственный опыт, так и информацию о глобально лучшем решении, что обеспечивает характерную для PSO способность к кооперативному (коллективному) обновлению траекторий поиска. В контексте прогнозирования параметров маршрутов процесс оптимизации включает инициализацию роя в допустимых диапазонах параметров, вычисление функции приспособленности для оценки качества текущих решений, обновление локальных и глобальных позиций при улучшении целевой функции, а также корректировку скоростей и координат частиц на основе стандартных рекуррентных соотношений, определяющих их движение к наиболее перспективным областям пространства поиска; завершение итерационного процесса определяется достижением установленного числа шагов, требуемого уровня эффективности либо отсутствием прогресса в глобальном решении. Стохастическая природа и роевой характер поиска обеспечивают PSO высокую скорость сходимости и устойчивость к изменяющимся условиям, однако отсутствие механизмов поддержания разнообразия, характерных, например, для элитного наследования в генетических алгоритмах, может приводить к преждевременной сходимости, что подтверждается результатами вычислительных экспериментов [5, 7, 9].

**Вычислительный эксперимент.** Для проведения вычислительного эксперимента использовался комплексный подход с применением стандартных и специально разработанных программных средств [8, 13, 18]. В рамках исследования была реализована серия вычислительных экспериментов, направленных на сравнительную оценку эффективности ГА и алгоритма роя частиц. Сравнение выполнялось в идентичных условиях, что гарантировало объективность полученных результатов. Исследование было направлено на

выявление ключевых преимуществ и ограничений каждого из алгоритмов в условиях решения сложных многокритериальных задач планирования полётных траекторий. Для обеспечения объективности анализа разработана программная среда, в которой реализовано несколько экспериментальных сценариев.

Программная среда поддерживает процессы моделирования и анализа четырёх целевых сценариев, каждый из которых отражает отдельный критически важный аспект формирования оптимальной полётной траектории. Сценарий «Time-efficiency» ориентирован на минимизацию общей продолжительности миссии, что определяет время выполнения целевых задач. Сценарий «Shortest-path» предусматривает построение геометрически оптимальной, минимальной по длине траектории, обеспечивающей сокращение суммарного пройденного пути. В сценарии «Weather-adaptivity» исследуется способность алгоритмов снижать влияние неблагоприятных атмосферных факторов – ветровой нагрузки, порывов и осадков – тем самым повышая устойчивость и энергоэффективность полёта. Сценарий «Safety-prioritization» направлен на максимизацию безопасности за счёт стратегического обхода зон потенциального риска и иных опасных участков маршрута.

Для каждого из рассматриваемых сценариев были подготовлены очищенные наборы данных, включающие широкий спектр параметров. В их состав входили три фиксированных значения максимального числа итераций (100, 1000 и 10 000), конфигурации маршрутов, лётно-технические характеристики (высота и скорость полёта), а также метеорологические параметры, такие как температура воздуха, направление, скорость ветра и интенсивность осадков. Структура подготовленных данных обеспечивает возможность их формализованного представления и дальнейшего анализа.

Сформированные экспериментальные наборы данных представлены в форме таблиц 1–4, что обеспечивает их удобство для структурированного анализа и последующей интерпретации. Каждая таблица отражает ключевые параметры сценариев моделирования, включая конфигурационные характеристики маршрутов, численные значения высоты и скорости полёта, метеорологические условия и фиксированные значения числа итераций, что позволяет систематизировать информацию и гарантировать её сопоставимость и валидацию. Формирование каждого датасета осуществляется с учётом требований репрезентативности и статистической устойчивости: варьирование параметров выполняется в пределах допустимых диапазонов, а структура данных поддерживает единообразие для всех сценариев. Такой подход позволяет сформировать статистически корректную и методологически согласованную экспериментальную базу, служащую надёжным основанием для объективного сравнения алгоритмической эффективности ГА и алгоритма PSO в заданных условиях моделирования.

Таблица 1

## Режим «time»

Набор данных time_1	Значения
Количество итераций	100
Количество точек	3
Широта точки 1	54,25
Долгота точки 1	54,5
Широта точки 2	54,5
Долгота точки 2	54,25
Широта точки 3	54,5
Долгота точки 3	54,5
Высота полета, м	25
Скорость полета, м\с	10
Температура, С	20
Скорость ветра, м\с	5
Осадки, мм	5

Таблица 2

## Режим «shortest»

Набор данных shortest_1	Значения
Количество итераций	100
Количество точек	3
Широта точки 1	54,2
Долгота точки 1	54,7
Широта точки 2	54,7
Долгота точки 2	54,2
Широта точки 3	54
Долгота точки 3	54
Высота полета,м	25
Скорость полета,м/с	10
Температура,С	20
Скорость ветра,м/с	5
Осадки,мм	5

Таблица 3

## Режим «distance»

Набор данных distance_1	Значения
Количество итераций	100
Количество точек	3
Широта точки 1	54
Долгота точки 1	55
Широта точки 2	53
Долгота точки 2	54
Широта точки 3	55
Долгота точки 3	53
Высота полета,м	25
Скорость полета,м/с	10
Температура,С	20
Скорость ветра,м/с	5
Осадки,мм	5

Таблица 4

## Режим «safety»

Набор данных safety_1	Значения
Количество итераций	100
Количество точек	3
Широта точки 1	54,2
Долгота точки 1	54,7
Широта точки 2	54,7
Долгота точки 2	54,2
Широта точки 3	54
Долгота точки 3	54
Высота полета,м	40
Скорость полета,м/с	10
Температура,С	30
Скорость ветра,м/с	10
Осадки,мм	8

Сформированная структура входных данных определяет дальнейшую логику проведения экспериментов, включая выбор режимов тестирования. Эти режимы не являются произвольными: каждый из них отражает отдельную прикладную задачу, возникающую

при формировании квазиоптимальных траекторий. Режим «time» ориентирован на минимизацию общей длительности полёта; режим «shortest» – на построение геометрически оптимальной и минимальной по длине траектории; режим «distance» – на снижение негативного влияния метеорологических факторов, прежде всего ветровой нагрузки; режим «safety» – на максимальное избегание зон повышенного риска. Подготовленные наборы данных служат основой для проведения сравнительного анализа в каждом из режимов требует определения набора объективных метрик, по которым оценивается качество решений.

Оценка эффективности работы алгоритмов выполняется на основе набора выбранных метрик, обеспечивающих качество формируемых решений. К таким метрикам относятся: интегральный показатель качества решения «fitness\_score», уровень энергопотребления «battery\_consume», индикатор потенциального риска «safety\_risk» и итоговое значение целевой функции «final\_fitness», фиксируемое после завершения алгоритма. Совокупность указанных метрик позволяет получить целостную и объективную оценку работы алгоритмов, охватывая ключевые аспекты их производительности и практической применимости в условиях реальной эксплуатации. Отметим, что полученные результаты в рамках вычислительного эксперимента измеряются в условных единицах.

Результаты вычислительного эксперимента представлены в табл. 5.

Таблица 5

Результаты вычислительного эксперимента

Наборы данных	fitness_score		battery_consume		safety_risk		final_fitness	
	GA	PSO	GA	PSO	GA	PSO	GA	PSO
time_1	0,7883	0,5996	79,17	47,86	0,6	0,4	0,87587	0,7698
time_2	0,8905	0,6003	63,26	51,28	0,6	0,4	0,9133	0,7701
time_3	0,8979	0,5137	49,41	62,59	0,5	0,4	0,9493	0,7311
short_1	0,7462	0,6	100	100	0,6	0,4	0,9089	0,77
short_2	0,8249	0,6	100	100	0,6	0,4	0,9305	0,77
short_3	0,8781	0,607	100	100	0,6	0,4	0,9485	0,7731
distance_1	0,8137	0,5972	100	100	0,6	0,4	0,9278	0,7687
distance_2	0,8642	0,6042	100	100	0,6	0,4	0,9416	0,7719
distance_3	0,8642	0,6008	100	100	0,6	0,4	0,9408	0,7703
safety_1	0,6377	0,6039	100	100	0,95	0,95	0,8914	0,7717
safety_2	0,7303	0,6054	100	100	0,95	0,95	0,9065	0,7724
safety_3	0,7377	0,6093	100	100	0,95	0,95	0,9045	0,7741

Анализ представленных данных показывает, что генетический алгоритм демонстрирует более высокие значения интегральных метрик качества (fitness\_score и final\_fitness) на всех тестовых наборах. Алгоритм роя частиц характеризуется большей вариативностью результатов и уступает ГА по значению целевой функции, что указывает на ограниченную способность PSO к последовательному улучшению решений в сложных сценариях. При этом показатели энергопотребления и риска остаются сопоставимыми, что подтверждает корректность условий сравнения и позволяет сделать вывод, что различия обусловлены именно особенностями поисковой динамики. Совокупность результатов подтверждает высокую эффективность и устойчивость ГА в задаче параметрического прогнозирования траекторий. Полученные численные показатели дополняются графической интерпретацией, позволяющей продемонстрировать особенности поведения данных алгоритмов в работе по различным сценариям.

Результаты моделирования представлены на рис. 1 и 2. Каждый из них демонстрирует характерные особенности построения траекторий при использовании различных критериев. На рис. 1 представлена траектория, сформированная в рамках сценария «Shortest-path», в котором основным критерием является геометрическая протяжённость маршрута.

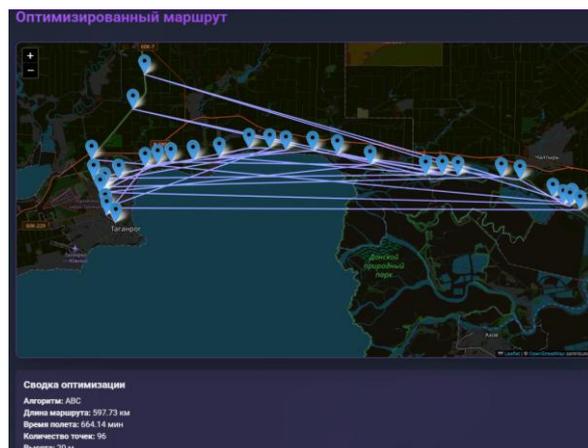


Рис. 1. Кратчайший маршрут

В данном режиме приоритет отдаётся исключительно геометрической оптимальности – минимизации длины пути. При этом алгоритм формирует максимально прямолинейную и компактную траекторию без дополнительных обходов и отклонений, возникающих при отсутствии жёстких ограничений по риску, метеорологическим параметрам или энергетическим требованиям.

Представленная конфигурация отражает эталонный вариант решения, применимый в условиях, когда длина пути является основным критерием. Такая траектория служит базовым ориентиром для сопоставления с другими сценариями, в которых в процессе поиска учитываются дополнительные требования, такие как устойчивость к метеофакторам, минимизация рисков или балансировка нескольких критериев. Визуализированный маршрут отражает особенности работы гибридного алгоритма в режиме, ориентированном на пространственную экономию.

На рис. 2 представлена траектория, оптимизированная по критерию безопасности. Маршрут отражает оптимальный обход потенциально опасных областей, а минимизация вероятности пересечения зон повышенного риска приводит к обоснованному отклонению траектории от прямой линии между ключевыми точками.

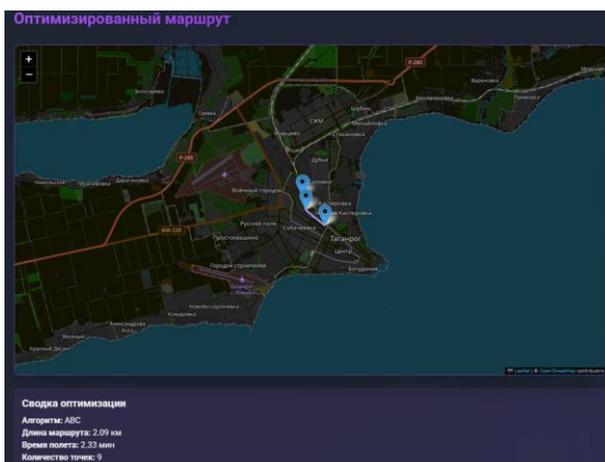


Рис. 2. Безопасный маршрут

Полученная траектория демонстрирует сбалансированное соотношение между увеличением длины пути и снижением интегрального риска: маршрут приобретает более плавную форму, избегая критические зоны для поддержания стабильных условий полёта.

Такое решение отражает приоритет безопасных требований над геометрическими и временными критериями, что особенно важно при выполнении задач в условиях неопределённости или повышенных эксплуатационных ограничениях.

На рис. 3 представлена динамика изменения целевой функции, позволяющая сравнить характер сходимости двух оптимизационных алгоритмов.

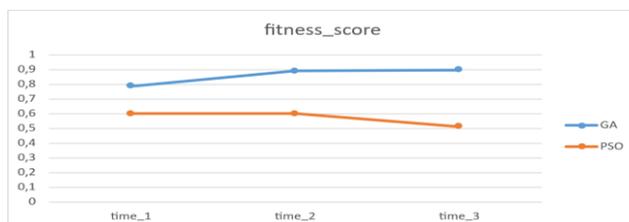


Рис. 3. Динамика изменения целевой функции

Анализ кривых сходимости показывает существенные различия в поведении алгоритмов. Генетический алгоритм демонстрирует устойчивое и последовательное улучшение значения целевой функции, тогда как PSO проявляет высокую вариативность и чувствительность к стохастическим компонентам. Это выражается в стабильном приближении ГА к квазиоптимальному решению, в то время как PSO часто фиксируется в локальных экстремумах и не обеспечивает монотонного улучшения результата. Динамика показателя *final\_fitness* дополнительно подтверждает преимущество ГА как более эффективной поисковой стратегии для рассматриваемой задачи.

**Заключение.** В ходе исследования рассмотрена задача параметрического прогнозирования и оптимизации траектории движения БАС, актуальность которой обусловлена высокой динамичностью полётной среды и необходимостью повышения точности выбора траекторных параметров в условиях неопределённости. Проведён анализ эволюционных методов и алгоритмов машинного обучения, позволивший определить их особенности и применимость в многокритериальных задачах оптимизации полёта.

На основе интеграции генетического алгоритма с моделью XGBoost разработан комбинированный подход, обеспечивающий адаптивную оценку качества решений и улучшенную динамику сходимости. На основе разработанных методов и механизмов реализован программный комплекс, который включает механизмы селекции, рекомбинации, мутации и элитного наследования, а также модуль машинного обучения для валидации траекторных параметров.

Проведённый вычислительный эксперимент, охватывающий четыре практических сценария («time», «shortest», «distance», «safety») и три уровня глубины оптимизации (100, 1000 и 10 000 итераций), продемонстрировал выраженное преимущество генетического алгоритма по сравнению с PSO. В частности, повышение качества проектных решений составило 14–17%, что отражено в более высоких значениях «fitness\_score» и «final\_fitness», а также в стабильной динамике сходимости. Генетический алгоритм показал устойчивость к локальным экстремумам и способность к последовательному улучшению результата на всех итерациях алгоритма, тогда как PSO продемонстрировал менее устойчивую траекторию поиска.

Полученные результаты демонстрируют практическую значимость предложенного подхода и подтверждают его эффективность в задачах прогнозирования и оптимизации траекторных параметров БАС. Гибридизация эволюционных методов и алгоритмов машинного обучения обеспечивает повышение точности прогнозов и устойчивость к вариативности входных данных, что расширяет возможности их применения в инженерных и эксплуатационных сценариях автономного управления беспилотными системами. Дальнейшее развитие исследования может быть связано с расширением набора критериев оценки качества и эффективности проектных решений, внедрением динамических моделей среды и созданием гибридных архитектур с использованием нейросетевых систем.

*Исследование выполнено за счет гранта Российского научного фонда No 24-71-00035, <https://rscf.ru/project/24-71-00035/> в Южном федеральном университете.*

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Курейчик В.В., Гладков Л.А., Кравченко Ю.А., Родзин С.И. Интеллектуальные системы: модели и методы метаэвристической оптимизации: монография. – Чебоксары: Издательский дом «Среда», 2024. – 228 с. – ISBN 978-5-907830-56-1. – DOI: 10.31483/a-10639.
2. Курейчик В.В., Родзин С.И. Вычислительные модели эволюционных и роевых биоэвристик (обзор) // Информационные технологии. – 2021. – Т. 27, № 10. – С. 507-520. – DOI: 10.17587/it.27.507-520.
3. Курейчик В.В., Данильченко В.И., Данильченко Е.В. Маршрутизация автономных устройств в трёхмерном пространстве // Информатика и автоматизация. – 2025. – Т. 24, № 2. – С. 492-525. – DOI 10.15622/ia.24.2.5.
4. Карпенко А.П. Современные алгоритмы поисковой оптимизации. Алгоритмы, вдохновлённые природой. – 3-е изд. – М.: МГТУ им. Баумана, 2021. – 448 с.
5. Гладков Л.А., Гладкова Н.В. Эволюционирующие многоагентные системы и эволюционное проектирование // Известия ЮФУ. Технические науки. – 2020. – № 4 (214). – С. 48-59. – DOI: 10.18522/2311-3103-2020-4-48-59.
6. Семенов Н.А., Иванов В.К., Думина Д.С. Определение весовых коэффициентов для аддитивной фитнес-функции генетического алгоритма // Программные продукты и системы. – 2020. – № 1. – С. 47-53.
7. Тарасов В.Б., Гладков Л.А., Лейба С.Н. Разработка и программная реализация гибридного алгоритма решения оптимизационных задач автоматизированного проектирования // Программные продукты и системы. – 2018. – № 3. – С. 569-580.
8. Кулиев Э.В., Лежебоков А.А., Семенова М.М., Семенов В.А. Подход к кодированию решений в эволюционных методах для создания инструментальной платформы проектирования // Известия ЮФУ. Технические науки. – 2020. – № 2 (212). – С. 169-179.
9. Казакова Е.М. Применение метода роя частиц в задачах оптимизации // Известия Кабардино-Балкарского научного центра РАН. – 2022. – № 5 (109). – С. 48-57. – DOI: 10.35330/1991-6639-2022-5-109-48-57.
10. Рачков Т.И., Кузьмина И.А. Мета-эвристический алгоритм децентрализованного управления группой // Математические методы в технологиях и технике. – 2021. – № 3. – С. 96-99. – DOI 10.52348/2712-8873\_ММТТ\_2021\_3\_96.
11. Костин А.С., Майоров Н.Н. Исследование моделей и методов маршрутизации и практического выполнения автономного движения беспилотными транспортными системами для доставки грузов // Вестник государственного университета морского и речного флота им. адмирала С.О. Макарова. – 2023. – Т. 15, № 3. – С. 524-536. – DOI 10.21821/2309-5180-2023-15-3-524-536.
12. Акопов А.С., Бекларян Л.А., Бекларян А.Л. Оптимизация характеристик интеллектуальной транспортной системы с использованием генетического алгоритма вещественного кодирования на основе адаптивной мутации // Информационные технологии. – 2023. – Т. 29, № 3. – С. 115-125. – DOI 10.17587/it.29.115-125.
13. De Souza L.A.M., Da Silva J.E.H., Chaves L.J., Bernardino H.S. A benchmark suite for designing combinational logic circuits via metaheuristics // Applied Soft Computing. – 2020. – Vol. 91. – P. 1-32.
14. Hemmak A. Optimal adjusting of simulated annealing parameters // Military Technical Courier. – 2024. – Vol. 72, No. 1. – P. 80-93.
15. Костюков В.А., Медведев М.Ю., Пишихов В.Х. Метод оптимизации траектории мобильного робота в поле источников-репеллеров // Информатика и автоматизация. – 2021. – Т. 20, № 3. – С. 690-726. – DOI 10.15622/ia.2021.3.7.
16. Литвиненко А.М., Кудрявцев Г.В., Ибрагимов М.У.У. Исследование адаптивной системы управления электроэнергетическим комплексом с ветроэлектрогенератором // Вести высших учебных заведений Черноземья. – 2021. – № 3 (65). – С. 10-17. – DOI 10.53015/18159958\_2021\_3\_10.
17. Курочкин А.Г., Тютенко Е.А. Модифицированный алгоритм сглаживания точек маршрута // Известия Юго-Западного государственного университета. – 2016. – № 5 (68). – С. 43-51.
18. Шмалько Е.Ю., Румянцев Ю.А., Байназаров Р.Р., Ямианов К.Л. Идентификация нейросетевой модели робота для решения задачи оптимального управления // Информатика и автоматизация. – 2021. – Т. 20, № 6. – С. 1254-1278. – DOI 10.15622/ia.20.6.3.
19. Кензин М.Ю., Бычков И.В., Максимкин Н.Н. Комплексный многоцелевой мониторинг группой автономных транспортных средств // Известия ЮФУ. Технические науки. – 2019. – № 7 (209). – С. 82-92. – DOI 10.23683/2311-3103-2019-7-82-92.
20. Казаков К.А., Семенов В.А. Обзор современных методов планирования пути // Тр. ИСП РАН. – 2016. – Т. 28, № 4. – С. 241-294.

## REFERENCES

1. Kureychik V.V., Gladkov L.A., Kravchenko Yu.A., Rodzin S.I. *Intellektual'nye sistemy: modeli i metody metaevristicheskoy optimizatsii: monografiya* [Intelligent systems: models and methods of metaheuristic optimization: monograph]. Cheboksary: Izdatel'skiy dom «Sreda», 2024, 228 s. ISBN 978-5-907830-56-1. – DOI: 10.31483/a-10639.
2. Kureychik V.V., Rodzin S.I. Vychislitel'nye modeli evolyutsionnykh i roevykh bioevristik (obzor) [Computational models of evolutionary and swarm bioheuristics: a review], *Informatsionnye tekhnologii* [Information Technologies], 2021, Vol. 27, No. 10, pp. 507-520. DOI: 10.17587/it.27.507-520.
3. Kureychik V.V., Danil'chenko V.I., Danil'chenko E.V. Marshrutizatsiya avtonomnykh ustroystv v trekhmernom prostranstve [Routing of autonomous devices in three-dimensional space], *Informatika i avtomatizatsiya* [Informatics and Automation], 2025, Vol. 24, No. 2, pp. 492-525. DOI 10.15622/ia.24.2.5.
4. Karpenko A.P. *Sovremennyye algoritmy poiskovoy optimizatsii. Algoritmy, vdokhnovlennyye prirodoy* [Modern algorithms of search optimization: algorithms inspired by nature]. 3rd ed. Moscow: MG TU im. Baumana, 2021, 448 p.
5. Gladkov L.A., Gladkova N.V. Evolyutsioniruyushchie mnogoagentnyye sistemy i evolyutsionnoe proektirovanie [Evolving multi-agent systems and evolutionary design], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2020, No. 4 (214), pp. 48-59. DOI: 10.18522/2311-3103-2020-4-48-59.
6. Semenov N.A., Ivanov V.K., Dumina D.S. Opredelenie vesovykh koeffitsientov dlya additivnoy fitnes-funktsii geneticheskogo algoritma [Determining weight coefficients for an additive fitness function of a genetic algorithm], *Programmnye produkty i sistemy* [Software Products and Systems], 2020, No. 1, pp. 47-53.
7. Tarasov V.B., Gladkov L.A., Leyba S.N. Razrabotka i programmnaya realizatsiya gibridnogo algoritma resheniya optimizatsionnykh zadach avtomatizirovannogo proektirovaniya [Development and software implementation of a hybrid algorithm for solving optimization problems in automated design], *Programmnye produkty i sistemy* [Software Products and Systems], 2018, No. 3, pp. 569-580.
8. Kuliev E.V., Lezhebokov A.A., Semenova M.M., Semenov V.A. Podkhod k kodirovaniyu resheniy v evolyutsionnykh metodakh dlya sozdaniya instrumental'noy platformy proektirovaniya [An approach to solution encoding in evolutionary methods for instrumental design platforms], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2020, No. 2 (212), pp. 169-179.
9. Kazakova E.M. Primenenie metoda roya chastits v zadachakh optimizatsii [Application of the particle swarm optimization method in optimization problems], *Izvestiya Kabardino-Balkarskogo nauchnogo tsentra RAN* [Proceedings of the Kabardino-Balkarian Scientific Center of RAS], 2022, No. 5 (109), pp. 48-57. DOI: 10.35330/1991-6639-2022-5-109-48-57.
10. Rakhov T.I., Kuz'mina I.A. Meta-evristicheskiy algoritm detsentralizovannogo upravleniya gruppoy [A meta-heuristic algorithm for decentralized group control], *Matematicheskie metody v tekhnologiyakh i tekhnike* [Mathematical Methods in Techniques and Technology], 2021, No. 3, pp. 96-99. DOI 10.52348/2712-8873\_MMTT\_2021\_3\_96.
11. Kostin A.S., Mayorov N.N. Issledovanie modeley i metodov marshrutizatsii i prakticheskogo vypolneniya avtonomnogo dvizheniya bespilotnymi transportnymi sistemami dlya dostavki gruzov [Study of models and methods of routing and autonomous navigation of unmanned transport systems for cargo delivery], *Vestnik gosudarstvennogo universiteta morskogo i rechnogo flota im. admirala S.O. Makarova* [Bulletin of Admiral Makarov State University of Maritime and Inland Shipping], 2023, Vol. 15, No. 3, pp. 524-536. DOI 10.21821/2309-5180-2023-15-3-524-536.
12. Akopov A.S., Beklaryan L.A., Beklaryan A.L. Optimizatsiya kharakteristik intellektual'noy transportnoy sistemy s ispol'zovaniem geneticheskogo algoritma veshchestvennogo kodirovaniya na osnove adaptivnoy mutatsii [Optimization of intelligent transport system characteristics using a real-coded genetic algorithm with adaptive mutation], *Informatsionnye tekhnologii* [Information Technologies], 2023, Vol. 29, No. 3, pp. 115-125. DOI 10.17587/it.29.115-125.
13. De Souza L.A.M., Da Silva J.E.H., Chaves L.J., Bernardino H.S. A benchmark suite for designing combinational logic circuits via metaheuristics, *Applied Soft Computing*, 2020, Vol. 91, pp. 1-32.
14. Hemmak A. Optimal adjusting of simulated annealing parameters, *Military Technical Courier*, 2024, Vol. 72, No. 1, pp. 80-93.
15. Kostyukov V.A., Medvedev M.Yu., Pshikhopov V.Kh. Metod optimizatsii traektorii mobil'nogo robota v pole istochnikov-repellerov [Trajectory optimization of a mobile robot in a field of repelling sources], *Informatika i avtomatizatsiya* [Informatics and Automation], 2021, Vol. 20, No. 3, pp. 690-726. DOI 10.15622/ia.2021.3.7.
16. Litvinenko A.M., Kudryavtsev G.V., Ibragimov M.U.U. Issledovanie adaptivnoy sistemy upravleniya elektroenergeticheskim kompleksom s vetroelektrogeneratorom [Study of an adaptive control system for an electric-power complex with a wind generator], *Vesti vysshikh uchebnykh zavedeniy Chernozem'ya* [Vestnik of Higher Educational Institutions of the Black Earth Region], 2021, No. 3 (65), pp. 10-17. DOI 10.53015/18159958\_2021\_3\_10.

17. Kurochkin A.G., Titenko E.A. Modifitsirovannyu algoritm sglazhivaniya toчек маршрута [Modified algorithm for smoothing route points], *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta* [Izvestiya of the Southwest State University], 2016, No. 5 (68), pp. 43-51.
18. Shmal'ko E.Yu., Rummyantsev Yu.A., Baynazarov R.R., Yamshanov K.L. Identifikatsiya neyrosetevoy modeli robota dlya resheniya zadachi optimal'nogo upravleniya [Identification of a neural network model of a robot for solving optimal control problems], *Informatika i avtomatizatsiya* [Informatics and Automation], 2021, Vol. 20, No. 6, pp. 1254-1278. DOI 10.15622/ia.20.6.3.
19. Kenzin M.Yu., Bychkov I.V., Maksimkin N.N. Kompleksnyu mnogotselovoy monitoring gruppy avtonomnykh transportnykh sredstv [Integrated multi-purpose monitoring by a group of autonomous vehicles], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2019, No. 7 (209), pp. 82-92. DOI 10.23683/2311-3103-2019-7-82-92.
20. Kazakov K.A., Semenov V.A. Obzor sovremennykh metodov planirovaniya puti [Review of modern path planning methods], *Tr. ISP RAN* [Proceedings of ISP RAS], 2016, Vol. 28, No. 4, pp. 241-294.

**Данильченко Владислав Иванович** – Южный федеральный университет; e-mail: vdanielchenko@sfedu.ru; г. Таганрог, Россия, тел.: 88634371651; кафедра систем автоматизированного проектирования им. В.М. Курейчика; доцент.

**Бова Виктория Викторовна** – Южный федеральный университет; e-mail: vbova@sfedu.ru; г. Таганрог, Россия, тел.: 88634371651; кафедра систем автоматизированного проектирования им. В.М. Курейчика; доцент.

**Danilchenko Vladislav Ivanovich** – Southern Federal University; e-mail: vdanielchenko@sfedu.ru; Taganrog, Russia; phone: +78634371651; V.M. Kureichik Computer-Aided Design Systems Department; associate professor.

**Bova Victoria Viktorovna** – Southern Federal University; e-mail: vbova@sfedu.ru; Taganrog, Russia; phone: +78634371651; V.M. Kureichik Computer-Aided Design Systems Department; associate professor.

УДК 519.711

DOI 10.18522/2311-3103-2025-6-276-287

**Б.А. Комаров, С.В. Леонов, Т.Е. Мамонова**

### **НЕЙРОСЕТЕВАЯ АППРОКСИМАЦИЯ МОДЕЛЬНО-ПРОГНОЗИРУЮЩЕГО УПРАВЛЕНИЯ ДЛЯ СИСТЕМЫ СТАБИЛИЗАЦИИ ДИНАМИЧЕСКОГО ОБЪЕКТА**

**Актуальность.** При решении задач стабилизации динамических объектов достаточно широко применяется классическое модельно-прогнозирующее управление. Оно обеспечивает высокое качество управления за счёт решения задачи оптимизации на каждом шаге, однако обладает значительными вычислительными затратами, что ограничивает его применение в системах реального времени с высокими требованиями к частоте обновления. Поэтому вопрос исследования применимости нейросетевого регулятора, обученного на модельно-прогнозирующем регуляторе (МРС) при решении задачи стабилизации положения динамического объекта при ограниченном вычислительном и временном ресурсе является актуальной. **Цель.** Целью представленной работы было разработать и исследовать нейросетевой регулятор, обученный на основе МРС-регулятора, для стабилизации положения динамического объекта на подвижной платформе. **Методы.** При выполнении работы использовались методы системного анализа, имитационного моделирования, а также экспериментальные испытания на стенде. **Результаты и выводы.** В рамках исследования разработан и обучен нейросетевой регулятор, аппроксимирующий поведение МРС на основе данных, полученных при управлении реальной балансировочной платформой. Обучение проводилось по входным и выходным данным МРС без использования внутренней модели системы, что позволило воспроизвести динамику регулятора при существенно меньших вычислительных затратах. Экспериментальные результаты показали, что нейросетевая модель обеспечивает качество стабилизации, сопоставимое с оригинальным МРС, при этом время вычислений сократилось с 47 мс до 1.6 мс, что составило значение ускорения в 29 раз. Предложенный подход демонстрирует потенциал нейросетевых методов управления в задачах замещения сложных оптимизационных регуляторов для систем с ограниченными вычислительными ресурсами.

*Нейросетевой регулятор; модельно-прогнозирующее управление (МРС); стабилизация положения; балансировочная платформа; аппроксимация МРС; оптимизация управления.*