

УДК 519.6  
DOI 10.17513/snt.40738



## АДАПТИВНОЕ УПРАВЛЕНИЕ ГЕНЕТИЧЕСКИМ АЛГОРИТМОМ НА ОСНОВЕ ОБУЧЕНИЯ С ПОДКРЕПЛЕНИЕМ С КОНТРОЛИРУЕМЫМ ПОПОЛНЕНИЕМ ПОПУЛЯЦИИ

**Привалов К. С. ORCID ID 0009-0001-5843-2944,  
Хорт Д. О. ORCID ID 0000-0001-6503-0065**

*Федеральное государственное образовательное бюджетное учреждение высшего образования  
«Финансовый университет при Правительстве Российской Федерации», Москва,  
Российская Федерация, e-mail: qqstik@gmail.com*

Эффективность генетических алгоритмов при решении задач глобальной оптимизации в значительной степени определяется способом управления ходом поиска. Использование фиксированных параметров операторов часто приводит к снижению разнообразия популяции и ухудшению качества получаемых решений. Целью исследования является разработка метода адаптивного управления эволюционным поиском, в котором выбор параметров генетического алгоритма и интенсивность пополнения популяции новыми особями определяются автоматически на основе анализа текущего состояния поиска. Предлагаемый подход учитывает изменение лучшего значения целевой функции, характеристики распределения приспособленности в популяции, уровень ее разнообразия и признаки стагнации. На основе этих данных формируется управляющее воздействие, задающее вероятность мутации, вероятность кроссовера и долю особей, подлежащих замене новыми решениями. В работе использован двухэтапный вычислительный эксперимент, включающий предварительное обучение агента глубокого обучения с подкреплением и последующую независимую оценку эффективности обученной стратегии. Проверка метода выполнена на наборе тестовых функций многомерной оптимизации, включающем сферическую функцию, функцию Розенброка, функцию Растригина и функцию Экли. Результаты исследования показали, что предложенный метод обеспечивает улучшение средних итоговых результатов по сравнению с классическим генетическим алгоритмом на большинстве рассмотренных функций. Наиболее выраженный эффект наблюдается на функции Розенброка, где дополнительное управление пополнением популяции позволяет поддерживать более устойчивую динамику поиска. Полученные результаты подтверждают перспективность использования глубокого обучения с подкреплением для адаптивного управления эволюционным поиском и поддержания разнообразия популяции.

**Ключевые слова:** генетический алгоритм, обучение с подкреплением, управление параметрами генетического алгоритма, адаптивное управление эволюционным поиском, глобальная оптимизация

## REINFORCEMENT LEARNING BASED CONTROL OF EVOLUTIONARY SEARCH WITH CONTROLLED POPULATION REFILL IN A GENETIC ALGORITHM

**Privalov K. S. ORCID ID 0009-0001-5843-2944,  
Khort D. O. ORCID ID 0000-0001-6503-0065**

*Federal State Educational Budgetary Institution of Higher Education  
“Financial University under the Government of the Russian Federation”,  
Moscow, Russian Federation, e-mail: qqstik@gmail.com*

The efficiency of genetic algorithms in solving global optimization problems largely depends on the way the search process is controlled. The use of fixed operator parameters often leads to a loss of population diversity and a decrease in the quality of the obtained solutions. The aim of this study is to develop a method for adaptive control of evolutionary search in which the parameters of the genetic algorithm and the intensity of population replenishment with new candidate solutions are determined automatically on the basis of the current search state. The proposed approach takes into account changes in the best objective function value, the characteristics of fitness distribution in the population, the level of population diversity, and signs of stagnation. On the basis of these data, a control action is formed that determines the mutation probability, the crossover probability, and the proportion of the population to be replaced with new solutions. A two-stage computational experiment was used in the study, including preliminary training of a deep reinforcement learning agent and subsequent independent evaluation of the learned strategy. The method was evaluated on a set of multidimensional optimization test functions, including the Sphere function, the Rosenbrock function, the Rastrigin function, and the Ackley function. The results showed that the proposed method improves the average final results in comparison with the classical genetic algorithm for most of the considered functions. The most pronounced effect was observed for the Rosenbrock function, where additional control of population replenishment provided a more stable search dynamic. The obtained results confirm the prospects of using deep reinforcement learning for adaptive control of evolutionary search and for maintaining population diversity.

**Keywords:** genetic algorithm, adaptive control of evolutionary search, reinforcement learning, control of genetic algorithm parameters, global optimization

### Введение

Задачи глобальной оптимизации, возникающие в математическом моделировании, численных методах и прикладных вычислениях, характеризуются высокой размерностью, сложным рельефом целевой функции и наличием множества локальных экстремумов. В таких условиях широкое распространение получили эволюционные методы поиска, в частности генетические алгоритмы, благодаря их универсальности, слабой зависимости от аналитических свойств целевой функции и способности работать в условиях многоэкстремальности [1, с. 44–54; 2, с. 1–18]. Вместе с тем эффективность генетического алгоритма в значительной степени определяется выбором параметров операторов и режимом организации поиска на различных этапах эволюции.

Одной из наиболее существенных проблем классического генетического алгоритма остается преждевременная сходимость, проявляющаяся в быстром снижении разнообразия популяции и последующей стабилизации поиска в области локального экстремума. Эта проблема особенно заметна при решении многомерных задач непрерывной оптимизации, где фиксированные значения вероятностей мутации и кроссовера оказываются недостаточно универсальными: параметры, способствующие интенсивному исследованию пространства решений на начальных этапах, нередко оказываются неэффективными на стадии локального уточнения, и наоборот [1, с. 89–124; 2, с. 62–70]. В связи с этим важным направлением развития эволюционных методов является адаптивное управление процессом поиска, при котором параметры алгоритма изменяются в зависимости от текущего состояния популяции.

В современной литературе представлены различные подходы к адаптации параметров эволюционных алгоритмов. Наиболее распространены схемы динамической настройки вероятностей мутации и кроссовера, а также методы выбора операторов поиска на основе анализа текущей эффективности эволюционного процесса [3; 4]. В последнее время особое внимание уделяется применению обучения с подкреплением, в рамках которого эволюционный поиск рассматривается как управляемая динамическая система, а стратегия изменения параметров формируется агентом на основе последовательности состояний, действий и получаемых вознаграждений [5, с. 1–10]. Такой подход позволяет перейти от фиксированных или эвристически заданных правил настройки к выработке адаптивной стратегии управления, учитывающей историю поиска и текущий прогресс по целевой функции.

Дополнительный интерес представляет использование глубокого обучения с подкреплением, в частности архитектур глубокого Q-обучения, позволяющих отказаться от жесткой дискретизации пространства состояний и перейти к работе с более информативным набором признаков, описывающих состояние популяции. Применение модификаций глубокого Q-обучения, ориентированных на повышение устойчивости оценки ценности действий, расширяет возможности построения интеллектуальных контуров управления эволюционным поиском [6; 7]. Однако даже в таких постановках объект управления чаще всего ограничивается только вероятностями кроссовера и мутации, тогда как проблема поддержания разнообразия популяции обычно решается отдельно, с помощью заранее заданных эвристик.

Для сопоставимой оценки эффективности методов глобальной оптимизации в литературе широко используются стандартные тестовые функции, различающиеся структурой рельефа целевой поверхности, размерностью и сложностью поиска глобального минимума [8]. Применение такого набора функций позволяет исследовать поведение алгоритма как на сравнительно простых задачах, так и на сложных многоэкстремальных функциях, требующих поддержания баланса между исследованием пространства решений и локальным уточнением найденных областей.

Дополнительный интерес в этой связи представляет проблема сохранения разнообразия популяции в процессе эволюционного поиска. В работах, посвященных оптимизации многоэкстремальных функций, отмечается, что снижение разнообразия популяции является одной из основных причин преждевременной сходимости. Для повышения устойчивости поиска применяются ансамблевые и гибридные схемы, а также специальные механизмы поддержания разнообразия популяции [9–11]. Отдельно исследуются методы динамической коррекции области поиска [12]. Однако в большинстве таких подходов поддержание разнообразия реализуется по заранее заданным правилам и не рассматривается как самостоятельный объект адаптивного управления.

В опубликованных и подготовленных ранее работах автора последовательно рассматривались подходы к адаптивному управлению параметрами генетического алгоритма на основе искусственных нейронных сетей, табличного Q-обучения и глубокого обучения с подкреплением [13; 14]. Эти исследования показали перспективность интеллектуального регулирования вероятностей мутации и кроссовера, однако также вы-

явили, что при длительном поиске и на сложных многоэкстремальных функциях одного лишь параметрического управления нередко оказывается недостаточно для устойчивого предотвращения стагнации. Это указывает на необходимость расширения контура управления и включения в него механизмов, непосредственно воздействующих на уровень разнообразия популяции.

Научная новизна исследования состоит в разработке метода адаптивного управления эволюционным поиском, в котором агент глубокого обучения с подкреплением формирует управляющее воздействие одновременно по трем компонентам: вероятности мутации, вероятности кроссовера и доле популяции, подлежащей замене новыми решениями. В отличие от ранее рассмотренных схем, предлагаемый подход ориентирован не только на улучшение текущего значения целевой функции, но и на предотвращение деградации поискового процесса за счет контролируемого восстановления разнообразия популяции. Это позволяет рассматривать предлагаемый метод как развитие ранее исследованных автором моделей управления генетическим алгоритмом.

**Целью работы** является разработка и исследование метода адаптивного управления процессом эволюционного поиска в генетическом алгоритме на основе глубокого обучения с подкреплением, обеспечивающего совместное регулирование параметров вариации и интенсивности частичной реинициализации популяции. Для достижения поставленной цели в статье предполагается решить следующие задачи: сформировать математическую модель управляемого эволюционного поиска; определить состав признаков состояния популяции, используемых агентом; задать пространство управляющих воздействий и функцию вознаграждения; реализовать программный прототип метода; провести вычислительные эксперименты на наборе тестовых функций многомерной оптимизации, различающихся структурой рельефа и сложностью поиска глобального минимума.

Практическая значимость работы определяется возможностью применения предложенного подхода в задачах численной оптимизации, где требуется автоматическое управление балансом между исследованием пространства решений и локальным уточнением найденных областей. В отличие от схем с фиксированными параметрами и от методов, в которых поддержание разнообразия задается заранее, предлагаемый метод ориентирован на ситуационное изменение режима поиска, что особенно важно для сложных многоэкстремальных задач и прикладных постановок с признаками стагнации.

## Материалы и методы исследования

В работе рассматривается задача минимизации целевой функции

$$\min_{x \in \Omega} F(x),$$

где  $x = (x_1, x_2, \dots, x_n)$  – вектор искомым параметров,  $\Omega \subset \mathbb{R}^n$  – допустимая область поиска,  $F(x)$  – целевая функция. Для решения задачи используется генетический алгоритм, в котором процесс эволюционного поиска рассматривается как управляемая динамическая система.

В отличие от классического генетического алгоритма с фиксированными параметрами, в предлагаемом подходе значения вероятности мутации, вероятности кроссовера и интенсивности пополнения популяции новыми особями изменяются адаптивно в зависимости от текущего состояния поиска. Такой подход направлен на повышение устойчивости поиска и снижение вероятности преждевременной сходимости к локальным экстремумам [1, с. 89–124; 2, с. 62–70].

Состояние алгоритма на итерации  $t$  описывается вектором

$$s_t = \left( F_{\min}^{(t)}, \bar{F}^{(t)}, \sigma_F^{(t)}, D^{(t)}, \Delta^{(t)}, L^{(t)} \right),$$

где  $F_{\min}^{(t)}$  – лучшее значение целевой функции в популяции,  $\bar{F}^{(t)}$  – среднее значение,  $\sigma_F^{(t)}$  – стандартное отклонение значений целевой функции,  $D^{(t)}$  – показатель разнообразия популяции,  $\Delta^{(t)}$  – относительное улучшение лучшего решения за шаг,  $L^{(t)}$  – счетчик стагнации. Включение в описание состояния характеристик разнообразия и стагнации позволяет учитывать не только текущее качество найденных решений, но и общую динамику эволюционного процесса.

Управляющее воздействие формируется агентом глубокого обучения с подкреплением и задается в виде

$$a_t = \left( p_m^{(t)}, p_c^{(t)}, r^{(t)} \right),$$

где  $p_m^{(t)}$  – вероятность мутации,  $p_c^{(t)}$  – вероятность кроссовера,  $r^{(t)}$  – доля популяции, подлежащая замене новыми особями. Тем самым в контур управления включаются не только параметры генетических операторов, но и механизм поддержания разнообразия популяции. Это отличает предлагаемый подход от схем адаптивного управления, в которых регулировались только вероятности мутации и кроссовера [3; 4]. Близкие постановки ранее рассматривались в работах автора [13; 14], а смежные гибридные подходы к развитию генетических алгоритмов представлены и в других исследованиях [15].

Таблица 1

Параметры вычислительного эксперимента

Тестовая функция	$n$	Интервал	$N$	$T$	Эпизоды обучения DQN2	Эпизоды обучения DQN3R	Запуски
Сферическая функция	20	[-100; 100]	50	100	150	200	20
Функция Розенброка	20	[-30; 30]	50	100	150	200	20
Функция Растргина	20	[-5,12; 5,12]	50	100	150	200	20
Функция Экли	20	[-32,768; 32,768]	50	100	150	200	20

Примечание: составлена авторами на основе полученных данных в ходе исследования.

Для выбора управляющего воздействия используется нейросетевая аппроксимация функции ценности действий

$$Q(s_t, a_t, \theta),$$

где  $\theta$  – параметры модели. После выполнения действия  $a_t$  – генетический алгоритм переходит в новое состояние  $s_{t+1}$ , а агент получает вознаграждение, зависящее от улучшения значения целевой функции и текущего уровня разнообразия популяции. В общем виде функция вознаграждения может быть записана следующим образом

$$R_t = \alpha (F_{min}^{(t-1)} - F_{min}^{(t)}) + \beta D^{(t)} - \gamma I_{stag}^{(t)},$$

где  $\alpha, \beta, \gamma$  – весовые коэффициенты,  $I_{stag}^{(t)}$  – индикатор стагнации. Такая функция ориентирует агент на достижение двух взаимосвязанных целей: улучшение качества решений и предотвращение деградации популяции.

Ключевой особенностью метода является механизм контролируемого пополнения популяции. Если выбранное значение  $r^{(t)} > 0$ , то часть особей с наихудшими значениями целевой функции заменяется новыми решениями, случайно сгенерированными в допустимой области поиска. Число заменяемых особей определяется выражением

$$K^{(t)} = r^{(t)} N,$$

где  $N$  – размер популяции. Такая процедура представляет собой частичную реинициализацию популяции и применяется не по фиксированному правилу, а в зависимости от текущего состояния поиска. Это позволяет адаптивно восстанавливать разнообразие популяции при появлении признаков стагнации. Современные исследования подтверждают, что повышение эффективности эволюционного поиска связано с развитием обобщенных подходов к адаптивному управлению параметрами и меха-

низмов поддержания разнообразия популяции [16–18]. Кроме того, существенную роль играет интеграция обучения с подкреплением в структуру метаэвристических алгоритмов [19; 20]. С учетом этих подходов вычислительный эксперимент проводился в два этапа. На первом этапе выполнялось предварительное обучение агента глубокого обучения с подкреплением на серии эпизодов, сформированных на тестовых функциях глобальной оптимизации. На втором этапе проводилась независимая оценка эффективности обученных стратегий без дополнительного обучения в процессе тестового запуска. Сравнение выполнялось для трех вариантов алгоритма: классического генетического алгоритма, алгоритма с предвременно обученным агентом адаптивного управления вероятностями мутации и кроссовера, а также предлагаемого метода, в котором дополнительно регулируется интенсивность контролируемого пополнения популяции новыми особями. Для всех алгоритмов использовались одинаковые значения размера популяции, числа поколений и диапазонов изменения переменных (табл. 1). Оценка результатов выполнялась по среднему финальному лучшему значению целевой функции, стандартному отклонению результатов, лучшему значению за прогон и динамике изменения разнообразия популяции.

#### Результаты исследования и их обсуждение

Результаты вычислительных экспериментов представлены в табл. 2. Сравнение выполнялось для классического генетического алгоритма, алгоритма с предвременно обученным агентом адаптивного управления вероятностями мутации и кроссовера и предлагаемого метода, в котором дополнительно регулируется интенсивность контролируемого пополнения популяции новыми особями.

Таблица 2

Результаты сравнения алгоритмов на тестовых функциях глобальной оптимизации

Тестовая функция	Алгоритм	Среднее финальное лучшее значение	Стандартное отклонение
Сферическая функция	GA	4978,49	1981,78
Сферическая функция	GA+DQN2	4165,27	1384,89
Сферическая функция	GA+DQN3R	3919,82	1177,76
Функция Розенброка	GA	289304,41	253314,27
Функция Розенброка	GA+DQN2	256804,16	178957,01
Функция Розенброка	GA+DQN3R	101306,48	128227,11
Функция Растригина	GA	58,32	14,29
Функция Растригина	GA+DQN2	57,99	7,86
Функция Растригина	GA+DQN3R	56,86	13,33
Функция Экли	GA	14,38	2,20
Функция Экли	GA+DQN2	12,52	3,48
Функция Экли	GA+DQN3R	14,19	2,31

Примечание: составлена авторами на основе полученных данных в ходе исследования.

Анализ полученных данных показывает, что предварительное обучение агента позволяет повысить эффективность адаптивного управления эволюционным поиском по сравнению с классическим генетическим алгоритмом. Вариант GA+DQN2 обеспечивает улучшение средних результатов на всех рассмотренных тестовых функциях по отношению к базовому генетическому алгоритму. Это свидетельствует о том, что использование заранее обученной стратегии выбора вероятности мутации и вероятности кроссовера является более эффективным, чем применение фиксированных параметров на всем протяжении поиска.

Предлагаемый метод GA+DQN3R, в котором дополнительно осуществляется адаптивное управление пополнением популяции новыми особями, показал наилучшие средние результаты на трех из четырех исследованных функций. Наиболее выраженное преимущество наблюдается на функции Розенброка, где среднее финальное значение целевой функции оказалось существенно ниже, чем у классического генетического алгоритма и у варианта с управлением только вероятностями мутации и кроссовера. Аналогичная тенденция наблюдается на сферической функции и функции Растригина, хотя в последнем случае выигрыш носит более умеренный характер.

На функции Экли лучшим оказался вариант GA+DQN2, тогда как метод GA+DQN3R уступил ему, сохранив при этом преимущество по отношению к классическому генетическому алгоритму. Это позволяет сделать

вывод о том, что эффективность механизма контролируемого пополнения популяции зависит от структуры ландшафта целевой функции и характера эволюционной динамики. В отдельных задачах дополнительное вмешательство в состав популяции способствует более эффективному поиску, тогда как в других случаях управление только вероятностями мутации и кроссовера оказывается недостаточным.

На рис. 1 представлена средняя динамика сходимости алгоритмов на функции Розенброка. Из графика следует, что предлагаемый метод обеспечивает более быстрое снижение значения целевой функции на основных этапах поиска и сохраняет преимущество вплоть до завершения вычислительного процесса. Это позволяет говорить о более эффективной организации поиска в условиях сложного рельефа целевой поверхности.

На рис. 2 показана средняя динамика разнообразия популяции на функции Розенброка. Видно, что метод GA+DQN3R поддерживает более высокий уровень разнообразия популяции по сравнению с классическим генетическим алгоритмом и вариантом GA+DQN2. При этом среднее значение параметра, отвечающего за пополнение популяции, остается небольшим, что указывает на корректирующий, а не агрессивный характер применения данного механизма. Иными словами, пополнение популяции используется не как постоянный источник случайного обновления, а как средство адаптивного противодействия стагнации поиска.

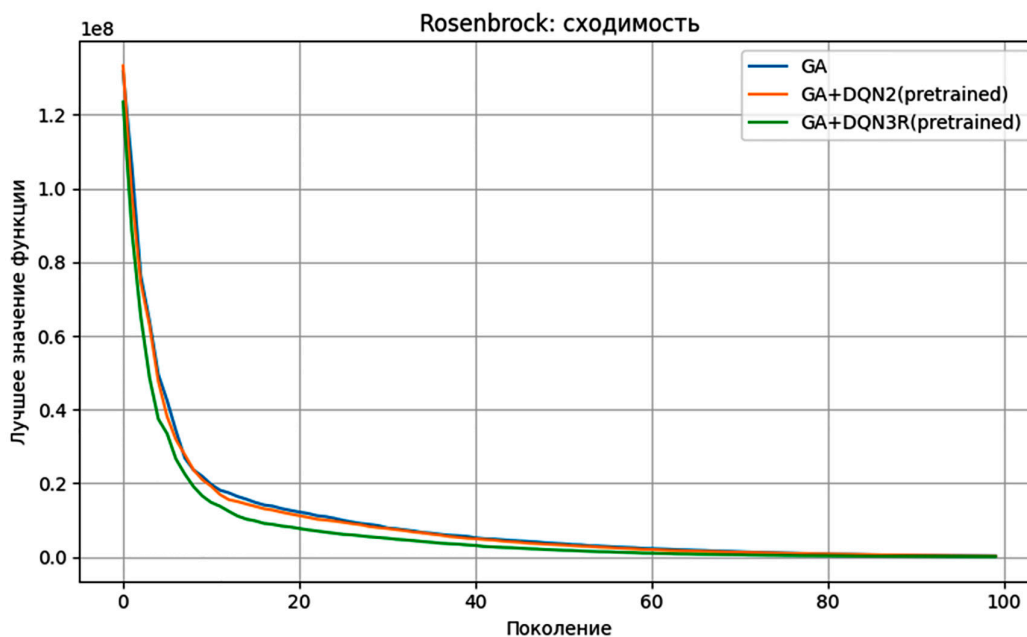


Рис. 1. Средняя динамика сходимости алгоритмов на функции Розенброка  
Примечание: составлена авторами по результатам данного исследования

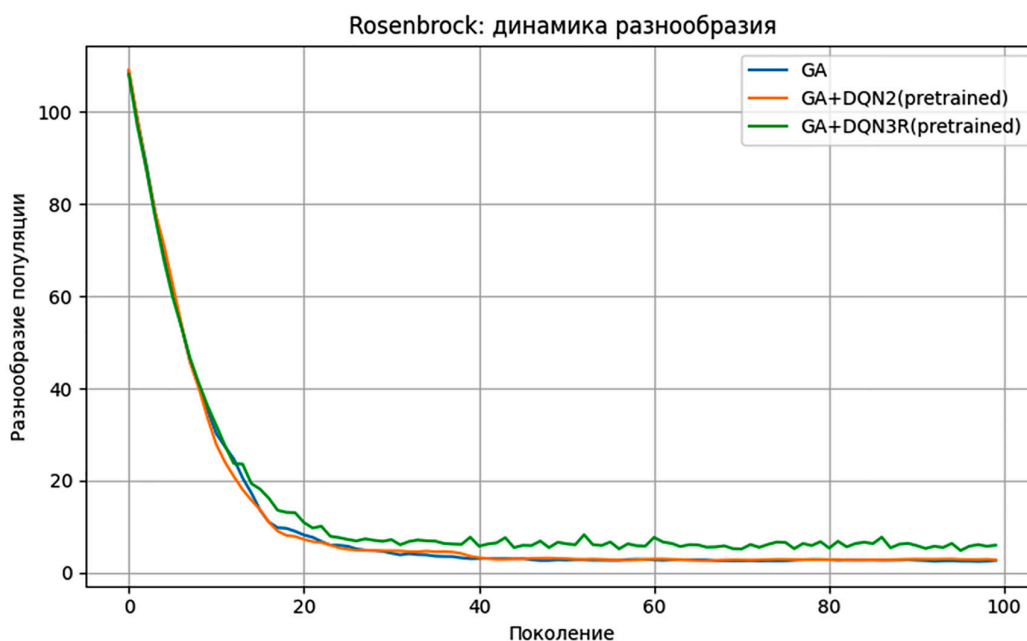


Рис. 2. Средняя динамика разнообразия популяции на функции Розенброка  
Примечание: составлен авторами по результатам данного исследования

Таким образом, полученные результаты подтверждают, что предварительно обученный агент глубокого обучения с подкреплением может быть использован для эффективного адаптивного управления эволюционным поиском. Дополнительное управление пополнением популяции новыми особями в большинстве рассмотренных случаев приводит к улучшению итоговых

результатов и повышению устойчивости поиска, хотя степень его эффективности определяется особенностями решаемой задачи.

### Заключение

В работе предложен метод адаптивного управления эволюционным поиском в генетическом алгоритме на основе предварительно обученного агента глубокого обуче-

ния с подкреплением. В отличие от схем, в которых регулируются только вероятности мутации и кроссовера, в предлагаемом подходе в контур управления дополнительно включен механизм контролируемого пополнения популяции новыми особями. Это позволяет учитывать не только текущую динамику изменения целевой функции, но и состояние разнообразия популяции.

Результаты вычислительных экспериментов показали, что использование предварительно обученного агента повышает эффективность управления параметрами генетического алгоритма по сравнению с классической схемой с фиксированными параметрами. Предлагаемый метод с управлением пополнением популяции продемонстрировал наилучшие средние результаты на большинстве исследованных тестовых функций. Наиболее выраженный эффект наблюдался на функции Розенброка, где дополнительное поддержание разнообразия популяции обеспечило более устойчивую динамику поиска и более высокое качество итоговых решений.

Вместе с тем результаты на функции Экли показали, что эффективность механизма контролируемого пополнения популяции зависит от структуры целевой поверхности и требует дальнейшей настройки стратегии его активации. Перспективы дальнейшего исследования связаны с совершенствованием механизма принятия решений о пополнении популяции, расширением набора тестовых задач и исследованием применимости разработанного подхода к прикладным задачам численной оптимизации.

### Список литературы

1. Holland J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor: University of Michigan Press, 1975. 183 p. ISBN 0-472-08460-7.
2. Goldberg D. E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Reading, MA: Addison-Wesley, 1989. 412 p. ISBN: 0-201-15767-5.
3. Eiben A. E., Hinterding R., Michalewicz Z. Parameter control in evolutionary algorithms // *IEEE Transactions on Evolutionary Computation*. 1999. Vol. 3. № 2. P. 124–141. DOI: 10.1109/4235.771166.
4. Karafotias G., Hoogendoorn M., Eiben A. E. Parameter Control in Evolutionary Algorithms: Trends and Challenges // *IEEE Transactions on Evolutionary Computation*. 2015. Vol. 19. № 2. P. 167–187. DOI: 10.1109/TEVC.2014.2308294.
5. Sutton R. S., Barto A. G. *Reinforcement Learning: An Introduction*. 2nd ed. Cambridge, MA: The MIT Press, 2018. 552 p. ISBN: 978-0-262-03924-6.
6. van Hasselt H., Guez A., Silver D. Deep Reinforcement Learning with Double Q-Learning // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2016. Vol. 30. № 1. P. 2094–2100. DOI: 10.1609/aaai.v30i1.10295.
7. Wang Z., Schaul T., Hessel M., van Hasselt H., Lanctot M., de Freitas N. Dueling Network Architectures for Deep Reinforcement Learning // *Proceedings of the 33rd International Conference on Machine Learning*. 2016. P. 1995–2003.
8. Jamil M., Yang X.-S. A Literature Survey of Benchmark Functions for Global Optimization Problems // *International Journal of Mathematical Modelling and Numerical Optimisation*. 2013. Vol. 4. № 2. P. 150–194. DOI: 10.1504/IJMMNO.2013.055204.
9. Масленников В. В., Демидова Л. А. Модификация квантово-инспирированного генетического алгоритма численной оптимизации с использованием кудита в условиях имитации квантовой декогеренции // *Computational nanotechnology*. 2024. Т. 11. № 2. С. 58–85. DOI: 10.33693/2313-223X-2024-11-2-58-85. EDN: MRWGYA.
10. Сопов Е. А., Аплеснин С. С. Самоконфигурируемый ансамбль генетических алгоритмов для решения задач мультиэволюционной оптимизации // *Сибирский аэрокосмический журнал*. 2015. Т. 16. № 4. С. 833–841. EDN: VDMGFR.
11. Курейчик В. В., Родзин С. И. Модель коллаборативного поведения роя саранчи для оптимизации многомерных мультиэкстремальных функций // *Известия вузов. Северо-Кавказский регион. Технические науки*. 2023. № 1. С. 10–16. DOI: 10.17213/1560-3644-2023-1-10-16.
12. Малашин И. П., Тынченко В. С. Применение методов кластерного анализа для динамической коррекции области поиска в генетическом алгоритме // *Сибирский аэрокосмический журнал*. 2025. Т. 26. № 3. С. 318–333. DOI: 10.31772/2712-8970-2025-26-3-318-333.
13. Привалов К. С. Гибридные методы оптимизации: адаптивное управление эволюционным процессом с использованием искусственных нейронных сетей // *Инженерный вестник Дона*. 2025. № 3. URL: <http://www.ivdon.ru/magazine/archive/n3y2025/9910> (дата обращения: 06.04.2026).
14. Привалов К. С. Обучение с подкреплением в адаптивном управлении параметрами генетического алгоритма // *Инженерный вестник Дона*. 2025. № 8. URL: <http://www.ivdon.ru/magazine/archive/n8y2025/10315> (дата обращения: 06.04.2026).
15. Roeva O., Zoteva D., Roeva G., Ignatova M., Lyubenova V. An Effective Hybrid Metaheuristic Approach Based on the Genetic Algorithm // *Mathematics*. 2024. Vol. 12. № 23. Art. 3815. DOI: 10.3390/math12233815.
16. de Lacerda M. G. P., de Araujo Pessoa L. F., Buarque de Lima Neto F., Ludermir T. B., Kuchen H. A systematic literature review on general parameter control for evolutionary and swarm-based algorithms // *Swarm and Evolutionary Computation*. 2021. Vol. 60. 100777. DOI: 10.1016/j.swevo.2020.100777.
17. Araujo J. N. R., Batista L. S. A diversity-driven migration strategy for distributed evolutionary algorithms // *Swarm and Evolutionary Computation*. 2023. Vol. 82. Is. 1. 101361. DOI: 10.1016/j.swevo.2023.101361.
18. Lin X., Meng Z. An adaptative differential evolution with enhanced diversity and restart mechanism // *Expert Systems with Applications*. 2024. Vol. 249. Is. 5. 123634. DOI: 10.1016/j.eswa.2024.123634.
19. Song Y., Wu Y., Guo Y., Yan R., Suganthan P. N., Zhang Y., Pedrycz W., Das S., Mallipeddi R., Solomon O., Feng Q. Reinforcement learning-assisted evolutionary algorithm: A survey and research opportunities // *Swarm and Evolutionary Computation*. 2024. Vol. 86. Is. 11. 101517. DOI: 10.1016/j.swevo.2024.101517.
20. Liang P., Chen Y., Sun Y., Huang Y., Li W. An information entropy-driven evolutionary algorithm based on reinforcement learning for many-objective optimization // *Expert Systems with Applications*. 2024. Vol. 238. Part E. 122164. DOI: 10.1016/j.eswa.2023.122164.

**Конфликт интересов:** Авторы заявляют об отсутствии конфликта интересов.

**Conflict of interest:** The authors declare that there is no conflict of interest.

**Финансирование:** Авторы заявляют об отсутствии внешнего финансирования.

**Financing:** The research was performed without external funding.