

© 2024 г. М. СОХРАБИ (msohrabi@hse.ru)
(Национальный исследовательский университет
“Высшая школа экономики”, Москва)

А.М. ФАТХОЛЛАХИ-ФАРД (fathollahifard.amirmohammad@courrier.uqam.ca)
(Университет Квебека в Монреале, Канада),

В.А. ГРОМОВ (stroller@rambler.ru)
(Национальный исследовательский университет
“Высшая школа экономики”, Москва)

АЛГОРИТМ ГЕНЕТИЧЕСКОЙ ИНЖЕНЕРИИ (GEA): ЭФФЕКТИВНЫЙ МЕТАЭВРИСТИЧЕСКИЙ АЛГОРИТМ ДЛЯ РЕШЕНИЯ ЗАДАЧ КОМБИНАТОРНОЙ ОПТИМИЗАЦИИ¹

Генетические алгоритмы (ГА) известны своей эффективностью в решении задач комбинаторной оптимизации благодаря их способности исследовать разнообразные пространства решений, обрабатывать различные представления, использовать параллелизм, сохранять хорошие решения, адаптироваться к изменяющимся условиям, управлять комбинаторным разнообразием и проводить эвристический поиск. Тем не менее такие ограничения, как преждевременная сходимость, неспецифичность и стохастичность операторов кроссовера и мутации, делают ГА не всегда эффективными при нахождении глобального оптимума. Чтобы преодолеть эти недостатки, в данной статье предлагается новый метаэвристический алгоритм, названный алгоритмом генетической инженерии (GEA), вдохновленный концепциями геной инженерии. GEA модифицирует традиционный ГА, включая новые методы поиска для выделения, коррекции, вставки и экспрессии новых генов на основе существующих, что способствует появлению желаемых признаков и производству хромосом на основе выбранных генов. Сравнение с результатами работы других алгоритмов на стандартных примерах демонстрирует эффективность GEA.

Ключевые слова: генетический алгоритм, метаэвристические алгоритмы, геной инженерия, комбинаторная оптимизация.

DOI: 10.31857/S0005231024030027, **EDN:** UAGNKK

1. Введение

Задачи комбинаторной оптимизации, относящиеся к классу NP-сложных, требуют эффективных алгоритмов для поиска оптимальных или близких к оптимальным решений. Генетические алгоритмы (ГА) [1] здесь популярны

¹ Данная работа является результатом исследовательского проекта, реализованного в рамках программы фундаментальных исследований Национального исследовательского университета “Высшая школа экономики” (НИУ ВШЭ). Исследование выполнено с использованием суперкомпьютерного комплекса НИУ ВШЭ [27]. Хотелось бы отметить, что публикации профессора Мостафа Хаджиагайи-Кештели вдохновили авторов на разработку нового метаэвристического алгоритма.

благодаря их способности исследовать разные области пространства решений и адаптироваться к изменяющейся динамике. Однако ограничения ГА, включающие вычислительную сложность, преждевременную сходимость, недостаточный учет информации о конкретной задаче и необходимость тонкой настройки параметров, предполагают поиск новых подходов [2]. Эти недостатки стимулируют попытки авторов перепроектировать ГА, используя концепцию генной инженерии, чтобы сделать его более эффективным для решения задач комбинаторной оптимизации.

ГА являются одними из самых первых алгоритмов, предназначенных для нахождения удовлетворительных решений за разумные сроки вычислений, а не только на нахождение оптимальности [3]. Несмотря на наличие множества других метаэвристических алгоритмов [4–18], следует отметить, что литература по ГА весьма обширна, она включает множество исследований, представляющих разнообразные варианты ГА с различными техниками генетического программирования и инженерии [19–27]. Например, в [28] проведено исследование, нацеленное на выявление полезного генетического материала и минимизацию присутствия вредных генетических компонентов, что привело к разработке нового варианта ГА. В [29] предложен подход, основанный на идее защиты “хороших” хромосом от нежелательных кроссоверов. В [30] исследовалась интеграция нейронной сети обратного распространения (BP) с ГА. В [31] разработана серия адаптивных элитарных популяционных стратегий, которые нашли применение в рамках генетических алгоритмов.

В [32] интегрирована стратегия балансировки нагрузки для облачных вычислений с ГА. В [33] проведено усовершенствование ГА путем внедрения нового многородительского оператора кроссовера. В [34] предложен улучшенный алгоритм DV-Нор на основе ГА, в то время как в [35] исследованы ГА, основанные на памяти. В [36] разработан гибридный ГА, сочетающийся с нечеткой логикой, а в [37] предложен гибрид ГА с другими новыми метаэвристическими алгоритмами. Кроме того, в [38] разработан модифицируемый генетический алгоритм с недоминируемой сортировкой, основанный на новых операторах поиска. В [39] представлен генетический алгоритм недоминируемой сортировки на основе локального поиска, адаптированный для решения задач маршрутизации в туристической индустрии. Однако ни одно из рассмотренных до сих пор исследований не предложило введение новых операторов поиска, основанных на наборе методов, направленных на изоляцию, очистку, вставку и экспрессию новых генов в существующие ГА-хромосомы, как в настоящем исследовании.

В последнее время для решения сложных задач оптимизации был предложен ряд новых популяционных алгоритмов. Здесь можно указать на алгоритмы поиска кукушки (Cuckoo Search, CS) [4], алгоритм оптимизации китов (Whale Optimization Algorithm, WOA) [5], синусно-косинусный алгоритм (Sine Cosine Algorithm, SCA) [6], оптимизацию ястребов Харриса (Harris Hawks Optimization, ННО) [7], алгоритм поиска белки (Squirrel Search Algorithm, SSA) [8], алгоритм красного оленя (Red Deer Algorithm,

RDA) [9], алгоритм поиска воробьев (Sparrow Search Algorithm, SSA) [10], алгоритм поиска капуцина (Capuchin Search Algorithm) [11], оптимизатор Aquila (Aquila Optimizer, AO) [12], алгоритм группы хамелеонов (Chameleon Swarm Algorithm, CSA) [13], оптимизация *Aptenodytes Forsteri* (AFO) [14], оптимизатор навозного жука (Dung Beetle Optimizer, DBO) [15], оптимизация белухи (Beluga Whale Optimization, BWO) [16] и др. Однако стоит отметить, что согласно теореме “Нет бесплатного обеда” [17] ни один метаэвристический алгоритм не может превзойти другие для всех задач оптимизации. Следовательно, существует постоянный спрос на разработку новых метаэвристических алгоритмов, способных увеличить производительность в различных проблемных областях [18].

В настоящей статье предложен новый метаэвристический алгоритм генетической инженерии (GEA), коррелирующий с принципами генной инженерии. Генная инженерия включает множество методов, применяемых для изоляции, очистки, вставки и экспрессии новых генов на базе существующих, что приводит к появлению желаемых признаков и хромосом на основе данного набора генов. На основе результатов из этой области в статье ставится цель переосмыслить процесс оптимизации и преодолеть ограничения, связанные с традиционными генетическими алгоритмами. Методы, применяемые в GEA, обеспечивают более точное управление процессом оптимизации, учитывают специфику рассматриваемой задачи и сокращают влияние случайности в операциях мутации и скрещивания. Введение концепции “манипуляция генами” в популяции направлено на более эффективный поиск в пространстве решений, что способствует улучшению сходимости и качества получаемых решений. Для оценки эффективности GEA были проведены широкомасштабные вычислительные эксперименты на ряде эталонных примеров; его производительность сравнивалась с другими метаэвристическими алгоритмами. Результаты указывают на высокую скорость сходимости алгоритма, качество получаемых им решений и его робастность, что подчеркивает его потенциал как нового и эффективного подхода к решению задач комбинаторной оптимизации.

Дальнейшее изложение организовано следующим образом: в разделе 2 представлены основные принципы алгоритма GEA. Раздел 3 посвящен деталям реализации GEA, включая описание операторов генной инженерии. В разделе 4 представлены описание проведенных вычислительных экспериментов и сравнительный анализ результатов работы GEA и других алгоритмов. Заключительный раздел 5 подводит итоги исследования и указывает на возможные направления будущих исследований.

2. Биологические основания алгоритма

В настоящее время генная инженерия (ГИ) перешла от теоретических исследований к практическим применениям. Этот подход продемонстрировал значительный потенциал в лечении различных заболеваний, например в им-

мунотерапии рака [19] и в технологии CRISPR для удаления вируса ВИЧ из геномов инфицированных клеток [20]. Методы генной инженерии оказывают влияние на генетику человека, меняя характеристики новорожденных [21], и обещают прорыв в сельском хозяйстве в создании высокоурожайных культур [22]. Разработка золотого риса, направленного на борьбу с дефицитом витамина А и предотвращение слепоты по всему миру, демонстрирует потенциал генной инженерии [23]. Точность в идентификации доминантных хромосом, отвечающих за урожайность растений, привела к созданию высокоурожайных видов, которые способствуют решению глобальных проблем, включая изменение климата, загрязнение окружающей среды и продовольственный дефицит [24].

Направленные мутации предполагают точные изменения ДНК в организмах с целью появления благоприятных изменений. Здесь специфические мутации вводятся в гены для стимулирования развития положительных признаков или подавления негативных. Разработка методов управления мутациями в генах, вызывающих болезни, позволяет создавать инновационные методы лечения генетических расстройств, таких как муковисцидоз и мышечная дистрофия. Для достижения этой цели необходимо выполнить два ключевых шага: идентификация ключевых генов и точное управление неинформативными генами [23, 25, 26].

Генная инъекция представляет собой новый подход, при котором терапевтические гены доставляются непосредственно в организм для лечения или профилактики заболеваний. Этот метод обладает перспективами в лечении таких заболеваний, как рак и сердечно-сосудистые расстройства. Введение генов, производящих терапевтические белки, позволяет ученым усиливать естественные защитные механизмы организма, стимулировать регенерацию тканей и оказывать целенаправленное воздействие на раковые клетки. Генная инъекционная терапия является значимым инструментом в области персонализированной медицины [25].

В заключение раздела отметим, что генная инженерия представляет собой революционное явление с многообразными приложениями в различных областях медицины, сельского хозяйства и охраны окружающей среды. Использование доминантных хромосом, направленных мутаций и идентификации необходимых генов позволяет сформировать генетические основы для выведения высокоурожайных сельскохозяйственных культур и разработки методов лечения заболеваний. Методы точного редактирования генов и генной инъекционной терапии позволяют достигать беспрецедентной точности и индивидуализации.

3. Предложенный метаэвристический алгоритм

ГА [1] представляет собой эволюционный алгоритм, использующий классические операторы мутации и скрещивания. В рамках данного исследования предложен новый подход, использующий методы генной инженерии (GE).

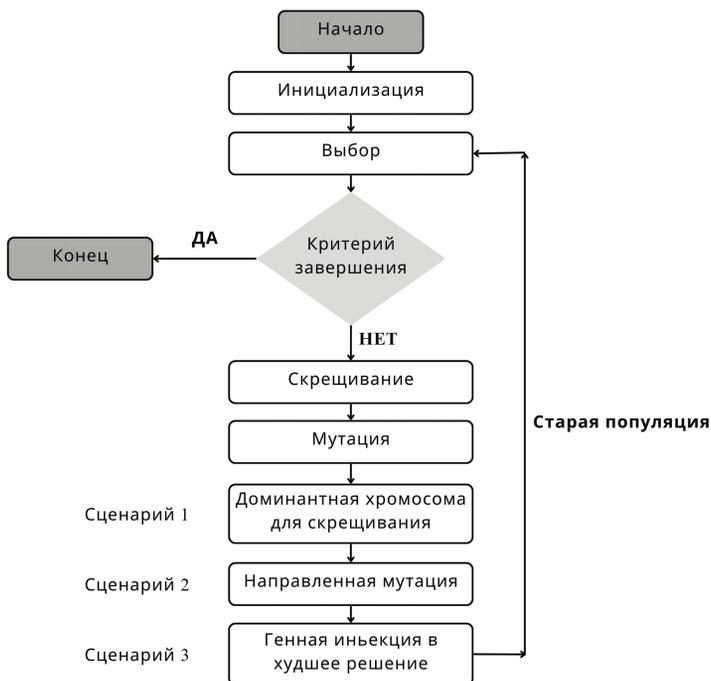


Рис. 1. Блок-схема предлагаемого ГЭА.

Общая блок-схема предлагаемого алгоритма (ГЭА) представлена на рис. 1. На приведенной схеме можно опустить любой оператор, от скрещивания до инъекции гена, с целью адаптации алгоритма к различным задачам и оценки эффективности метода при использовании части операторов. Подобно другим метаэвристикам ГЭА начинается с формирования начальной популяции. После формирования начальной популяции все особи оцениваются на основе специфичной для задачи функции приспособленности. Важно подчеркнуть, что каждая задача характеризуется уникальной функцией приспособленности, необходимой для представления решения в рамках эволюционного алгоритма. Например, в задаче маршрутизации хромосома определяется как последовательность посещений [2], в задачах планирования производственных процессов — как последовательность работ на машинах [18], в задаче о рюкзаке — с помощью бинарных переменных [3]. В ГЭА также предполагается, что хромосома бинарна, т.е. каждый ген может принимать значения ноль или один. В этом алгоритме, помимо операторов мутации и скрещивания, используются три оператора генной инженерии, представленные ниже в трех сценариях.

3.1. Сценарий 1

Поиск доминантной хромосомы для кроссовера (наиболее часто повторяющихся генов). Первый сценарий ГЭА направлен на выявление доминантной хромосомы, здесь учитываются только $p\%$ лучших особей в популяции. Зна-

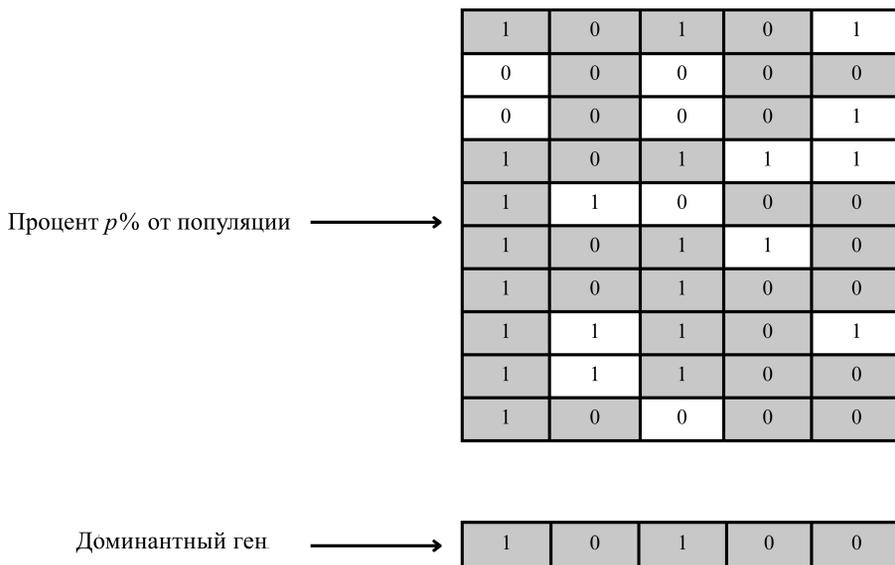


Рис. 2. Поиск доминантных генов в популяции $p\%$.

чение p задается пользователем до начала работы алгоритма и может быть оптимизировано с учетом специфики задачи. Хромосома считается доминантной, если она содержит наибольшее количество повторяющихся генов среди лучших $p\%$ особей. Процесс идентификации доминантных генов и формирования доминантной хромосомы описывается уравнениями (1) и (2). На рис. 2 представлен пример определения доминантной хромосомы; псевдокод данной операции представлен в алгоритме 1.

$$(1) \quad RM_i = [\sum_{j=1}^M gene_j],$$

$$(2) \quad DC = \max(RM),$$

где M , RM и DC обозначают количество особей в $p\%$ популяции, матрицу повторений и доминантную хромосому соответственно.

3.2. Сценарий 2

Направленная мутация. Второй сценарий в GEA направлен на увеличение эффективности оператора мутации, что предельно важно для предотвращения застревания алгоритма в локальном оптимуме. В традиционных ГА часто применяется случайная мутация, что, вероятно, является их недостатком; в GEA оператор мутации был модифицирован с целью управления процессом мутации. Здесь возможен поиск важных генов, с тем чтобы алгоритм “сосредоточился” на генах, способствующих развитию желаемых признаков или результатов. Направление процесса мутации и устранение случайности, связанной с традиционными мутациями, значительно повышает производительность генетического алгоритма. Подход позволяет алгоритму приоритезировать гены и вносить полезные изменения контролируемым образом. Тем

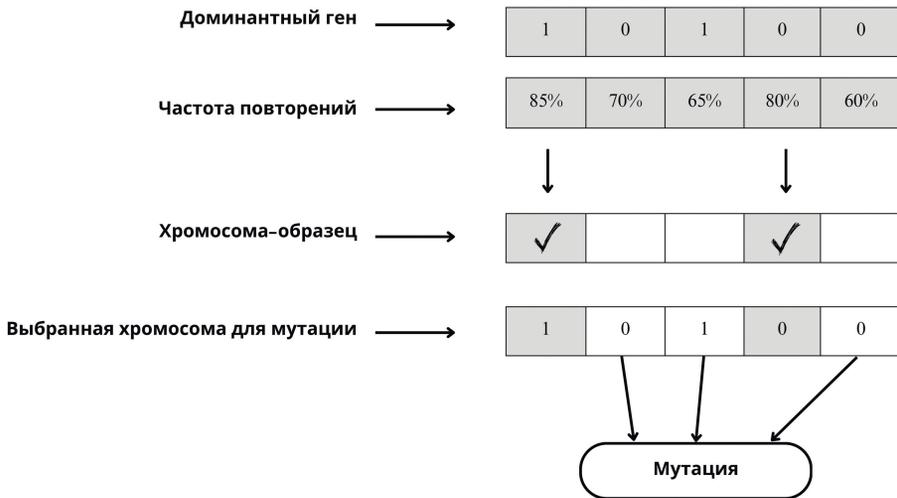


Рис. 3. Направленная мутация путем фиксации информативных генов.

самым, GEA преодолевает ограничения случайной мутации и повышает свою способность эффективно исследовать пространство решений. На рис. 3 представлен пример процесса направленной мутации.

$$(3) \quad f(x) = \begin{cases} 1, & \text{если } M_{ij}, \text{ желаемая хромосома} \\ 0, & \text{в противном случае.} \end{cases}$$

- Желательный ген.** Первый этап применения данного оператора заключается в поиске наиболее часто повторяющихся генов среди $p\%$ лучших хромосом, которые считаются желательными генами. Цель этого этапа — выделение части генов, являющихся наиболее информативными элементами для формирования элитной части популяции. Наличие этих генов в решении способствует удержанию популяции в элитной области и, при незначительных изменениях, может привести к приближению к глобальному оптимуму в ближайшем будущем. Здесь формируется матрица шаблонов размером $n * t$, где n — количество хромосом в элитной части популяции (лучшие $p\%$), а t — количество генов в хромосоме (число переменных в задаче). Матрица шаблонов состоит из бинарных элементов: 1 отвечает специфической части хромосомы, которая считается желаемой и должна быть зафиксирована, а 0 представляет неинформативные гены, подлежащие мутации. Уравнение (3) демонстрирует процесс формирования матрицы шаблонов. Если число повторений достигает определенного порога, ген становится желаемым. Пороговое значение устанавливается пользователем до начала работы алгоритма.
- Мутация поиска желательных генов.** После формирования шаблона для $p\%$ хромосом с наивысшими значениями приспособленности кандидат выбирается с помощью метода колеса рулетки. Мутация применяется исключительно к неинформативным генам, которые обозначены нулем в соответ-

ствующей матрице шаблонов. Целью применения целевой мутации является эффективный поиск в пространстве решений для нахождения глобального оптимума. Специально разработанная мутация повторяется в рамках общего числа мутаций, но только в отношении неинформативных генов, что способствует инвестициям в элитную часть популяции и обеспечивает более быструю конвергенцию.

3.3. Сценарий 3

Инъекция генов. Третий сценарий в GEA подчеркивает значимость учета всей популяции, включая особи с наименьшими показателями пригодности. Здесь, в отличие от первых двух сценариев, ориентированных на элитную часть популяции, возможна ситуация, когда даже наименее успешные решения могут способствовать общему улучшению алгоритма. В алгоритмах оптимизации важно учитывать особи с наихудшими показателями, поскольку они также обладают потенциалом для положительных изменений. В данном сценарии осуществляется “инъекция” в наихудшие особи с использованием инженерного подхода для улучшения их производительности. Минимальные изменения в наихудших особях могут способствовать их движению к глобальному оптимуму и в конечном итоге включению в число элитных решений в последующих итерациях алгоритма.

Для реализации этой стратегии создается матрица паттернов для элитной части популяции. Затем из неэлитной части популяции (представляющей $1 - p\%$) отбираются особи. Исходя из матрицы паттернов, в выбранную хромосому инжектируются гены из хромосомы с наибольшим количеством повторений. Этот оператор инъекции генов способствует передаче полезной генетической информации от доминирующей хромосомы другим особям в популяции, позволяя им улучшиться и внести свой вклад в общий процесс оптимизации. На рис. 4 представлен пример, демонстрирующий механизм работы

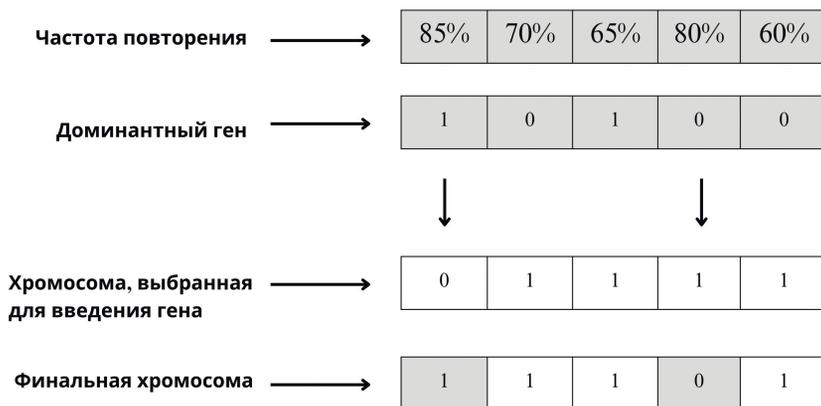


Рис. 4. Инъекция информативных генов в сухие особи популяции.

предложенного оператора инъекции генов. Он показывает процесс передачи генетической информации для улучшения выбранной хромосомы.

Включение этого третьего сценария в GEA позволяет использовать потенциал даже наименее успешных решений для продвижения алгоритма к глобальному оптимуму. Такой подход обеспечивает всестороннее исследование пространства решений и способствует улучшению всей популяции в ходе последовательных итераций.

Алгоритм 1. Доминантная хромосома

Данные: Поп., Проб. Инфо.

Результат: ДоминантныйГен, Маска, МаскаПеревернутая

```
while i меньше длины хромосомы do
  while j меньше, чем количество Поп. do
    | Гены <- [Гены, Поп_j(i)]
  end
  while в генах есть элемент do
    | темп <- сумма(Гены == Гены(1))
    | if размер ДоминантныйГен == 0 then
      | ДоминантныйГен <- Гены(1)
      | СчетчикДоминантныхГенов <- темп
    | else
      | if темп > СчетчикДоминантныхГенов then
        | ДоминантныйГен <- Гены(1)
        | СчетчикДоминантныхГенов <- темп
      | else
        | ДоминантныйГен <- [ДоминантныйГен, Гены(1)]
      | end
    | end
  end
end
Маска <- нули(1, размер(хромосома))
while i меньше длины хромосомы do
  | if (СчетчикДоминантныхГенов > порог) и (порог не 0) then
  | | Маска(i) <- 1
  | end
end
МаскаПеревернутая <- !Маска
```

4. Результаты вычислительного эксперимента

В рамках данного исследования была проведена оценка эффективности алгоритма GEA при решении задач комбинаторной оптимизации на примере задачи отыскания оптимальных маршрутов транспортных средств. Эта задача заключается в определении оптимальных маршрутов для транспортных средств, направленных на обслуживание ряда точек спроса с минимальными транспортными издержками. Алгоритм GEA был сопоставлен не только с традиционным алгоритмом генетической оптимизации (GA), но и с тремя

его модификациями: GEA1, GEA2 и GEA3. Каждая из этих модификаций использовала свой сценарий (как было показано в разделе 3). В алгоритме GEA на каждой итерации основного цикла случайным образом выбирался один из этих сценариев.

В исследовании были использованы шесть эталонных примеров (см. [9, 18]). Для всех рассматриваемых алгоритмов были установлены одинаковые параметры: максимальное число итераций — 1000, размер популяции — 100. Вероятность скрещивания и мутации были унифицированы для всех алгоритмов и составили 0,8 и 0,1 соответственно. Для GEA были установлены доли учета сценариев в размере 0,5, 0,5 и 0,2 для первого, второго и третьего сценариев соответственно.

Для оценки производительности алгоритмов было проведено 10 независимых запусков каждого алгоритма на каждом тестовом наборе данных. Результаты представлены в табл. 1, включающей лучшие, худшие, средние значения и стандартные отклонения полученных решений для каждого алгоритма.

Таблица 1. Результаты работы алгоритмов по критериям Лучшее=Л, Худший=X, Среднее=C и Стандартное отклонение=Стд. (Лучшие значения по каждому критерию и тестовому экземпляру выделены жирным шрифтом.)

Тестовый экземпляр		Ф1	Ф2	Ф3	Ф4	Ф5	Ф6
Точки спроса × Количество автомобилей		8 × 3	10 × 3	14 × 4	20 × 4	25 × 5	30 × 5
GA	Л	257,3492	268,1687	301,6661	317,6503	326,5457	308,8542
	X	291,6624	269,0742	316,0882	351,2298	363,0131	343,9097
	C	260,7805	268,7120	305,8615	333,5178	338,1742	321,1532
	Стд	10,8507	0,4675	5,4002	12,3733	11,3976	11,5798
GEA_1	Л	257,3492	268,1687	301,6661	319,3303	319,5602	307,1991
	X	257,3492	269,0742	318,8057	342,2278	359,0854	370,7047
	C	257,3492	268,2593	304,7409	324,0378	330,8722	328,0479
	Стд	5,99E-14	0,2863	5,4787	6,8149	10,8851	21,2861
GEA_2	Л	257,3492	268,1687	301,6661	317,1235	321,5556	302,5377
	X	257,3492	269,0742	306,3834	353,7992	359,0854	322,7266
	C	257,3492	268,3498	302,8296	327,4803	333,1713	311,4745
	Стд	5,99E-14	0,3817	1,6555	12,1645	13,4915	7,3910
GEA_3	Л	257,3492	268,1687	301,6661	317,6503	319,0169	308,8834
	X	257,3492	269,0742	306,3834	331,8416	331,3571	346,2497
	C	257,3492	268,4404	302,3684	323,3476	326,245	323,5826
	Стд	5,99E-14	0,4373	1,58597	5,45505	4,1059	13,7657
GEA	Л	257,3492	268,1687	301,6661	317,6503	317,7347	304,4598
	X	257,3492	268,1687	301,6661	331,8416	331,4877	343,6004
	C	257,3492	268,1687	301,6661	321,4611	323,1822	313,4242
	Стд	5,99E-14	5,99E-14	0	4,7726	6,0097	11,8294

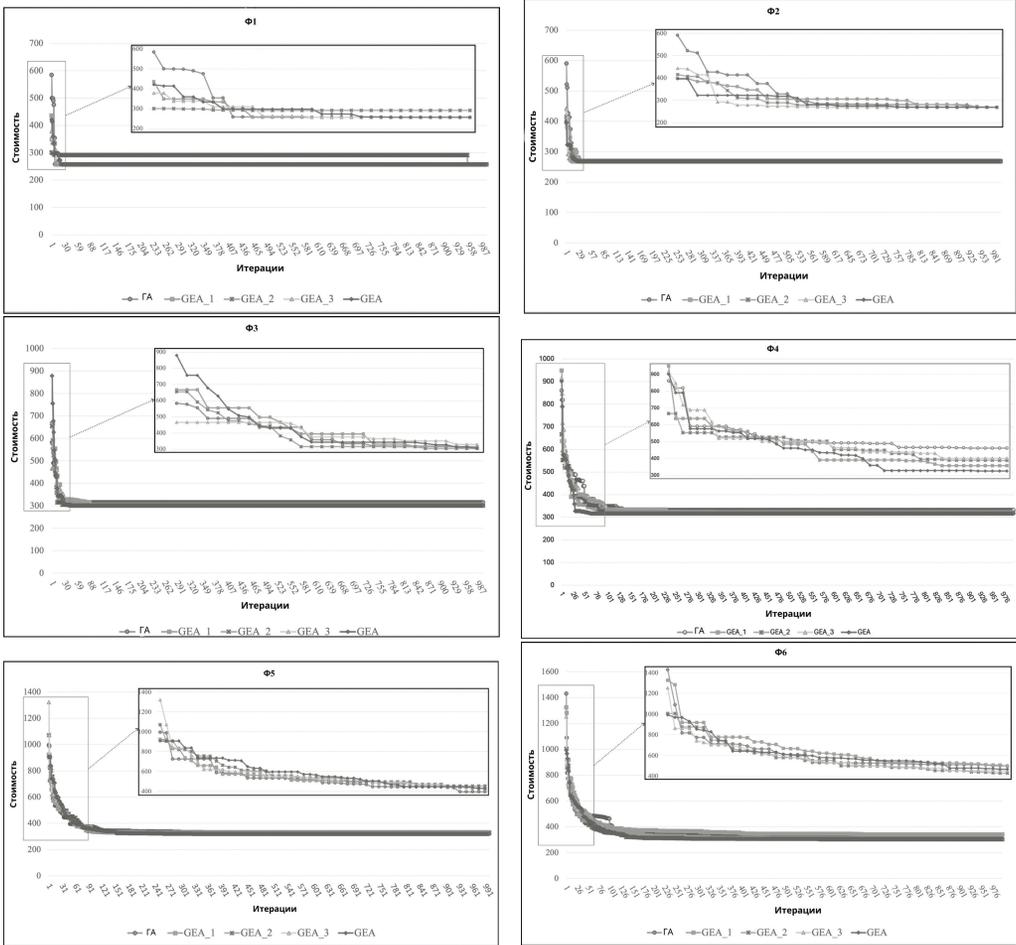


Рис. 5. Скорость сходимости метаэвристических алгоритмов во всех эталонных случаях.

ма. Это позволило проанализировать устойчивость и надежность применяемых метаэвристических алгоритмов. Рисунок 5 демонстрирует скорость сходимости алгоритмов к их наилучшей производительности. Также был проведен статистический анализ с уровнем достоверности 0,95, включающий нормализованные стандартные отклонения по всем алгоритмам. Результаты этого анализа представлены на рис. 6.

Результаты, представленные в табл. 1, свидетельствуют о том, что GEA, использующий все сценарии, превосходит другие алгоритмы. В большинстве случаев он последовательно находит решения, близкие к оптимальным, которые превосходят результаты, полученные с помощью GA и других модификаций GEA. Среди вариантов GEA особо выделяется GEA2, подтверждая эффективность второго сценария в поиске улучшенных решений. Рисунок 5 показывает, что все алгоритмы демонстрируют приемлемую скорость сходи-

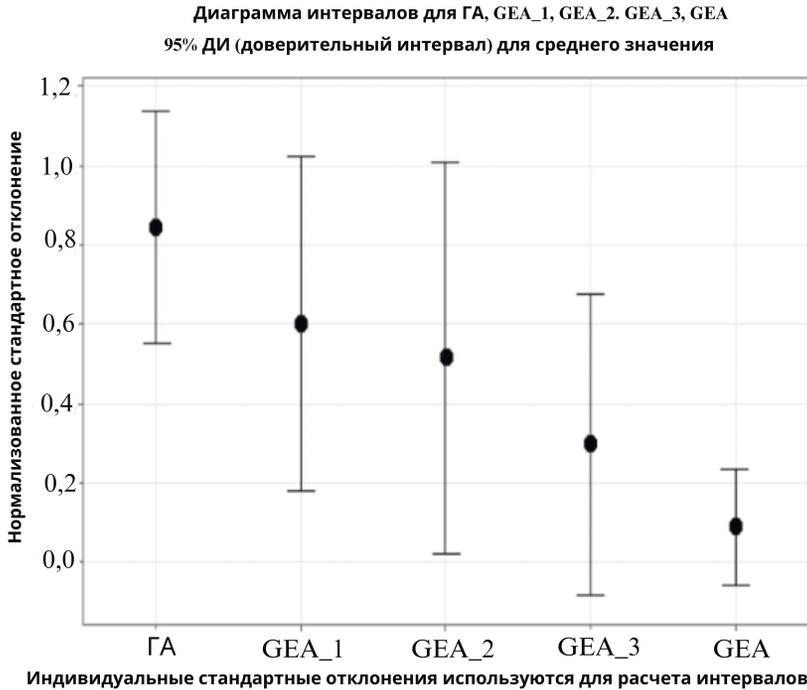


Рис. 6. Интервальный график на основе доверительного уровня 95% для анализа робастности метаэвристических алгоритмов.

мости на тестовых наборах данных, обеспечивая схожее качество решений. Статистический анализ, представленный на рис. 6, наглядно подтверждает высокую точность GEA по сравнению с другими алгоритмами.

Таким образом, проведенная оценка подтвердила эффективность GEA в решении задач комбинаторной оптимизации, в частности в задаче маршрутизации транспортных средств. Результаты, изложенные в табл. 1 и на рис. 5 и 6, выявляют превосходную производительность и точность GEA, особенно при использовании всех сценариев. Полученные данные свидетельствуют о потенциале GEA как надежного метаэвристического алгоритма для решения оптимизационных задач.

5. Выводы и возможные направления будущих исследований

В данной статье проведено исследование алгоритма GEA и его эффективности при решении задач комбинаторной оптимизации, в частности задачи маршрутизации транспортных средств. Результаты, полученные в ходе сравнительного анализа с традиционным ГА и различными вариантами GEA, демонстрируют превосходство GEA, особенно при использовании всех сценариев. GEA превосходит другие алгоритмы, давая лучшие близкие к оптимальным решения в большинстве случаев.

Эффективность GEA в решении задачи маршрутизации транспортных средств демонстрирует его потенциал в реальных задачах, где эффективная маршрутизация транспорта имеет решающее значение. Эти результаты дают представление об эффективности методов генной инженерии для решения задач комбинаторной оптимизации и указывают на необходимость учета различных сценариев при разработке алгоритмов.

Можно выделить несколько направлений будущих исследований. Во-первых, можно провести дальнейшие исследования, чтобы изучить влияние различных параметров на производительность GEA и его вариаций. Тонкая настройка параметров алгоритма может повысить его эффективность и привести к получению более качественных решений. Во-вторых, применение подхода к другим оптимизационным задачам позволит получить представление о его эффективности и конкурентоспособности. Кроме того, интеграция GEA с другими методами оптимизации или гибридизация его с подходами машинного обучения может расширить его возможности. Наконец, проведение экспериментов на более высокоразмерных задачах позволит установить границы масштабируемости и эффективности GEA [40, 41].

СПИСОК ЛИТЕРАТУРЫ

1. *Holland J.* Adaptation in natural and artificial systems. Ann Arbor: University of Michigan Press, 1975.
2. *Elshaer R., Awad H.* A taxonomic review of metaheuristic algorithms for solving the vehicle routing problem and its variants // *Computers Indust. Engin.* 2020. V. 140. P. 106242.
3. *Katoch S., Chauhan S.S., Kumar V.* A review on genetic algorithm: past, present, and future // *Multimedia Tools Appli.* 2021. V. 80. P. 8091–8126.
4. *Yang X.S., Deb S.* Engineering optimisation by cuckoo search // *Int. J. Math. Modell. Numer. Optim.* 2010. V. 1. No. 4. P. 330–343.
5. *Mirjalili S., Lewis A.* The whale optimization algorithm // *Advanc. Engin. Software.* 2016. V. 95. P. 51–67.
6. *Mirjalili S.* SCA: a sine cosine algorithm for solving optimization problems // *Knowledge-Based Syst.* 2016. V. 96. P. 120–133.
7. *Heidari A.A., Mirjalili S., Faris H., et al.* Harris hawks optimization: Algorithm and applications // *Future Generat. Comput. Syst.* 2019. V. 97. P. 849–872.
8. *Jain M., Singh V., Rani A.* A novel nature-inspired algorithm for optimization: Squirrel search algorithm // *Swarm Evoluti. Comput.* 2019. V. 44. P. 148–175.
9. *Fathollahi-Fard A.M., Hajiaghaei-Keshteli M., Tavakkoli-Moghaddam R.* Red deer algorithm (RDA): a new nature-inspired meta-heuristic // *Soft Comput.* 2020. V. 24. P. 14637–14665.
10. *Xue J., Shen B.* A novel swarm intelligence optimization approach: sparrow search algorithm // *Syst. Sci. Control Engine.* 2020. V. 8. No. 1. P. 22–34.
11. *Braik M., Sheta A., Al-Hiary H.* A novel meta-heuristic search algorithm for solving optimization problems: capuchin search algorithm // *Neural Comput. Appli.* 2021. V. 33. P. 2515–2547.

12. *Abualigah L., Yousri D., Abd Elaziz M., et al.* Aquila optimizer: a novel meta-heuristic optimization algorithm // *Comput. Indust. Engin.* 2021. V. 157. P. 107250.
13. *Braik M.S.* Chameleon Swarm Algorithm: A bio-inspired optimizer for solving engineering design problems // *Expert Syst. Appl.* 2021. V. 174. P. 114685.
14. *Yang Z., Deng L., Wang Y., et al.* Aptenodytes forsteri optimization: Algorithm and applications // *Knowledge-Based Syst.* 2021. V. 232. P. 107483.
15. *Xue J., Shen B.* Dung beetle optimizer: A new meta-heuristic algorithm for global optimization // *J. Supercomput.* 2023. V. 79. No. 7. P. 7305–7336.
16. *Zhong C., Li G., Meng Z.* Beluga whale optimization: A novel nature-inspired metaheuristic algorithm // *Knowledge-Based Syst.* 2022. V. 251. P. 109215.
17. *Wolpert D.H., Macready W.G.* No free lunch theorems for optimization // *IEEE Transactions on Evoluti. Comput.* 1997. V. 1. No. 1. P. 67–82.
18. *Fathollahi-Fard A.M., Hajiaghaei-Keshteli M., Tavakkoli-Moghaddam R.* The social engineering optimizer (SEO) // *Engin. Appli. Artific. Intellig.* 2018. V. 72. P. 267–293.
19. *Li D., Li X., Zhou W.L., et al.* Genetically engineered T cells for cancer immunotherapy // *Signal Transduct. Targeted Therapy.* 2019. V. 4. No. 1. P. 35.
20. *Xiao Q., Guo D., Chen S.* Application of CRISPR/Cas9-based gene editing in HIV-1/AIDS therapy // *Frontiers Cellul. Infect. Microbiol.* 2019. V. 9. P. 69.
21. *Raposo V.L.* The first Chinese edited babies: a leap of faith in science // *JBRA Assist. Reproduct.* 2019. V. 23. No. 3. P. 197.
22. *Li C.* Breeding crops by design for future agriculture // *J. Zhejiang Univer. Sci. B.* 2020. V. 21. No. 6. P. 423.
23. *Dubock A.* Golden rice: to combat vitamin A deficiency for public health. *Vitamin A.* 2019. V. 1.
24. *Huang T.K., Puchta H.* Novel CRISPR/Cas applications in plants: from prime editing to chromosome engineering // *Transgen. Res.* 2021. V. 30. P. 529–549.
25. *Shahryari A., Saghaeian Jazi M., Mohammadi S., et al.* Development and clinical translation of approved gene therapy products for genetic disorders // *Front. Genet.* 2019. V. 10. P. 868.
26. *Zhuo C., Zhang J., Lee J.H., et al.* Spatiotemporal control of CRISPR/Cas9 gene editing // *Signal Transduct. and Targeted Therapy.* 2021. V. 6. No. 1. P. 238.
27. *Kostenetskiy P.S., Chulkevich R.A., Kozyrev V.I.* HPC Resources of the Higher School of Economics // *J. Phys. Conf. Seri.* 2021. V. 1740. No. 1. P. 012050. <https://doi.org/10.1088/1742-6596/1740/1/012050>
28. *Gero J.S., Kazakov V.* A genetic engineering approach to genetic algorithms // *Evoluti. Comput.* 2001. V. 9. No. 1. P. 71–92.
29. *Kameya Y., Prayoonsri C.* Pattern-based preservation of building blocks in genetic algorithms // *IEEE Congre. Evolut. Comput. (CEC).* 2011. P. 2578–2585.
30. *Ding S., Su C., Yu J.* An optimizing BP neural network algorithm based on genetic algorithm // *Artific. Intellig. Rev.* 2011. V. 36. P. 153–162.
31. *Liang Y., Leung K.S.* Genetic algorithm with adaptive elitist-population strategies for multimodal function optimization // *Appl. Soft Comput.* 2011. V. 11. No. 2. P. 2017–2034.
32. *Dasgupta K., Mandal B., Dutta P., et al.* A genetic algorithm (ga) based load balancing strategy for cloud computing // *Procedia Techn.* 2013. V. 10. P. 340–347.

33. *Elsayed S.M., Sarker R.A., Essam D.L.* A new genetic algorithm for solving optimization problems // *Engin. Appli. of Artific. Intellig.* 2014. V. 27. P. 57–69.
34. *Peng B., Li L.* An improved localization algorithm based on genetic algorithm in wireless sensor networks // *Cognitive Neurodynam.* 2015. V. 9. P. 249–256.
35. *Askarzadeh A.* A memory-based genetic algorithm for optimization of power generation in a microgrid // *IEEE Transact. Sustainable Energy.* 2017. V. 9. No. 3. P. 1081–1089.
36. *Reddy G.T., Reddy M.P.K., Lakshmana, et al.* Hybrid genetic algorithm and a fuzzy logic classifier for heart disease diagnosis // *Evolut. Intellig.* 2020. V. 13. P. 185–196.
37. *Fathollahi-Fard A.M., Dulebenets M.A., Hajiaghaei-Keshteli M., et al.* Two hybrid meta-heuristic algorithms for a dual-channel closed-loop supply chain network design problem in the tire industry under uncertainty // *Adv. Engin. Inform.* 2021. V. 50. P. 101418.
38. *Fathollahi-Fard A.M., Tian G., Ke H., et al.* Efficient Multi-objective Metaheuristic Algorithm for Sustainable Harvest Planning Problem // *Comput. Oper. Res.* 2023. V. 158. P. 106304.
39. *Kolae M.H., Mirzapour Al-e-Hashem S.M.J., Jabbarzadeh A.* A local search-based non-dominated sorting genetic algorithm for solving a multi-objective medical tourism trip design problem considering the attractiveness of trips // *Engin. Appl. Artific. Intellig.* 2023. V. 124. P. 106630.
40. *Du D., Pardalos P.M.* Handbook of combinatorial optimization. Springer Science & Business Media. 1998. V. 4.
41. *Mart R., Pardalos P.M., Resende M.G.* Handbook of heuristics. Springer Publishing Company, Incorporated. 2018.

Статья представлена к публикации членом редколлегии А.А. Галяевым.

Поступила в редакцию 08.07.2023

После доработки 09.10.2023

Принята к публикации 20.01.2024