

© 2021 г. И.А. ХОДАШИНСКИЙ, д-р техн. наук (hodashn@rambler.ru)
(Томский государственный университет систем управления и радиоэлектроники)

МЕТОДЫ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ РОЕВЫХ АЛГОРИТМОВ ОПТИМИЗАЦИИ¹

Роевые алгоритмы относятся к классу популяционных метаэвристических методов оптимизации. Несмотря на использование различных метафор, большинство роевых алгоритмов имеют схожую структуру, в них можно выделить такие общие компоненты, как инициализация популяции решений, диверсификация и интенсификация решений. На основании концепции общности был проведен анализ ключевых подходов, методов и способов повышения эффективности роевых алгоритмов оптимизации. В обзоре роевые алгоритмы оптимизации рассматриваются как совокупность операторов, без детального обсуждения каждого алгоритма, основное внимание сосредоточено на анализе ключевых компонентов алгоритмов. Основная идея повышения эффективности заключается в соблюдении баланса между диверсификацией и интенсификацией. В этом контексте рассмотрены механизмы поддержки популяционного разнообразия, методы настройки и регулировки параметров роевых алгоритмов, подходы к гибридизации алгоритмов, обозначено несколько открытых проблем, связанных с темой обзора.

Ключевые слова: оптимизация, метаэвристики, роевые алгоритмы, диверсификация, интенсификация.

DOI: 10.31857/S0005231021060015

1. Введение

Многие сложные проблемы в области науки, техники, экономики и бизнеса могут быть сформулированы как задачи оптимизации. Традиционные методы оптимизации, основанные на производных, доказали свою эффективность в решении различных типов задач оптимизации. Однако применение этих методов связано с рядом ограничений, таких как “застывание” в локальных оптимумах, сильная зависимость от начальных условий, большая вычислительная сложность и неприменимость к конкретным классам целевых функций. Это привело к необходимости разработки альтернативных методов, которые могли бы преодолеть эти ограничения [1].

Поиск оптимальных решений NP-трудных задач часто выполняется с помощью методов, получивших название “метаэвристики”. Прежде чем перейти

¹ Исследование выполнено при финансовой поддержке Российского фонда фундаментальных исследований (проект № 19-17-50050).

к рассмотрению метаэвристик, дадим рабочее определение понятию эвристика — это способ нахождения “достаточно хороших” решений без доказательства оптимальности найденных решений. Качество или эффективность решения могут быть выражены через точность, стабильность, экономию памяти или времени. Термин “мета” указывает на обобщенность и “методологию верхнего уровня”. Как правило, эвристики предназначены для решения конкретных задач, в то время как метаэвристики независимы от решаемых проблем. По мнению Шона Люка, автора известной книги “Основы метаэвристик” [2], метаэвристика — общее, но неудачное название стохастического алгоритма оптимизации, который применяется в качестве последней надежды на пути к решению задачи оптимизации. Стохастическая оптимизация — большой класс алгоритмов и методов, использующих случайность для поиска оптимального (субоптимального) решения сложных задач. Применяются метаэвристики в том случае, когда 1) *неизвестен* способ поиска оптимального решения; 2) *недостаточно* имеющейся априорной информации; 3) *невозможен* полный перебор; 4) *можно* проверить качество решения, т.е. неизвестна аналитическая форма целевой функции $f(\mathbf{x})$, но ее значение может быть вычислено для конкретного решения $\mathbf{x}$.

Метаэвристики не используют вычисление производных целевой функции, однако, в отличие от детерминированных методов оптимизации, метаэвристики позволяют находить за приемлемое время удовлетворительные решения задач большой размерности. Широкому применению метаэвристик способствуют увеличение вычислительной мощности компьютеров и развитие параллельных архитектур [3]. На рис. 1 приведено распределение количества статей, индексируемых в базе данных Scopus, в которых упоминалось слово “metaheuristic”, а на рис. 2 указано распределение статей по отраслям знаний.

Метаэвристические методы классифицируются по различным основаниям. Методы, формирующие последующее решение на основе единственного предыдущего решения, относятся к траекторным методам, типичными представителями которых являются алгоритм имитации отжига [4] и поиск с запретами [5]. Популяционные методы формируют решение на основе своего предыдущего опыта и информации о лучших решениях в популяции. Траекторные методы в большей степени ориентированы на интенсификацию решений, тогда как базовая метаэвристика, основанная на популяциях, в большей степени ориентирована на диверсификацию [3]. Популяционные методы разделены на четыре класса [6]: эволюционные алгоритмы, основанные на процессах эволюции; алгоритмы, имитирующие физические процессы; роевые алгоритмы, основанные на поведенческих процессах социальных животных; алгоритмы, имитирующие поведение человека.

Концепция отсутствия универсального алгоритма оптимизации, оформленная в виде “теоремы о бесплатных завтраках” [7], фактически констатирует отсутствие необходимости оценивать эффективность алгоритмов оптимизации *в среднем* для всех проблем. Теорема указывает на важность понимания взаимосвязи между компонентами алгоритма оптимизации и спецификой решаемой проблемы и побуждает специалистов к проведению новых исследований в области роевых алгоритмов. Эти исследования можно разделить на три большие категории [8]. Первая категория связана с исследованием и




Рис. 1. Распределение количества статей, индексируемых в базе данных Scopus, в которых упоминалось слово “metaheuristic”.




Рис. 2. Распределение по отраслям знаний статей, в которых упоминалось слово “metaheuristic”.

модификацией роевого алгоритма для улучшения его сходимости, точности решения, уменьшения времени выполнения. Вторая категория относится к исследованию типов проблем, которые могут быть решены с помощью данного алгоритма. Большинство роевых алгоритмов изначально предназначались для решения однокритериальных задач безусловной оптимизации. После того как алгоритм показал свою эффективность в решении указанных задач,

проводится его модификация для решения других типов задач, таких как задачи одноцелевой оптимизации с ограничениями, задачи многоцелевой оптимизации, задачи многоцелевой оптимизации с ограничениями, комбинаторные задачи оптимизации и т.д. Третья категория связана с исследованиями практических приложений алгоритмов.

Цель обзора связана с первой категорией исследований. Существующие обзоры, посвященные метаэвристической оптимизации, по большей части сосредоточены на эволюционных алгоритмах и в меньшей степени на роевых алгоритмах. Обзоры, за редким исключением, сосредоточены на рассмотрении метафор, лежащих в основе метаэвристических алгоритмов, и не раскрывают общего понимания механизмов генерации и модификации решений. В представленном обзоре роевые алгоритмы оптимизации рассматриваются как совокупность операторов, без детального обсуждения каждого алгоритма, основное внимание сосредоточено на анализе ключевых компонентов роевых алгоритмов.

Статья организована следующим образом. В разделе 2 дается краткое описание основных понятий и терминологии роевых алгоритмов. Так как алгоритм роящихся частиц является прототипом для реализации многих последующих роевых алгоритмов, его описанию посвящен раздел 3. Процедуры инициализации рассматриваются в разделе 4. В разделе 5 приведены некоторые меры популяционного разнообразия, а механизмы поддержки разнообразия — в разделе 6. Проблемы настройки и регулирования значений параметров рассматриваются в разделе 7. В разделе 8 дается краткое описание основных подходов к гибридизации роевых алгоритмов. Открытые проблемы кратко рассмотрены в разделе 9. В разделе 10 подведены итоги.

2. Основные понятия и терминология

Алгоритмы оптимизации ищут точку в пространстве поиска, в которой значение целевой функции максимально или минимально в зависимости от задачи оптимизации.

Рассмотрим задачу поиска минимального значения функции

$$\min f(\mathbf{x}), \mathbf{x}_{\min} \leq \mathbf{x} \leq \mathbf{x}_{\max},$$

$$\mathbf{x}_{\min} = (x_{1,\min}, x_{2,\min}, \dots, x_{D,\min}), \quad \mathbf{x}_{\max} = (x_{1,\max}, x_{2,\max}, \dots, x_{D,\max}),$$

$\mathbf{x}_{\min}$ и $\mathbf{x}_{\max}$ определяют пространство поиска, $f: \mathbb{R}^D \rightarrow \mathbb{R}$ — целевая функция D -мерного векторного аргумента, которая оценивает решение $\mathbf{x} = (x_1, x_2, \dots, x_D)$.

Большинство традиционных методов оптимизации требуют выполнения определенных условий, таких как выпуклость, непрерывность и т.д. Принимая во внимание ограничения традиционных методов, исследователи предложили использовать методы стохастической оптимизации, в частности роевые алгоритмы.

Большинство роевых алгоритмов оптимизации основаны на метафоре природных или техногенных процессов. Однако анализ работы метаэвристического алгоритма должен быть выполнен с использованием общепринятой тер-

минологии в области оптимизации, а не на языке метафоры. Реальная ценность использования таких метафор в алгоритмах оптимизации часто неясна и вызывает ряд критических замечаний [9, 10]. Основное замечание связано с отсутствием алгоритмических различий в так называемых новых метаэвристиках по сравнению с ранее опубликованными. Автор публикации [11], проведя строгий анализ гармонического поиска [12], приходит к выводу, что эта метаэвристика является частным случаем хорошо известной эволюционной стратегии. В [13] показано, что оптимизация на основе черных дыр [14] является упрощенной версией алгоритма роящихся частиц. Анализ алгоритма под названием “интеллектуальные капли воды” [15] позволил авторам [10] сделать вывод о том, что все основные алгоритмические компоненты этой метаэвристики являются упрощениями или частными случаями алгоритма муравьиной колонии. Другое важное критическое замечание связано с сомнением по поводу полезности использования некоторых метафор при разработке алгоритмов оптимизации. Авторы публикаций [9, 10, 13] указывают на то, что, хотя некоторые метафоры имеют хорошее математическое описание, созданные на их основе метаэвристики либо существенно модифицируют указанные описания, либо вообще не соответствуют исходной метафоре. В [9] утверждается, что в большинстве случаев метафоры совершенно не нужны для описания алгоритма оптимизации, роль метафор часто преувеличивается их авторами.

Роевые алгоритмы оптимизации могут рассматриваться как итеративные процедуры поиска, где рой — это множество взаимодействующих частиц, которые определяют потенциальное решение задачи оптимизации в D -мерном пространстве. Итоговое решение может быть представлено либо отдельной частицей (координаты частицы в пространстве поиска), либо группой частиц, где каждая частица представляет собой часть решения. Существуют две основные схемы кодирования возможных решений: векторное и представление в виде графа. В векторном типе представления каждое возможное решение кодируется строкой значений:

$$(1) \quad \mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{iD}) \quad i = 1, 2, \dots, N,$$

где N — размер популяции, D — размерность пространства поиска.

Многие задачи комбинаторной оптимизации, например задача коммивояжера, могут быть представлены в виде графа. В таком представлении частицы перемещаются от одного узла к другому, пока не пройдут все узлы, и не будет найдено полное решение проблемы (путь, соединяющий все города).

Схемы кодирования во многом определяют способ формирования новых вариантов решения. В большинстве роевых алгоритмов новые решения генерируются случайным образом или с использованием эвристики, которая объединяет существующие решения для получения нового. Для векторного представления типичный метод обновления выполняется на основе уравнения

$$(2) \quad \mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \Delta_i(t+1),$$

где $\mathbf{x}_i(t)$ — текущее решение, $\mathbf{x}_i(t+1)$ — обновленное решение, $\Delta_i(t)$ — модифицирующий вектор, t — текущая итерация. Модифицирующий вектор

может быть сформирован так: 1) на основе градиента; 2) перестановкой отдельных частей нескольких решений; 3) внесением направленного возмущения, вычисленного как разность двух решений, умноженная на равномерно распределенное случайное число; 4) внесением случайного возмущения, основанного на распределениях Гаусса, Коши, Леви.

В силу ограниченности объема статьи будет рассмотрен только векторный тип представления решения.

Большинство роевых алгоритмов имеют сходную структуру, в которой можно выделить ключевые компоненты и функции:

1) инициализация — задание значений параметрам алгоритма, формирование начальной популяции;

2) диверсификация (глобальный поиск) — генерация новых решений или исследование всего пространства поиска, когда модифицирующий вектор может принимать большие значения, обеспечивая разнообразие решений и не позволяя застрять в локальном оптимуме;

3) интенсификация (локальный поиск) — улучшение ранее найденных решений, выполняемое на ограниченном пространстве поиска, в этом случае модифицирующий вектор принимает малые значения.

Перечисленные выше компоненты реализуют вычислительные процедуры, например диверсификация почти всегда выполняется путем рандомизации, а интенсификация реализуется путем незначительного изменения лучших решений. Роевые алгоритмы можно классифицировать на две группы. В первую группу входят алгоритмы, в которых явно присутствуют компоненты диверсификации и интенсификации, например миметические алгоритмы [16], алгоритм на основе теории электромагнетизма [17], алгоритм ворон [18], прямой алгоритм муравьиной колонии [19]. Ко второй группе относятся алгоритмы с одним выражением, отвечающим как за диверсификацию, так и за интенсификацию, например алгоритм роящихся частиц [20], алгоритм “кукушкин поиск” [21]. Для соблюдения баланса между диверсификацией и интенсификацией необходима мера измерения популяционного разнообразия, определив которую, можно поддерживать баланс путем изменения параметров алгоритма или гибридизации.

Типичным представителем алгоритмов с одним выражением является алгоритм роящихся частиц, являющийся прототипом для реализации многих последующих алгоритмов и примером для иллюстрации методов повышения эффективности. Далее приведено краткое описание этого алгоритма.

3. Стандартный алгоритм роящихся частиц

Алгоритм роящихся частиц имеет мало настраиваемых параметров, небольшое требование к памяти, что делает его вычислительно эффективным. Алгоритм роящихся частиц [20] — это стохастический метод поиска, основанный на итеративном взаимодействии частиц, образующих рой. Перемещение частицы в пространстве поиска определяют три фактора: инерция, память, сотрудничество. Инерция подразумевает, что частица не может мгновенно изменить свое направление движения. Каждая частица имеет память

и хранит свою лучшую позицию в пространстве поиска. Известна частице и лучшая позиция роя. Зная эти две позиции, частица динамически изменяет скорость согласно ее собственному опыту и опыту полета других частиц. Таким образом, движение каждой частицы задается ее лучшей позицией, ее текущей скоростью, ускорением, заданным предыдущей позицией, и ускорением, заданным лучшей частицей в рое. Рой прекращает движение при выполнении хотя бы одного из следующих условий: рой достиг состояния равновесия, найдено оптимальное решение (ошибка меньше заданной), выполнено заданное количество итераций. Пространство поиска — множество действительных чисел, рой состоит из N частиц-решений. Позиция i -й частицы определяется вектором (1). Лучшая позиция, которую занимала i -я частица, определяется вектором $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$, модифицирующий вектор в выражении (2) определяется скоростью частицы $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$. Скорость и положение i -й частицы на итерации $t + 1$ определяют уравнения

$$\begin{aligned}\mathbf{x}_i(t + 1) &= \mathbf{x}_i(t) + \mathbf{v}_i(t + 1), \\ \mathbf{v}_i(t + 1) &= w \cdot \mathbf{v}_i(t) + c_1 \cdot \text{rand} \cdot (\mathbf{p}_i(t) - \mathbf{x}_i(t)) + c_2 \cdot \text{Rand} \cdot (\mathbf{p}_g(t) - \mathbf{x}_i(t)),\end{aligned}$$

где $i = 1, 2, \dots, N$; $\mathbf{v}_i(t)$ — вектор скорости i -й частицы на итерации t ; $\mathbf{x}_i(t)$ — координаты i -й частицы на итерации t ; c_1, c_2 — положительные коэффициенты ускорения; $\mathbf{p}_i(t)$ — лучшая позиция i -й частицы на первых t итерациях; $\mathbf{p}_g(t)$ — глобально лучшая позиция частицы в рое на первых t итерациях (задается индексом g); w — эмпирический коэффициент инерции; rand, Rand — случайные числа из диапазона $[0; 1]$.

Если коэффициенты ускорения и инерции не меняются в процессе работы алгоритма, то для соблюдения баланса между диверсификацией и интенсификацией значения этих коэффициентов рекомендуется устанавливать $c_1 = c_2 = 1,419$, а $w = 0,721$ [22].

Рой имеет своего рода топологию, описывающую взаимосвязи между частицами. Каждая частица имеет множество соседей. Соседями частицы может быть весь рой или некоторое его подмножество. Две наиболее часто используемые топологии известны как *gbest* и *lbest*. Топология *gbest* является полносвязной топологией, в отличие от *lbest*, в которой частица взаимодействует с ограниченным числом соседей. Алгоритм с топологией *gbest* быстро сходится и имеет больше шансов застрять в локальных оптимумах. Алгоритм с топологией *lbest* медленнее сходится, но более полно исследует пространство поиска и, как правило, находит лучшее решение [3].

4. Инициализация

Если целевая функция имеет несколько локальных оптимумов, то традиционные алгоритмы сходятся к одному из них, положение которого определяет процедура инициализации. Алгоритмы могут найти глобальный оптимум, если начальные решения принадлежат области притяжения глобального оптимума. Процедура инициализации играет важную роль и в роевых алгоритмах, где отсутствие разнообразия в популяции может привести к преждевременной сходимости и попаданию в локальный оптимум. Таким образом, эффективность методов оптимизации может быть повышена за счет разработки

методов генерации перспективных начальных решений. Однако на сегодняшний день отсутствуют системные исследования процесса инициализации и того, как начальные распределения решений могут влиять на эффективность роевых алгоритмов при решении определенного класса проблем [1].

Процедура инициализации включает задание начального размера популяции и собственно создание начальной популяции. *Размер популяции* влияет на надежность и вычислительные затраты алгоритма. Небольшой размер популяции может привести к быстрой сходимости к локальному оптимуму, большой размер увеличит вычислительные затраты и может привести к медленной сходимости [23]. Размер популяции может быть увязан с размерностью пространства поиска D . В [8] предлагается определять размер популяции в алгоритме роящихся частиц как

$$[10 + 2\sqrt{D}],$$

где $[\cdot]$ — целая часть числа. Для задач большой размерности ($D \geq 50$) в [24] размер популяции в алгоритме “кукушкин поиск” предлагается устанавливать равным D . Авторы [25] определяют размер популяции в модифицированном алгоритме искусственной пчелиной колонии как $5D$, а в модифицированном алгоритме серого волка размер популяции задается равным $3D$ [26]. Однако чаще всего размер популяции выбирается экспериментальным путем. Другим подходом к решению этой проблемы является введение адаптивного метода формирования размера популяции, который делает роевый алгоритм менее чувствительным к начальному выбору размера популяции.

Можно выделить несколько различных стратегий *создания начальной популяции*: стохастические методы, квазислучайные последовательности, метод оппозиционного обучения, многошаговый метод. Группу стохастических методов можно разделить на две подгруппы: генераторы псевдослучайных чисел и генераторы хаотических чисел. В роевых алгоритмах при отсутствии априорных знаний генерация случайных чисел является распространенным способом создания начальной популяции, которая может быть определена как

$$x_{i,j} \sim U(low_j; up_j), \quad i = 1, 2, \dots, N, \quad j = 1, 2, \dots, D,$$

где U представляет собой равномерное распределение, low_j , up_j — нижнее и верхнее значения j -й переменной.

Равномерное распределение начальных решений по пространству поиска не является единственно возможным, наряду с равномерным используется распределение Леви, бета-распределение, нормальное распределение, логнормальное распределение и др. [1]. Основным достоинством метода на основе псевдослучайных чисел является простота, поскольку средства генерации псевдослучайных чисел присутствуют в каждом языке программирования, с их помощью легко решается проблема инициализации начальной популяции.

Для создания стохастических начальных популяций используются хаотические методы, для которых характерны эргодичность, случайность и регулярность [27]. Чтобы создать хаотическую популяцию, нужна хаотическая

карта. В очень общем виде одномерные хаотические карты работают следующим образом [27]:

$$x_{i,j}^{t+1} = f_m(x_{i,j}^t),$$

где $x_{i,j}^t$ — j -я переменная i -й частицы на итерации t , m — определяемый пользователем параметр. Обычно $x_{i,j}^0$ выбирается случайным образом, последующие точки создаются путем многократного применения хаотической карты. Наиболее часто применяются следующие хаотические карты: логистическое отображение (Logistic Map), синусоидальное отображение (Sinusoidal iterator), отображение tent-map, гауссово отображение (Gauss Map).

Авторы [28] считают что, хотя метод генерации случайных чисел очень прост с точки зрения программирования, он не очень эффективен, потому что сгенерированные компьютером числа не покрывают равномерно пространство поиска. Квазислучайные последовательности относятся к детерминированным методам, генерирующим одну и ту же популяцию. Детерминированные методы инициализации разработаны для обеспечения равномерного распределения частиц на всем пространстве поиска. В последнее время эти методы привлекают больше внимания, потому что в отсутствие предварительных знаний о проблеме, однородность начальной популяции может повысить исследовательскую способность алгоритма на его ранних стадиях [27]. В квазислучайной последовательности разнообразие популяции, как правило, лучше, чем при псевдослучайной генерации. Для формирования начальной популяции алгоритма роящихся частиц использовались квазислучайные последовательности Ван-дер-Корпута [28] и Фора [29], а для инициализации популяции алгоритма гравитационного поиска использовали генератор Соболя [30].

Идея инициализации на основе оппозиционного обучения основана на противоположных отношениях между сущностями и заключается в одновременном формировании как текущих решений, так и решений, противоположных текущим, используя для этого противоположные числа. В [31] дано определение противоположной точки в D -мерном пространстве. Пусть $\mathbf{z} = (z_1, \dots, z_D)$ — точка в пространстве и $z_j \in [a_j; b_j]$, $j = 1, 2, \dots, D$. Противоположность $\mathbf{z}$ определяется как $\check{\mathbf{z}} = (\check{z}_1, \dots, \check{z}_D)$ как

$$(3) \quad \check{z}_j = a_j + b_j - z_j.$$

Одновременное использование случайного решения и его противоположности дает больше шансов найти оптимальное решение [31]. Можно предположить, если текущие случайно сгенерированные решения далеки от оптимального решения, то их противоположности будут ближе к этому решению. Приведенное выше определение противоположной точки называется противоположностью типа I, она определяется в соответствии с отношением между точками в пространстве поиска без учета их функциональных значений. Противоположность типа II определяется с учетом функционального пространства задачи следующим образом [31]. Предположим, что для функции $f(x_1, x_2, \dots, x_D)$ предопределены или могут быть оценены $y_{\min}$ и $y_{\max}$. Пусть $y = f(x_1, x_2, \dots, x_D) \in \mathbb{R}$ и $y \in [y_{\min}; y_{\max}]$. Для каждой точки

$\mathbf{x} = (x_1, x_2, \dots, x_D)$ противоположная точка типа II $\check{\mathbf{x}} = (\check{x}_1, \check{x}_2, \dots, \check{x}_D)$ определяется как

$$(4) \quad \check{x}^\Pi = \{x \mid \check{y} = y_{\min} + y_{\max} - y\}.$$

Авторы [31] теоретически доказали, что в общем случае противоположные числа с большей вероятностью будут ближе к оптимальному решению, чем чисто случайные; в [32] теоретические исследования были подтверждены экспериментально применительно к метаэвристике “дифференциальная эволюция”. Применением инициализации на основе оппозиционного обучения улучшены алгоритм роящихся частиц [33], алгоритм на основе стада криля [34], алгоритм на основе электромагнетизма [17]. На первом этапе методы оппозиционного обучения генерируют набор точек, называемых исходной популяцией. Исходная популяция может быть сгенерирована с использованием любого метода инициализации, например генератором равномерно распределенных чисел [32] или хаотической картой [35]. Затем используются некоторые простые эвристические правила (например выражения 3 или 4) для создания другой популяции такого же размера. Итоговая популяция формируется путем объединения обеих популяций на основе значений целевых функций входящих в них решений.

Примером многошагового метода является центроидальная тесселяция Вороного. С помощью этого метода можно разделить пространство поиска на равные объемы, не используя целевую функцию. Временная популяция создается с использованием генератора равномерно распределенных чисел или более сложных методов. Затем с помощью множества случайно сгенерированных вспомогательных точек пространство поиска разделяется на несколько областей. Эти области итеративно расширяются, пока не будут выполнены некоторые критерии. Центры областей используются в качестве начальной популяции [36]. Другим примером многошагового метода является подход к поиску перспективных регионов, названный Smart Sampling [37], который генерирует начальные решения, оценивает их, используя целевую функцию, и разделяет их на два класса — “хорошие” и “плохие” — на основе порога, применяемого к значению целевой функции каждого решения. На размеченной выборке начальных решений строится классификатор, который позволяет проверять, является ли вновь сгенерированное решение хорошим без использования целевой функции. Если новое решение классифицируется как “хорошее”, оно может быть оценено целевой функцией. Подход Smart Sampling эффективен только в том случае, если вычислительно затратным является процесс определения значения целевой функции.

В [1] предложен метод инициализации на основе латинского гиперкуба, суть которого заключается в разделении значений каждой координаты поиска на N равных интервалов, в каждый из которых попадает по одному начальному решению. Такой метод позволяет избежать проблемы чрезмерного скопления решений в одной точке пространства поиска. Исследования показывают, что такой метод может обеспечить лучшее покрытие, чем равномерное распределение [1].

Автор обзора [1] отмечает следующие проблемы рассмотренных методов инициализации: стохастические методы просты и легко реализуемы, однако

они плохо масштабируемы; хаотические методы сильно зависят от начальных условий; методы оппозиционного обучения генерируют популяцию удвоенного размера, что приводит к удваиванию вычислительных затрат; метод латинского гиперкуба очень эффективен при небольших размерностях пространства поиска, но он не дает явного преимущества при решении задач высокой размерности [1]. Как не существует единственного эффективного алгоритма оптимизации (“теорема о бесплатных завтраках” [7]), так не существует единственного эффективного алгоритма инициализации, в [1] на примерах показано, что для разных задач следует использовать разные алгоритмы.

5. Меры популяционного разнообразия

Эффективность роевого алгоритма во многом определяет баланс между фазами диверсификации и интенсификации. О том, в какой фазе находится алгоритм в каждый момент выполнения, можно судить по значению популяционного разнообразия. Разнообразие определяется как расстояние между решениями в пространстве поиска или как различие между значениями целевых функций найденных решений. Недостаточное популяционное разнообразие приводит к быстрой сходимости к потенциально неоптимальному решению. Для управления поиском решений необходимо иметь метрику для определения популяционного разнообразия. Метрики, основанные на расстоянии Минковского, наиболее часто используются для определения разнообразия. В [38] популяционное разнообразие определяется как

$$Div = \frac{1}{N} \sum_{i=1}^N \sqrt{\sum_{j=1}^D (x_{ij}(t) - \bar{x}_j(t))^2},$$

где $\bar{x}_j(t)$ — среднее значение по j -му признаку на итерации t .

В [35, 39] разнообразие популяции алгоритма роящихся частиц и алгоритма искусственной пчелиной колонии рассчитывается по формуле

$$Div = \frac{1}{N} \frac{\sum_{i=1}^N \|\mathbf{x}_i - \bar{\mathbf{x}}\|}{\max_{1 \leq i, j \leq N} \|\mathbf{x}_i - \mathbf{x}_j\|}.$$

В [40] разнообразие популяции основано на норме $L1$:

$$Div = \frac{1}{N \cdot D} \sum_{i=1}^N \sum_{j=1}^D |x_{ij}(t) - \bar{x}_j(t)|.$$

По мнению авторов [41], медиана более эффективно указывает на центр j -го измерения, поэтому в [41] среднее значение $\bar{x}_j(t)$ заменено на медиану.

В [42] разнообразие определяется через Евклидово расстояние относительно лучшего решения в популяции

$$Div = \frac{1}{N} \sum_{i=1}^N \sqrt{\sum_{j=1}^D (x_{ij}(t) - p_{jg}(t))^2}.$$

Разнообразие может быть определено как значение расстояния между лучшими решениями. В [43] это расстояние между всеми лучшими решениями, найденными каждой из частиц,

$$Div = \frac{2}{N(N-1)} \sum_{i=1}^{N-2} \sum_{j=i+1}^{N-1} |\mathbf{p}_i - \mathbf{p}_j|.$$

В [44] разнообразие определяется как значение расстояния между текущим и усредненным лучшим решением каждой частицы:

$$Div = \frac{1}{N} \sum_{i=1}^N |\mathbf{p}_i - \bar{\mathbf{p}}|.$$

В качестве показателя преждевременной сходимости в [45] рассматривается разность целевых функций лучших решений на двух итерациях:

$$\delta(t) = f(\mathbf{p}_g(t-1)) - f(\mathbf{p}_g(t)).$$

Констатируется преждевременная сходимость, если для заданного числа последовательных итераций значение $\delta(t)$ меньше заданного порога.

Мера разнообразия, основанная на относительном расстоянии частиц до глобально лучшей частицы, предложена в [45]:

$$Div = \max_{i=1, \dots, N} \frac{\|\mathbf{x}_i - \mathbf{p}_g\|}{\sqrt{\sum_{j=1}^D (x_{\max,j} - x_{\min,j})^2}}.$$

Популяционное разнообразие может быть определено на основе индекса квази-энтропии, который вычисляется по формулам [46]

$$QE(t) = - \sum_{i=1}^N P_i(t) \log P_i(t),$$

$$P_i(t) = \frac{f(\mathbf{p}_i(t))}{\sum_{i=1}^N f(\mathbf{p}_i(t))},$$

где $f(\mathbf{p}_i(t))$ — лучшее значение целевой функции i -й частицы на первых t итерациях. Авторы [46] предполагают, что на ранних стадиях оптимизации ни одна из частиц не находится в области глобального оптимального решения и индекс QE изменяется незначительно. На более поздних стадиях, когда все больше частиц попадают в область глобального оптимального решения, индекс QE резко уменьшается и, когда он достигнет определенной доли от начального значения, запускается локальный поиск.

Разнообразие в [44] определяется через распределение текущих скоростей частиц

$$Div = \frac{1}{N} \sum_{i=1}^N |\mathbf{v}_i - \bar{\mathbf{v}}_i|,$$

где $\mathbf{v}_i$, $\bar{\mathbf{v}}_i$ — текущее и среднее значения скорости i -й частицы соответственно.

Популяционное разнообразие может быть определено на основе значения целевой функции. В [1] популяционное разнообразие определяется по формуле

$$Div = \frac{\min(f_{best}, f_{avg})}{\max(f_{best}, f_{avg})},$$

где $f_{best}(t)$, $f_{worst}(t)$, $f_{avg}(t)$ — лучшее, худшее и среднее значения целевой функции.

В [16, 47] проведено исследование метрик разнообразия при поиске оптимума различных математических функций. Для исследования были выбраны метрики

$$\begin{aligned} \xi = Div &= \min \left\{ \left| \frac{f_{best} - f_{avg}}{f_{best}} \right|, 1 \right\}, \\ \nu = Div &= \min \left\{ \left| \frac{\sigma_f}{f_{avg}} \right|, 1 \right\}, \\ \psi = Div &= 1 - \left| \frac{f_{avg} - f_{best}}{f_{worst} - f_{best}} \right|, \\ \chi = Div &= 1 - \frac{|f_{best} - f_{avg}|}{\max |f_{best} - f_{avg}|_k}, \\ \varphi = Div &= \frac{\sigma_f}{|f_{worst} - f_{best}|}, \end{aligned} \tag{5}$$

где σ_f — стандартное отклонение от среднего значения целевой функции. Недостатками метрики ξ являются слабая устойчивость и сильная зависимость от области изменения целевой функции. Однако с ее помощью удается получить хороший результат для многомерных и сложных ландшафтов целевых функций, которые имеют ограниченный диапазон изменчивости и минимум у которых находится около нуля (например в инженерных задачах для минимизации ошибки). Метрика ν зависит от стандартного отклонения и, следовательно, от распределения значений целевой функции по всем элементам популяции. Эта метрика также как и ξ -метрика хорошо работает с целевыми функциями, имеющими ограниченный диапазон изменчивости, но она менее чувствительна к разбросам значений этих функций. В отличие от ξ - и ν -метрик, ψ не зависит от диапазона изменения значений целевой функции. Эта метрика очень чувствительна к небольшим изменениям и поэтому особенно подходит для ландшафтов целевых функций, содержащих плато и

области с небольшим градиентом. Метрика χ характеризует не только меру разнообразия, но и является оценкой лучшего результата по сравнению с другими решениями. Метрика φ может рассматриваться как комбинация ν - и ψ -метрик [16, 47].

Метрик разнообразия столько же, сколько проблем, т.е. метрики разнообразия специфичны для конкретной проблемы [48]. Не существует “наилучшей” метрики в целом, но есть “наиболее подходящая” метрика, зависящая не только от ландшафта целевой функции, но и от алгоритма оптимизации [16]. Автор [16] утверждает, что эффективная метрика разнообразия для эволюционной стратегии вряд ли будет эффективной для определения разнообразия для дифференциальной эволюции; это соображение автор [16] рассматривает как следствие теоремы об отсутствии бесплатных завтраков [7].

Разнообразие характеризует состояние популяции или распределение частиц. Большое значение Div означает, что поиск находится в состоянии диверсификации, малое значение свидетельствует о том, что поиск находится в состоянии интенсификации [40]. С помощью измерения разнообразия рассчитывается доля диверсификации и интенсификации на каждой итерации:

$$X_{dv} = \left(\frac{Div}{Div_{\max}} \right),$$

$$X_{it} = \left(\frac{|Div - Div_{\max}|}{Div_{\max}} \right).$$

Используя приведенные выше соотношения, можно поддерживать разнообразие популяции на достаточном уровне, не допуская ранней сходимости алгоритма. Механизмы поддержки популяционного разнообразия рассмотрены в разделе 6.

6. Механизмы поддержки популяционного разнообразия

Результаты поиска, выполняемого роевым алгоритмом, зависят от установленного или динамического баланса между двумя компонентами алгоритма: диверсификацией и интенсификацией. Успешно работающий компонент диверсификации обеспечит поиск на всем пространстве поиска, однако этот компонент может замедлить процесс сходимости алгоритма. Существуют несколько основных механизмов поддержания разнообразия: 1) ре-инициализация; 2) введение новых операторов: хаотических процедур и операторов кроссовера и мутации; 3) разделение популяции на субпопуляции.

6.1. Ре-инициализация

Ре-инициализация частиц является эффективным способом поддержания разнообразия, такой механизм способствует выходу частиц из локальных оптимумов и дает алгоритму возможность находить “достаточно хорошее” решение. Различают случайную ре-инициализацию, когда повторно генерируются большинство частиц, и элитную ре-инициализацию, когда сохраняются решения с лучшей целевой функцией [44].

В [49] новое решение генерируется на основе предыдущего решения путем добавления в него шума. По количеству повторно инициализированных решений определено три стратегии.

1. Количество ре-инициализированных решений уменьшается в процессе поиска. Более половины решений ре-инициализируются в начале поиска, а затем количество ре-инициализированных решений линейно уменьшается при каждой ре-инициализации. Эта стратегия заключается в том, чтобы сначала сосредоточиться на диверсификации, а в конце поиска — на интенсификации.

2. Часть решений повторно инициализируется после заданного числа итераций. Количество ре-инициализированных решений не меняется в процессе поиска.

3. Количество ре-инициализированных решений увеличивается в процессе поиска. Менее половины решений ре-инициализируются в начале поиска, и число ре-инициализированных решений линейно увеличивается при каждой ре-инициализации. Эта стратегия заключается в том, чтобы сначала сосредоточиться на интенсификации, а в конце поиска — на диверсификации.

В [50] ре-инициализация выполняется следующим образом: через заданное количество итераций в текущую популяцию из N решений добавляется еще N случайно сгенерированных решений; из полученных $2N$ решений выбираются N лучших; процесс повторяется заданное количество раз. В [51] предлагаются две стратегии ре-инициализации алгоритма роящихся частиц. Первая стратегия предполагает повторную инициализацию отдельных частиц, чье лучшее положение не улучшается после заданного числа итераций. Вторая стратегия подразумевает ре-инициализацию всей популяции, когда число лучших частиц в рое, имеющих значение целевой функции, близкое к значению целевой функции глобально лучшей частицы, превысит заданное пороговое значение. В [52] предлагается элитная схема ре-инициализации, когда случайным образом генерируются все решения за исключением лучшего, полученного на последней итерации, при условии, что после заданного числа итераций относительное улучшение значения целевой функции меньше порогового. В [45] активируется процедура ре-инициализации, если подтверждается состояние преждевременной сходимости или недостаточного популяционного разнообразия. В этом случае каждое решение заменяется на его противоположность, используя метод оппозиционного обучения.

6.2. Введение новых операторов

6.2.1. Эволюционные операторы

Операторы кроссовера и мутации, применяемые в эволюционных алгоритмах, все чаще применяются и в роевых алгоритмах для увеличения популяционного разнообразия [34, 53–56]. Оператор мутации, вносящий возмущение в решение $\mathbf{z} \in \mathbb{R}^D$, может быть определен как

$$\mathbf{x}' = \mathbf{x} + \mathbf{Z},$$

где $\mathbf{Z}$ — вектор случайных чисел, распределенных по заданному закону. Примерами являются операторы мутации на основе распределения Гаусса

Таблица 1. Описание операторов мутации

Схема	Оператор мутации
De/Best/1	$\mathbf{x} = \mathbf{p}_g + F \cdot (\mathbf{x}_{r1} - \mathbf{x}_{r2})$
De/Best/2	$\mathbf{x} = \mathbf{p}_g + F \cdot (\mathbf{x}_{r1} - \mathbf{x}_{r2} + \mathbf{x}_{r3} - \mathbf{x}_{r4})$
De/CurrToBest/1	$\mathbf{x} = \mathbf{x}_i + K \cdot (\mathbf{p}_g - \mathbf{x}_i) + F \cdot (\mathbf{x}_{r1} - \mathbf{x}_{r2})$
De/CurrToRand/1	$\mathbf{x} = \mathbf{x}_i + K \cdot (\mathbf{x}_{r3} - \mathbf{x}_i) + F \cdot (\mathbf{x}_{r1} - \mathbf{x}_{r2})$
De/Rand/1	$\mathbf{x} = \mathbf{x}_{r1} + F \cdot (\mathbf{x}_{r2} - \mathbf{x}_{r3})$
De/Rand/2	$\mathbf{x} = \mathbf{x}_{r5} + F \cdot (\mathbf{x}_{r1} - \mathbf{x}_{r2} + \mathbf{x}_{r3} - \mathbf{x}_{r4})$
De/RandToBest/1	$\mathbf{x} = \mathbf{x}_{r3} + K \cdot (\mathbf{p}_g - \mathbf{x}_{r3}) + F \cdot (\mathbf{x}_{r1} - \mathbf{x}_{r2})$

$(Z \sim N(\mu, \sigma^2))$ и Коши $(Z \sim C(x_0, \gamma))$. Динамическая регулировка параметров σ^2 и γ в процессе выполнения роевого алгоритма позволяет изменять баланс между диверсификацией и интенсификацией. Большие значения указанных параметров могут привести к появлению сильно возмущенных решений, малые значения параметров способствуют выполнению локального поиска.

Оператор мутации может быть основан не только на законах распределения. Популяционное разнообразие алгоритма роящихся частиц и гравитационного поиска в [57, 58] регулируется оператором мутации, построенным на основе вейвлета Морле:

$$x_{ij}(t+1) = \begin{cases} x_{ij}(t+1) + (x_{\max,j} - x_{ij}(t+1)), & \sigma > 0, \\ x_{ij}(t+1) + (x_{ij}(t+1) - x_{\min,j}), & \sigma \leq 0, \end{cases}$$

$$\sigma = \frac{1}{\sqrt{a}} e^{\left(\frac{z}{2}\right)} \cos\left(5\frac{z}{a}\right),$$

где a — масштабный коэффициент, $z \in [-2,5a; 2,5a]$.

Авторы [59] вводят в алгоритм гравитационного поиска знаковую мутацию:

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \mathbf{s}_i \cdot \Delta_i(t+1),$$

$$s_{ij} = \begin{cases} -1, & rand < P_s, \\ 1, & rand \geq P_s, \end{cases}$$

где Δ_i — модифицирующий вектор, вычисленный по оригинальной схеме гравитационного поиска, $\mathbf{s}_i$ — вектор мутации, P_s — вероятность мутации.

В роевых алгоритмах для увеличения популяционного разнообразия часто применяется оператор мутации, заимствованный из алгоритма дифференциальной эволюции [60–63]. В табл. 1 приведены операторы мутации [64], здесь $\mathbf{p}_g$ — лучшее решение в текущей популяции; F и K — коэффициенты масштабирования, действительные положительные числа; индексы $r_1, r_2, r_3, r_4, r_5 = \overline{1, N}$ — случайно сгенерированные целые числа, причем $r_1 \neq r_2 \neq r_3 \neq r_4 \neq r_5 \neq i$.

Оператор кроссовера на основе исходного списка решений генерирует новые решения путем “смешивания” информации о решениях из исходного списка. Оператор кроссовера $O(\mathbf{x}_i, \mathbf{x}_k, j)$ применяется для формирования нового решения путем изменения j -го элемента x_{ij} и x_{kj} в выбранных решениях. Новый элемент решения x_{lj} с использованием оператора арифметического кроссовера вычисляется по формуле

$$x_{lj} = \alpha x_{ij} + (1 - \alpha) x_{kj},$$

где α — коэффициент масштабирования, случайно выбранный из некоторого интервала. Элемент решения с применением геометрического кроссовера определяется по формуле

$$x_{lj} = (x_{ij} \cdot x_{kj})^\alpha, \quad \alpha \in [0, 1].$$

Случайный кроссовер формирует элемент решения по схеме

$$x_{lj} = \begin{cases} x_{ij}, & rand \leq 0,5, \\ x_{kj}, & rand > 0,5. \end{cases}$$

В [55] предложен оператор самоадаптирующегося кроссовера:

$$x_{lj}(t+1) = x_{ij}(t) \cdot (1 - Cr) + x_{kj}(t) \cdot Cr, \\ Cr = 0,8 + 0,2 \cdot \frac{f(\mathbf{x}_i(t)) - f(\mathbf{p}_g(t))}{f(\mathbf{p}_w(t)) - f(\mathbf{p}_g(t))},$$

где $\mathbf{p}_w$ и $\mathbf{p}_g$ — худшее и лучшее решения в популяции соответственно.

В [65] приведена классификация операторов кроссовера, применяемых в решении задач с непрерывно меняющимися параметрами, а также проведено эмпирическое исследование 14 операторов кроссовера при решении задач нахождения минимума математических функций. В [56] описан двухточечный полный кроссовер, в котором каждое из двух решений (оригинальное и его противоположность, полученная методом оппозиционного обучения) делится на три части двумя случайно выбранными точками. Новое решение формируется путем обмена частями исходных решений. Итоговые решения получаются после упорядочения по значению целевой функции шести новых решений и двух исходных.

Изменяя частоту (вероятность) применения операторов кроссовера и мутации в роевом алгоритме, можно регулировать баланс диверсификация–интенсификация.

6.2.2. Хаотические операторы

Существуют два способа включения хаоса в роевые алгоритмы оптимизации. Первый способ состоит в том, чтобы использовать последовательно, сгенерированные хаотическими системами, для замены случайных чисел, используемых в оригинальном алгоритме. Другой способ заключается

во включении хаотического поиска в качестве локального поиска в оригинальный алгоритм. Оба способа авторы [66] применяют в алгоритме гравитационного поиска для повышения скорости сходимости и решения проблемы выхода из локальных оптимумов. Двенадцать хаотических карт применяются для настройки значений коэффициентов инерции (ω_n, ω_f) в алгоритме стадо криля [54]. Хаотические последовательности используются в качестве генераторов псевдослучайных чисел в алгоритме искусственной пчелиной колонии [67], алгоритме роящихся частиц [68], алгоритме кузнечика [53].

6.3. Разделение популяции на субпопуляции

Многопопуляционные методы за последние десять лет стали одними из часто используемых методов оптимизации. Концепция этого метода следующая: исходная популяция делится на несколько субпопуляций; над элементами субпопуляции выполняются некоторые эволюционные операции; взаимодействуя между собой, субпопуляции обмениваются элементами, дробятся, поглощают друг друга, что способствует предотвращению преждевременной сходимости и поддержанию популяционного разнообразия путем распределения элементов по всему пространству поиска. Многопопуляционные методы сравнительно легко интегрируются в роевые алгоритмы оптимизации и часто работают эффективнее, чем алгоритмы с одной популяцией [69].

Многопопуляционные алгоритмы можно классифицировать на два типа: конкурирующие и кооперативные. Для алгоритмов конкурирующего типа каждая субпопуляция ищет решения в области, выделенной только для нее [70]. Кооперативные алгоритмы ведут поиск в одной и той же области, взаимодействуя и обмениваясь информацией [71].

В [69] обозначены проблемы и решения, характерные для многопопуляционных методов оптимизации. Первая проблема заключается в том, как определить количество субпопуляций: большое их количество связано с высокими вычислительными затратами, малое количество может не привести к желаемому эффекту. Указанная проблема решается двумя способами. Первый способ — использовать фиксированное количество субпопуляций. По этому способу функционирует большинство многопопуляционных методов. Его преимущество заключается в простоте реализации. Однако число субпопуляций определяется эмпирически, и трудно получить единые и эффективные правила для определения этого числа при решении различных практических задач. Второй способ заключается в динамическом изменении числа субпопуляций во время оптимизации. Выдвигается предположение, что на начальных этапах требуется большое количество субпопуляций для увеличения популяционного разнообразия и распределения возможных решений по всему пространству поиска. На поздних этапах небольшое количество субпопуляций способствует уменьшению разнообразия, что может быстрее приблизить решение к глобальному оптимуму.

Вторая проблема заключается в определении параметров коммуникации (миграции) между субпопуляциями. К таким параметрам относятся: 1) количество решений, подлежащих обмену; 2) коммуникационная (миграционная) политика, которая определяет, какие решения должны быть заменены реше-

ниями других субпопуляций; 3) частота коммуникаций; 4) топология коммуникаций. Чаще других применяется коммуникационная политика, основанная либо на жадном алгоритме, либо на случайном отборе, например элитарная политика миграции предполагает замену худших решений в субпопуляции лучшими решениями другой субпопуляции. Среди множества топологий можно выделить иерархическую и случайную топологии, а также линейные (цепочечные), кольцевые и решетчатые (клеточные) топологии, которые могут быть однонаправленными или двунаправленными.

Одной из широко применяемых многопопуляционных стратегий является модель островов [72], в которой популяция делится на несколько субпопуляций, называемых островами, эволюционирующие независимо друг от друга, но периодически взаимодействующие друг с другом посредством миграций. Схема взаимодействия, состоящая из последовательно происходящих процессов миграции и эволюции, позволяет создать баланс между диверсификацией и интенсификацией [18]. В [73] приводится динамическая островная модель, в которой размер популяции фиксирован, но размер каждой субпопуляции может меняться; топология задается полносвязным неориентированным графом. На каждой итерации алгоритма каждое решение мигрирует с исходного острова на остров назначения в соответствии с заданными вероятностями и динамически изменяющейся матрицей миграции, которая формируется с использованием алгоритма QLearning [74]; вместо единственной миграционной политики используется несколько миграционных политик.

В [18] предлагается иерархическая модель с 16 островами и четырьмя топологиями миграции. Острова нижних уровней ответственны за глобальный поиск, острова верхнего уровня выполняют локальный поиск. После каждой итерации лучшее решение мигрирует в соседнюю субпопуляцию верхнего уровня. Миграция между субпопуляциями одного уровня поддерживается путем замены лучшего решения текущей субпопуляции худшим решением соседнего острова.

Коммуникации могут быть синхронными или асинхронными. В первом случае все субпопуляции обновляют свои решения одновременно, тогда как во втором случае решения обновляются по наступлению какого-либо события. Обе модели имеют свои преимущества и недостатки. Синхронные островные модели проще в реализации, тогда как асинхронные модели являются более гибкими и эффективными [75]. Важным улучшением модели островов является слабосвязанная модель с виртуальным хранилищем совместно используемых данных, получившая название “океан” [76]. “Океан” позволяет легко реализовать гетерогенность и динамическое изменение числа островов, уменьшить задержку на обмен решениями за счет того, что “океан” хранит решения, которые были отправлены островом, но еще не приняты другим островом, — таким образом реализован асинхронный режим обмена решениями. В изложенном авторами [77] подходе на островах независимо работают четыре алгоритма: алгоритм пчелиной колонии для генерации правил нечеткого классификатора, алгоритм пчелиной колонии для оптимизации параметров, алгоритм адаптивной эволюционной стратегии и метод наименьших квадратов. “Океан” реализует обмен только множеством лучших решений, нахо-

дящихся в нем. Моменты отправки и приема лучших решений из “океана” выбирают сами алгоритмы, выполняющиеся на островах.

В клеточной топологии популяция делится на множество субпопуляций малого размера, обычно состоящих только из одного решения. Коммуникации происходят только в пределах небольшой окрестности, определенной вокруг отдельного решения или малой субпопуляции. При такой топологии снижается риск преждевременной сходимости по причине медленного распространения информации от соседа к соседу [78]. В качестве топологий окрестности в [79] рассматриваются три клеточные структуры — кубическая, тригональная и гексагональная, — интегрированные в алгоритм роящихся частиц. В [80] описан алгоритм роящихся частиц с клеточно-структурированной популяцией, частицы в которой распределены в двумерной сетке и взаимодействуют со своими соседями в соответствии с заданной окрестностью; авторы исследуют шесть типов окрестности: две линейные (L5, L9) и четыре компактных окрестности (C9, C25, C13, C21); для обработки краевых ячеек используется тороидальная структура.

Третья проблема многопопуляционных методов — как определить область поиска каждой субпопуляции. Одним из решений этой проблемы является кластеризация. Авторы [81] используют метод кластеризации для разделения популяции в алгоритме гравитационного поиска. При инициализации размер субпопуляции выбирается случайным образом из множества $T = \{5, 10, 25\}$. После каждого цикла работы алгоритма размер субпопуляции изменяется по результатам поиска. Если лучшее решение в субпопуляции не улучшается, из множества T случайным образом выбирается новое значение, в противном случае размер не меняется. В [82] предлагается многопопуляционный алгоритм роящихся частиц, который использует метод иерархической кластеризации, позволяющий адаптивно корректировать количество необходимых субпопуляций. Алгоритм кластеризации на основе нечетких s -средних в [83] используется для адаптивного разделения популяции на кластеры в алгоритме роящихся частиц. Для каждого кластера вычисляется его адаптивная ценность, полученная в результате конкурентного обучения. Кластеры ранжируются в соответствии с их ценностью. Кластеры с малой адаптивной ценностью поглощаются соседними кластерами, имеющими большую ценность.

Роевый алгоритм со структурированной популяцией имеет больше параметров, чем его аналог с единой популяцией. Дополнительно введенные параметры существенно влияют на работу алгоритма, поэтому настройка и регулировка этих параметров имеют важное значение для повышения эффективности алгоритма [75].

7. Настройка и регулировка значений параметров

Роевые алгоритмы характеризуются наличием стохастических компонентов и свободных параметров, которые могут быть установлены пользователем. Основная проблема здесь в том, что нет никакой гарантии, что хорошо настроенный алгоритм, хорошо работающий для одного типа проблем, может хорошо работать для другого типа проблем. Эффективность роевых алгоритмов во многом зависит от значений параметров, задаваемых в начале работы

и изменяемых в процессе выполнения алгоритма. По сути, это две проблемы: проблема автономной настройки и проблема регулировки значений параметров “на лету”. Процедура настройки параметров требует большого количества прогонов алгоритма для анализа его эффективности на одном или нескольких экземплярах проблем с различными настройками параметров. Процедура эта является вычислительно затратной, что является основным недостатком настройки параметров. Преимущество настройки параметров заключается в ее универсальности, хороший метод настройки применим для задания параметров многих различных метаэвристик. Недостатком регулировки параметров является ее узкая специализация, хорошо подобранные стратегии управления для одного алгоритма обычно не подходят для другого алгоритма [84].

7.1. Автономная настройка параметров

Автономная настройка параметров выполняется перед началом работы алгоритма. Цель состоит в том, чтобы априори найти лучшее сочетание значений параметров. Автономная настройка параметров является сложной проблемой из-за большого количества значений, которые может принимать каждый параметр. При этом необходимо учитывать, что параметры некоторых алгоритмов являются взаимозависимыми. Теоретический анализ, проведенный авторами [85], показал, что для обеспечения стабильной работы алгоритма роящихся частиц необходимо выполнение следующего соотношения между параметрами алгоритма:

$$(c_1 + c_2) < 24(1 - \omega^2) / (7 - 5\omega).$$

А в [86] условие сходимости алгоритма роящихся частиц определено как

$$1 > \omega > ((c_1 + c_2)/2 - 1) \geq 0.$$

На ранних этапах исследований метаэвристик настройка параметров осуществлялась либо “вручную” путем проведения серий экспериментов с различными конфигурациями параметров и выбора среди них лучшей на основе полученных результатов, либо “по аналогии” с применением настроек, показавших хорошие результаты при решении подобных проблем [87].

В последние два десятилетия проблеме автоматической настройки параметров стали уделять больше внимания [84, 87–91]. В [92] утверждается, что при разработке и создании нового метаэвристического алгоритма только 10 % времени тратится на разработку алгоритма, а 90 % времени уходит на тонкую настройку его параметров. Актуальность этой проблемы определяется следующим [89]:

1) использование методов автоматической настройки параметров может сократить затраты времени и позволит достичь лучших результатов по сравнению с ручными методами;

2) методы автоматической настройки могут помочь решить вопрос, превосходит ли один алгоритм другой, потому что он принципиально лучше или потому что его разработчики более успешно подобрали его параметры;

3) конечные пользователи часто не знают о влиянии настроек параметров алгоритма на его эффективность, поэтому просто используют настройки по умолчанию, однако конфигурация параметров по умолчанию может не работать должным образом для конкретных проблемных ситуаций, с которыми сталкивается пользователь;

4) автоматическая настройка параметров позволяет устранить необходимость пользователю устанавливать связь между настраиваемыми параметрами и решаемой проблемой.

Проблема настройки параметров может рассматриваться как проблема оптимизации, часто называемая мета-оптимизацией. Здесь алгоритм настройки является мета-оптимизатором, который ищет оптимальный (или по крайней мере хорошо работающий) набор параметров для целевого (настраиваемого) алгоритма. Сложность проблемы автоматической настройки обусловлена стохастической природой целевого алгоритма и метрики его эффективности [84, 90].

Конечной целью оптимизации является решение конкретных проблем, возникающих в реальном мире, но чтобы не решать каждую конкретную задачу отдельно и заново не начинать исследование с нуля, когда появляется новая задача, можно предположить, что некоторые из задач имеют общую структуру и могут рассматриваться как различные примеры общей проблемы. Этот шаг абстракции является фундаментальным для формального развития оптимизации и открывает путь к разработке алгоритмов и формальному анализу их свойств [88]. Если настройка алгоритма выполняется на одном примере проблемы, показателем эффективности может быть среднее значение показателя эффективности целевого алгоритма на нескольких прогонах. Показатель эффективности целевого алгоритма для множества примеров проблемы может быть определен как средняя эффективность алгоритма по данному множеству. Однако в некоторых случаях показатели эффективности могут сильно различаться, тогда показатели нормализуют для каждого примера [88]. Для нахождения оптимальной настройки параметров (или конфигурации) обычно требуется большое количество прогонов целевого алгоритма с разными конфигурациями на различных примерах. Таким образом, проблема настройки параметров является вычислительно дорогой и трудоемкой задачей [84].

Существующие методы автоматической настройки работают по принципу генерация–оценка, т.е. путем генерации различных конфигураций параметров и их оценки с помощью метрик эффективности [90, 91]. В качестве методов генерации часто используются методы планирования эксперимента [92–94], а также кригинг модели [95] и метод прямого поиска на адаптивных сетках [96]. Простым является метод повторной оценки параметров, который оценивает каждую конфигурацию несколько раз и возвращает среднее значение [90]. В методе грубой силы сначала генерируется семейство конфигураций параметров, как правило, с помощью методов планирования эксперимента, затем оценивается эффективность каждой конфигурации. В этом методе затраты на тестирование низкоэффективных конфигураций равны затратам на тестирование высокоэффективных конфигураций. Кроме того, здесь нет критерия, который определяет, сколько прогонов каждой конфигурации на

каждом экземпляре должно быть выполнено для обработки стохастичности целевого алгоритма [84]. Метод F-Race [88] поэтапно оценивает возможные конфигурации на примерах проблемы. После каждого этапа с использованием непараметрического теста Фридмана проверяется, есть ли статистически значимые отличия в показателях эффективности среди конфигураций-кандидатов. Если обнаружены значимые отличия, то после ранжирования кандидатов худшие отбрасываются и не участвуют в оценке на следующем этапе. Ранжирование в методе F-Race является еще и способом нормализации показателей эффективности, определяемых для разных примеров проблемы. В методе F-Race вычислительные ресурсы используются более эффективно, чем в методе грубой силы. Однако если целевой алгоритм имеет большое количество параметров и/или каждый параметр имеет большой диапазон изменений, тогда для получения хорошего результата необходимо оценить большое количество возможных конфигураций, что может стать практически невыполнимой задачей с точки зрения выполненных вычислений. К достоинствам методов F-Race и грубой силы относятся их понятность и простота реализации, с помощью этих методов можно настраивать как числовые, так и категориальные параметры [84].

Метод ParamILS [89] — это один из самых современных методов автоматической настройки параметров, с его помощью можно настраивать как числовые, так и категориальные параметры. В этом методе новая конфигурация параметров сравнивается с лучшей на текущий момент конфигурацией последовательности примеров проблемы. Если новая конфигурация хуже лучшей конфигурации, она исключается, иначе она оценивается на следующем примере и снова сравнивается с лучшей. Процесс продолжается до тех пор, пока новая конфигурация не будет оценена на всех примерах последовательности и будет определена новая лучшая конфигурация.

Перспективным подходом к решению проблемы настройки параметров является применение моделей поверхности отклика для описания зависимости эффективности целевого алгоритма от настроек его параметров. Процедура SPO [84] настраивает только числовые параметры и строит модель поверхности отклика, называемую моделью Кригинга. Метод SMAC работает как с числовыми, так и категориальными параметрами целевого алгоритма. Для построения поверхности отклика здесь используется случайный лес. Экспериментальное исследование показало, что с помощью SMAC удается получить лучшие результаты по сравнению с ParamILS. Метод SMAC особенно хорош при решении задач настройки со многими категориальными параметрами [84].

Подводя итог рассмотрения методов настройки параметров, можно утверждать, что эти методы выполняются до запуска настраиваемого алгоритма и выполняют поиск значений параметров, которые останутся фиксированными во время выполнения алгоритма. Кроме того, процессы настройки обычно включают несколько прогонов алгоритма, чтобы проанализировать его эффективность на разных значениях параметров с учетом его стохастической природы [97].

7.2. Регулировка значений параметров

Проблема регулировки значений параметров в роевых алгоритмах появилась одновременно с самими этими алгоритмами. В [98] отмечается, что изменение параметров в процессе выполнения алгоритма позволяет: искать решения, двигаясь в пространстве поиска большими шагами в начале работы алгоритма, и вести поиск оптимальных решений малыми шагами на последних этапах; алгоритму приспосабливаться к изменяющемуся ландшафту целевой функции; алгоритму накапливать информацию о целевой функции в процессе поиска и использовать эту информацию для повышения эффективности на поздних этапах и освобождает пользователя от необходимости выполнения этапа настройки значений параметров.

Методы регулировки значений параметров выполняются во время работы роевого алгоритма и изменяют значения его параметров во время выполнения алгоритма. Указанные методы могут быть разделены на две категории [99]: детерминированные и адаптивные. Детерминированные методы работают без обратной связи и следуют заранее установленному правилу при задании новых значений параметров. Адаптивные методы изменяют значения параметров на основе информации, получаемой после очередной итерации работы алгоритма.

Детерминированные методы регулировки значений параметров основаны исключительно на количестве пройденных итераций. В качестве примера рассмотрим методы регулировки коэффициента инерции алгоритма роящихся частиц, поскольку этот параметр в большей степени ответственен за соблюдение баланса между диверсификацией и интенсификацией. Несмотря на значительный объем исследований, многие стратегии изменения коэффициента инерции не изучены ни аналитически, ни эмпирически [100]. В табл. 2 приведены детерминированные методы регулировки коэффициента инерции; здесь

Таблица 2. Детерминированные методы изменения значения коэффициента инерции

Метод	Выражение	Ссылка
Случайное изменение	$\omega(t) = 0,5 + r(t)/2$	[101]
Линейное изменение	$\omega(t) = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \cdot (t/T)$	[102]
Нелинейное изменение	$\omega(t) = \omega_{\max} - (\omega_{\max} - \omega_{\min})(t/T)^{1/\pi^2}$	[103]
	$\omega(t) = \omega \cdot u^{-t}$	[104]
	$\omega(t) = (2/t)^{0,3}$	[105]
	$\omega(t) = \exp(-\exp((T-t)/T))$	[106]
	$\omega(t) = \omega_{\min} + (\omega_{\max} - \omega_{\min})e^{-10t/T}$	[107]
	$\omega(t) = \omega_{\min} + (\omega_{\max} - \omega_{\min})e^{-16t/T^2}$	
	$\omega(t) = \omega_{\max} + (\omega_{\min} - \omega_{\max}) \cdot \log_{10}(1 + 10t/T)$	[108]
Хаотическое изменение	$\omega(t) = 0,5z(t) + 0,5r(t)$	[109]
	$\omega(t) = z(t)\omega_{\min} + (\omega_{\max} - \omega_{\min}) \cdot (T-t)/T$	
Осциллирующее изменение	$\omega(t) = \begin{cases} ((\omega_{\min} + \omega_{\max})/2 + (\omega_{\max} - \omega_{\min})/2) \times \\ \times \cos(2\pi t(4k+6)/3T), & t < 3T/4, \\ \omega_{\min} & \text{иначе} \end{cases}$	[110]

Таблица 3. Адаптивные методы изменения значения коэффициента инерции

Метод	Выражение	Ссылка
Саморегуляция	$\omega(t) = \begin{cases} \omega(t-1) + \Delta\omega & \text{для лучшей частицы,} \\ \omega(t-1) - \Delta\omega & \text{для остальных частиц,} \end{cases}$ $\Delta\omega = \frac{\omega_{\max} - \omega_{\min}}{T}$	[112]
Адаптация на основе информации о скорости	$\omega(t) = \begin{cases} \max\{\omega(t-1) - \Delta\omega\}, & \bar{v}(t-1) \geq v_{ideal}(t), \\ \omega(t-1) - \Delta\omega, & \bar{v}(t-1) < v_{ideal}(t), \end{cases}$ $\bar{v}(t) = \frac{1}{N \cdot D} \sum_{i=1}^N \sum_{j=1}^D v_{ij} ,$ $v_{ideal}(t) = v_{\max} \left(\left(1 + \cos \left(\pi \frac{t}{T_{0,95}} \right) \right) / 2 \right)$	[113]
Адаптация на основе информации об успешности роя	$\omega(t) = 0,5r(t) + 0,5ssr(t-1)$	[114]
	$\omega(t) = (\omega_{\max} - \omega_{\min})(T-t)/T + \omega_{\min}ssr(t-1)$ $ssr(t) = \frac{\sum_{i=1}^N \begin{cases} 1, & f(\mathbf{p}_i(t)) < f(\mathbf{p}_i(t-1)), \\ 0, & f(\mathbf{p}_i(t)) \geq f(\mathbf{p}_i(t-1)) \end{cases}}{N}$	
Адаптация на основе факторов скорости изменения и степени агрегации	$\omega_i(t) = \omega_i(t-1) - (\omega_i(t-1) \exp(d(\mathbf{p}_g, \mathbf{p}_i) \cdot t/T))$	[106]
	$\omega(t) = \exp(-\exp(-d(\mathbf{p}_g, \mathbf{p}_i) \cdot (T-t)/T))$	
	$\omega_i(t) = \omega_{\max} - \alpha(1 - h_i(t)) + \beta \cdot s$ $h_i(t) = \left \frac{\min(f(\mathbf{p}_i(t-1)), f(\mathbf{p}_i(t)))}{\max(f(\mathbf{p}_i(t-1)), f(\mathbf{p}_i(t)))} \right $ $s = \left \frac{\min(f(\mathbf{p}_g(t)), \bar{f}(\mathbf{x}(t)))}{\max(f(\mathbf{p}_g(t)), \bar{f}(\mathbf{x}(t)))} \right $	[115]
	$\alpha, \beta \in [0, 1], \bar{f}(\bullet) - \text{среднее значение}$	

Таблица 4. Стратегии регулирования значений параметров c_1 и c_2

Стратегии	Состояния	c_1	c_2
Стратегия 1	Диверсификация	Увеличение	Уменьшение
Стратегия 2	Интенсификация	Незначительное увеличение	Незначительное снижение
Стратегия 3	Сходимость	Незначительное увеличение	Незначительное увеличение
Стратегия 4	Прыжок	Уменьшение	Увеличение

приняты обозначения: t — текущая итерация; T — максимальное число итераций; $r(t) \in [0, 1]$ — равномерно распределенное случайное число; $\omega \in [0, 1]$, $u \in [1,0001; 1,005]$; $z(t)$ — значение хаотического логистического отображения (Logistic Map).

Авторами [111] предложен детерминированный способ регулирования значений коэффициентов c_1 и c_2 алгоритма роящихся частиц:

$$\begin{aligned} c_1(t) &= c_{1i} + (c_{1f} - c_{1i}) \cdot t/T, \\ c_2(t) &= c_{2i} + (c_{2f} - c_{2i}) \cdot t/T, \end{aligned}$$

где c_{1i} и c_{2i} — начальные значения коэффициентов, c_{1f} и c_{2f} — конечные значения коэффициентов. В [111] рекомендовано использовать следующие начальные значения этих коэффициентов: $c_{1i} = c_{2f} = 2,5$, $c_{2i} = c_{1f} = 0,5$.

Адаптивные методы динамически регулируют параметры роевых алгоритмов в процессе их работы. В качестве средств адаптации используются такие характеристики, как средняя скорость, компактность роя, расстояние до лучшей частицы в рое. В табл. 3 приведены адаптивные методы регулирования коэффициента инерции.

Быстрая сходимость и уход из локальных оптимумов — две наиболее важные цели в исследовании роевых алгоритмов. Для достижения этих целей в [116] предложены четыре стратегии адаптивной регулирования коэффициентов ускорения алгоритма роящихся частиц (табл. 4).

Оценка состояния популяции основана на вычислении суммарного расстояния между частицами роя

$$f = (d_g - d_{\min}) / (d_{\max} - d_{\min}),$$

где $d_{\min}$, $d_{\max}$, d_g — минимальное, максимальное суммарное расстояние и суммарное расстояние до лучшей частицы в рое. Значение f относительно велико в состоянии диверсификации или прыжка и относительно мало в состоянии интенсификации или сходимости.

Коэффициент инерции ω уравнивает возможности глобального и локального поиска, в [116] значение ω адаптивно регулируется в соответствии с выражением:

$$\omega(f) = 1 / (1 + 1,5 \exp(-2,6f)).$$

Регулировка значений параметров c_1 и c_2 выполняется с помощью нечеткой системы типа сингтон, на вход которой подается значение f .

В последнее время увеличивается количество исследований, связанных с встраиванием хаоса в алгоритмы оптимизации. Использование хаоса усиливает диверсификационные и интенсификационные свойства алгоритмов оптимизации [53]. Стадии диверсификации и интенсификации в роевых алгоритмах регулируются хаотическим изменением их параметров: шага полетов Леви в алгоритме кукушкин поиск [117], гравитационных констант в гравитационном поиске [118], коэффициента c в алгоритме кузнечика [53], двух коэффициентов — γ и β — в алгоритме светлячков [119], четырех параметров в алгоритме летучих мышей [120].

Нечеткие системы достаточно часто используются для регулировки параметров роевых алгоритмов. В [121] адаптивная нечеткая схема построена на вычислении разности значений целевой функции лучших решений на двух последних итерациях алгоритма роящихся частиц (df). Предлагаются следующие нечеткие правила регулировки значений параметров c_1 и c_2 :

ЕСЛИ df маленькое, ТО c_1 большое, c_2 маленькое,
 ЕСЛИ df среднее, ТО c_1 среднее, c_2 среднее,
 ЕСЛИ df большое, ТО c_1 маленькое, c_2 большое.

Входная переменная df и выходные переменные c_1 и c_2 представлены тремя нечеткими термами: маленькое, среднее, большое.

В [122] для модификации параметров c_1 и c_2 построены три нечеткие системы типа Мамдани с разными входными переменными, в качестве которых используются нормированные значения: а) популяционного разнообразия, б) усредненной разности между значением целевой функций каждой частицы и значением целевой функции лучшей частицы, в) итерации. Все входные переменные представлены тремя равномерно распределенными на интервале $[0; 1]$ нечеткими термами с треугольными функциями принадлежности. Выходные переменные (c_1 и c_2) представлены пятью равномерно распределенными на интервале $[0,5; 2,5]$ нечеткими термами с треугольными функциями принадлежности. Входными переменными для первой нечеткой системы являются итерации и разнообразие, для второй — итерации и усредненная разность, для третьей — итерации, разнообразие и усредненная разность. Первые две системы имеют по девять нечетких правил, третья — 27.

В модифицированном алгоритме роящихся частиц FAIPSO [123] коэффициенты c_1 и c_2 корректируются с применением нечеткой системы, которая имеет шесть входных переменных, содержащих информацию о расстояниях между частицами, два выхода (c_1 и c_2) и десять нечетких правил. Компромисс между диверсификацией и интенсификацией при решении задач оптимизации с использованием гравитационного алгоритма достигается изменением значения ускорения, для этого авторы [124] применяют нечеткую систему типа 2. Системы этого же типа используются в [125] для регулировки параметров алгоритма летучих мышей, а в [126] — для динамической адаптации параметров алгоритма пчелиной колонии.

Размер популяции — параметр, присутствующий во всех роевых алгоритмах и влияющий на их эффективность. В [23] предложено адаптивное изменение размера популяции в зависимости от популяционного разнообразия;

максимальное количество итераций делится на равные периоды, каждый из которых содержит равное количество итераций; в конце каждого периода вычисляется разнообразие популяции и в зависимости от его значения размер популяции либо увеличивается, либо уменьшается.

Методы регулировки значений параметров включаются в исходный алгоритм, что приводит к увеличению вычислительной и временной сложности алгоритма. Одним из вариантов решения этой проблемы является разработка роевых алгоритмов без параметров, но этот подход требует детального изучения [6]. Существует еще ряд открытых вопросов, связанных с настройкой и регулировкой параметров. Необходимо теоретическое обоснование существования зависимости эффективности роевого алгоритма от его параметров. Необходимы разработки схем адаптации параметров для сложных задач оптимизации, таких как многоцелевая оптимизация, оптимизация с ограничениями, крупномасштабная оптимизация, оптимизация в динамических и неопределенных средах. Необходимы исследования применения методов машинного обучения для решения проблем настройки и регулировки параметров роевых алгоритмов, частично эта проблема рассматривается в разделе 8 обзора.

8. Гибридизация

Создатели метаэвристических алгоритмов сталкиваются с трудно разрешимой проблемой: как найти хороший баланс между диверсификацией и интенсификацией; в одном алгоритме практически невозможно сбалансировать указанные компоненты [127]. Задачи оптимизации могут быть более эффективно решены путем гибридизации существующих алгоритмических структур. Основная цель гибридизации заключается в использовании уникальных особенностей и преимуществ каждого алгоритма для достижения компромисса между диверсификацией и интенсификацией, а также для предотвращения преждевременной сходимости путем использования сильных сторон каждого из компонентов в соответствующем алгоритме. Однако создание эффективного гибридного алгоритма является сложным процессом, который требует обширных знаний и большого опыта в создании систем оптимизации [128].

В [129] приведена следующая классификация гибридных алгоритмов:

1) портфельные алгоритмы — это библиотека последовательно работающих алгоритмов поиска;

2) гиперэвристика — это библиотека алгоритмов поиска, снабженная механизмом координации, который выбирает и активизирует различные алгоритмы или генерирует специальные компоненты поиска;

3) меметические алгоритмы — это структура, которая содержит основной решатель и несколько алгоритмов локального поиска; 4) ансамбль алгоритмов — алгоритмическая структура, в которую входят стратегии поиска и общие компоненты решения проблем оптимизации.

Авторы [129] указывают на то, что классификация скорее отражает исторический путь гибридизации, чем выявляет алгоритмические различия в подходах.

Роевые алгоритмы показывают хорошие результаты на стадии диверсификации, но существенно уступают традиционным методам на стадии интенсификации; при приближении к оптимуму метаэвристические методы уступают градиентным. Комбинирование глобального поиска на уровне популяции и локального поиска на уровне отдельного решения получило развитие в области меметических алгоритмов [49]. Меметические алгоритмы — класс алгоритмов оптимизации, в структуру которых включены компоненты популяционных метаэвристик и процедуры локального поиска. Термин “меметический алгоритм” вытекает из того факта, что процедура локального поиска сродни мему, представляющему некоторую форму предметно-специфических априорных знаний человека-эксперта о том, как можно улучшить решение. В гибридных алгоритмах мемы воспринимаются как инструкции, правила, стратегии, априорные знания [130].

Авторы [131] разделяют меметические алгоритмы на три основных класса:

1) алгоритмы с одним фиксированным мемом или локальным оператором поиска, применяемым к решению, сформированному популяционной метаэвристикой;

2) алгоритмы с пулом заданных локальных операторов поиска (мемов), которые конкурируют между собой; выбор мема может быть основан на различных критериях, таких как абсолютное значение целевой функции решений, связанных с мемом, или улучшение значения целевой функции в результате прошлых применений мема;

3) эволюционирующие мемы с априори неизвестным пулом мемов, которые автоматически адаптируются к ландшафту целевой функции.

Процедура локального поиска, используемая в меметических алгоритмах, имеет как детерминированный, так и стохастический характер. В качестве детерминированных процедур часто используются алгоритмы Хука–Дживса [132] и Нелдера–Мида [133], а также градиентные и квазиньютоновские методы [134]. Стохастические процедуры в меметических алгоритмах представлены поиском с запретами [135], имитационным отжигом [6, 133], хаотическим локальным поиском [136]. Глобальный и локальный поиск в гибриде, предложенном в [127], выполняется двумя операторами, основанными на полетах Леви и поисковых выражениях алгоритма крилья соответственно.

В большинстве меметических алгоритмов локальный поиск применяется только к текущему глобально лучшему решению по причине того, что 1) окрестность такого решения может быть наиболее перспективной для поиска глобального оптимума; 2) экономится время выполнения по сравнению со схемами, которые применяют локальный поиск ко всем решениям.

В [137] предложены три схемы, комбинирующие алгоритм роящихся частиц с локальным поиском:

Схема 1. Локальный поиск применяется к глобально лучшему решению $\mathbf{p}_g$;

Схема 2. Локальный поиск применяется к лучшему решению i -й частицы $\mathbf{p}_i$ при условии, что случайно сгенерированное число $r < \varepsilon$, где $\varepsilon > 0$ — заданный порог;

Схема 3,а. Локальный поиск применяется как к глобально лучшему решению $\mathbf{p}_g$, так и к некоторым случайно выбранным решениям $\mathbf{p}_i$;

Схема 3,б. Локальный поиск применяется как к глобально лучшему решению $\mathbf{p}_g$, так и к некоторым случайно выбранным решениям $\mathbf{p}_i$, для которых $|\mathbf{p}_g - \mathbf{p}_i| > c(S)$, где $A \in (0, 1)$ и (S) — размер поискового пространства S .

Приведенные три схемы могут применяться либо на каждой итерации алгоритма, либо на некоторых итерациях. Существуют и другие схемы, например применяющие локальный поиск ко всем частицам, однако такие схемы являются вычислительно затратными, на практике локальный поиск должен применяться только к небольшому количеству частиц (порядка 5 % от общего числа) [137].

В [138] предложен алгоритм роящихся частиц с двумя адаптивными методами локального поиска. Первый метод выполняет случайное перемещение от текущего решения, уменьшая на каждой итерации длину шага. Во втором методе процедуру локального поиска можно рассматривать как итеративное локальное движение частицы, когда поиск направляется лучшим решением i -й частицы без учета глобально лучшего решения:

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + w \cdot \mathbf{v}_i(t) + c_1 \cdot \text{rand} \cdot (\mathbf{p}_i(t) - \mathbf{x}_i(t)).$$

В [139] предложен меметический алгоритм на основе алгоритма искусственной пчелиной колонии, методов Нелдера–Мида и случайного блуждания. Для поддержания баланса диверсификация/интенсификация используется адаптивная схема:

$$\begin{cases} \text{если } \text{rand}(0,1) > p(\psi), \text{ то использовать Метод Нелдера–Мида,} \\ \text{в противном случае использовать метод случайных блужданий.} \end{cases}$$

Значения $p(\psi)$ находятся из экспоненциального распределения

$$p(\psi) = e^{-\frac{(\psi - \mu_p)}{2\sigma_p^2}},$$

где ψ — значение меры разнообразия (5), μ_p , σ_p — среднее значение и стандартное отклонение меры разнообразия соответственно.

Оптимальный баланс между глобальным и локальным поиском явно зависит от решаемой задачи оптимизации, применяемого меметического алгоритма и настроек его параметров. Поэтому невозможно разработать универсальные принципы проектирования роевых алгоритмов, всегда приводящие к лучшим решениям [140]. Существование таких универсальных принципов противоречит теореме о бесплатных завтраках [7].

8.2. Ансамбли

Одним из подходов к повышению эффективности роевых алгоритмов является ансамблевая стратегия. В контексте проблемы оптимизации понятие “ансамбль” связано с использованием нескольких операторов и стратегий поиска, субпопуляций, алгоритмов, значений параметров для решения задачи

оптимизации. Ансамбли могут быть разделены на низкоуровневые и высокоуровневые. В ансамбль низкого уровня объединены различные типы операторов и стратегий поиска. Высокоуровневые ансамбли относятся к методам, которые для данной задачи адаптивно выбирают лучший алгоритм оптимизации из набора алгоритмов-кандидатов [141].

В [22] предлагается ансамбль стратегий адаптивного изменения коэффициента инерции в алгоритме роящихся частиц. Линейное или нелинейное уменьшение значения коэффициента инерции для каждой частицы определяется предысторией; если стратегия, выбранная на предыдущей итерации, приводит к лучшему решению, тогда назначенная стратегия сохраняется, в противном случае меняется. В [68] описан ансамбль из шести хаотических карт для генерации псевдослучайных чисел, используемых для формирования вектора скорости в алгоритме роящихся частиц. В начале работы алгоритма каждой частице случайным образом назначается одна из шести карт; если частица не улучшает свое положение в течение 20 итераций, ей назначается другая хаотическая карта. В [142] описан алгоритм роящихся частиц, в котором скорости частицы вычисляются с помощью одного из четырех операторов, ответственных за сходимость, интенсификацию, диверсификацию и “выпрыгивание” из локальных оптимумов. Выбор одного из четырех операторов основан на предложенной авторами адаптивной стратегии.

В модифицированном алгоритме искусственной пчелиной колонии МЕАВС используется ансамбль из трех стратегий поиска решений [143]:

1) стратегия, принятая в оригинальном алгоритме, когда новое решение генерируется путем перемещения старого решения к случайно выбранному из популяции решению;

2) стратегия ABC/best, повторяющая первую, в которую добавлена информация о лучшем решении в популяции;

3) модифицированная стратегия ABC/best/1, основанная на мутации DE/best/1 [64].

Указанные стратегии динамически меняются в процессе поиска, соревнуясь между собой при генерации нового решения, что позволяет сбалансировать процессы диверсификации и интенсификации. Эффективность МЕАВС проверялась экспериментально на множестве тестовых функций. По сравнению с оригинальным алгоритмом искусственной пчелиной колонии и двумя его модификациями МЕАВС показал более высокую скорость сходимости и более точные решения. Алгоритм МЕАВС оказался лучшим при сравнении с пятью модификациями алгоритма роящихся частиц, равным по эффективности третьей модификации при решении сложных мультимодальных задач и уступил этой модификации при поиске оптимума на нескольких математических функциях. Однако авторы утверждают, что МЕАВС проще и требует настройки меньшего количества параметров при одинаковой вычислительной временной сложности [143].

К высокоуровневым методам относится ансамбль алгоритмов роящихся частиц с самоадаптивным механизмом выбора лучшего алгоритма [144]. Ансамбль состоит из пяти разных алгоритмов роящихся частиц, каждый из которых используется для выполнения определенных задач, а именно: обес-

печения высокой скорости сходимости, для предотвращения преждевременной сходимости, для поддержания популяционного разнообразия, для увеличения возможностей локального поиска, для поиска нескольких локальных оптимумов при мультимодальной оптимизации. Выбор наиболее подходящего алгоритма на текущей итерации выполняется на основе механизма самоадаптации.

Хотя за последнее десятилетие были достигнуты впечатляющие результаты в разработке и исследовании ансамблевых стратегий в оптимизации, существует ряд открытых проблем, требующих решения, далее приведены некоторые из них [141].

1. В настоящее время количество элементов, включенных в ансамбль, относительно невелико, было бы полезно включить в ансамбль большее количество элементов с различными характеристиками. Однако пока неизвестно, как реализовать крупномасштабный ансамбль, насколько он будет надежен и эффективен.

2. Нерешенной проблемой остается определение характеристики алгоритмических компонентов, входящих в ансамбль. Необходимо разработать адекватные метрики описания компонентов, а также методы формирования ансамбля на основе этих метрик.

3. Эффективность стратегии ансамбля обычно проверяется с помощью эксперимента. Необходим теоретический анализ компонентов ансамбля и описание эффекта от каждого из них.

4. Наличие множества различных алгоритмических компонентов может вызвать нестабильность ансамбля по причине случайности, присущей этим компонентам. В реализацию ансамбля должны быть включены оценки изменения целевой функции и популяционного разнообразия, а также механизмы взаимодействия между различными компонентами.

8.3. Гиперэвристика

Эффективность метаэвристических алгоритмов зависит от решаемых задач. В общем случае неизвестно, какой алгоритм лучше всего подходит для данной задачи. Как следствие, выбор наиболее подходящей метаэвристики для конкретной задачи обычно является непростой задачей. Альтернативой экспертному поиску лучшего алгоритма для конкретной задачи оптимизации является гиперэвристика, которая обеспечивает универсальный эвристический подход к решению сложных задач оптимизации. Гиперэвристика ориентирована не на решение конкретной задачи, а на поиск (мета)эвристики или их последовательностей, которые будут решать конкретную задачу. Отличие метаэвристики от гиперэвристики в том, что первая работает в пространстве решений, а вторая в пространстве (мета)эвристик.

С точки зрения пространства поиска различают гиперэвристики, которые либо выбирают, либо генерируют (мета)эвристики низкого уровня, используемые в дальнейшем для решения конкретной задачи оптимизации. Гиперэвристику можно рассматривать как алгоритм обучения либо в режиме офлайн, либо в режиме онлайн. Онлайн обучение проводится в процессе решения проблемы, офлайн обучение заключается в формировании правил из

множества обучающих примеров. Среди подходов, основанных на онлайн-обучении, можно выделить подходы, основанные на обучении с подкреплением для выбора эвристики нижнего уровня, и подходы, которые применяют метаэвристику для поиска эвристики, работающей в пространстве решений [145].

Гиперэвристика на основе выбора строится следующим образом [146]:

- 1) выбрать множество эвристик низкого уровня для решения задач оптимизации, причем, не обязательно, чтобы каждая из них была высокоэффективной при решении поставленной задачи, но их число должно быть достаточно большим, чтобы генерировать большое пространство поиска;
- 2) определить алгоритм высокого уровня, который может быть обучающим автоматом или метаэвристикой (эволюционный алгоритм, алгоритм муравьиной колонии, роевый алгоритм);
- 3) определить процедуру кодирования для поиска низкоуровневых эвристик.

Подавляющее большинство гиперэвристик разработаны для дискретных пространств поиска. Далее приведены несколько гиперэвристик, работающих в непрерывных пространствах. Гиперэвристика DEWCO [147], используя на верхнем уровне алгоритм дифференциальной эволюции, формирует оптимальную начальную популяцию алгоритма китов. В выборе участвуют метод оппозиционного обучения и множество хаотических карт. Гиперэвристика H3AD [148] сочетает в себе два подхода: генерацию и выбор. В основе генерации лежит база знаний, которая содержит примеры алгоритмов, созданных для набора репрезентативных задач, вместе с описанием характерных признаков этих задач. Решение новой задачи начинается с выбора из базы знаний по представленным признакам наиболее похожей задачи и алгоритма, ранее сгенерированного для решения этой задачи. Гиперэвристика H3AD применяется для определения адекватных конфигураций параметров и компонентов алгоритма роящихся частиц. Для формирования компонентов алгоритма используется генетическое программирование, которое определяет такую процедуру, как, например, стратегия инициализации популяции. Выбор алгоритма роящихся частиц выполняется с использованием метода рассуждений по прецедентам.

В гиперэвристику HyperSPAM [129] включены три алгоритма решения задач оптимизации в непрерывном пространстве поиска. Алгоритм эволюционной стратегии с ковариационной матрицей адаптации активируется в начале процесса оптимизации в качестве компонента предварительной обработки. Далее полученное решение подается на два других алгоритма поиска. Первый выполняет перемещения по осям, а второй использует матричную ортогонализацию для выполнения диагональных перемещений. Четыре адаптивные стратегии используются для координации работы алгоритмов поиска. Первая стратегия является простым случайным выбором, а остальные три применяют механизм вознаграждения, основанный на успехах алгоритма поиска на предыдущих итерациях.

9. Открытые проблемы

Хотя за последние десятилетия исследование роевых алгоритмов продвинулось далеко вперед, остается еще ряд открытых проблем. Часть этих проблем затронута в обзоре, но в большинстве своем решаются эти проблемы на эмпирическом уровне. Далее рассмотрены некоторые актуальные проблемы в исследовании роевых алгоритмов [141, 149].

1. Эффективность роевого алгоритма напрямую связана с установлением оптимального баланса между диверсификацией и интенсификацией. Однако ни один алгоритм не может претендовать на решение проблемы достижения такого баланса. По сути, сам баланс является проблемой гипероптимизации, потому что это оптимизация алгоритма оптимизации.

2. Отсутствие единой математической структуры для всестороннего изучения роевых алгоритмов, позволяющей анализировать сложность, устойчивость, сходимость, соотношение точности решения и вычислительных затрат, настройку и регулировку параметров. Разработка такой структуры потребует междисциплинарного подхода для объединения различных математических, стохастических и численных методов.

3. Отсутствие унифицированной тестовой среды с комплексным набором метрик для сравнения результатов работы различных роевых алгоритмов. Показателем эффективности работы алгоритма чаще всего является точность. Однако если не учитывать время работы, то точность не будет адекватной оценкой работы алгоритма. Практика современного тестирования использует набор математических функций с различными свойствами, однако реальные задачи гораздо более разнообразны, они могут иметь много нелинейных ограничений, образованных несколькими изолированными областями. Таким образом, алгоритмы, хорошо работающие на тестовых функциях, могут быть неэффективными при решении реальных задач.

4. Масштабируемость роевых алгоритмов. Открытой остается проблема, как наилучшим образом изменить алгоритмы, хорошо работающие на задачах небольшой размерности (с числом переменных от нескольких единиц до нескольких сотен), для эффективного решения задач большой (больше тысячи переменных) и очень большой размерности.

5. Проблемой отдаленного будущего является создание интеллектуальных алгоритмов и систем, способных распознавать особенности решаемой задачи и выбирать или проектировать подходящий алгоритм.

10. Заключение

В статье рассмотрены некоторые подходы к повышению эффективности роевых алгоритмов оптимизации. Модульная структура роевых алгоритмов позволяет изменять входящие в них компоненты. Для задания популяции начальных решений используется метод инициализации или комбинация этих методов. Новое решение формируется как операторами оригинального алгоритма, так и эволюционными или хаотическими операторами. Лучшие решения получены путем гибридизации роевых алгоритмов с использованием различных стратегий. В разработке и исследовании роевых алгоритмов оп-

тимизации существует ряд нерешенных проблем, некоторые из них указаны в обзоре.

К настоящему времени в литературе представлено большое количество результатов исследований, невозможно охватить все соответствующие публикации в пределах заданного объема статьи. В обзоре не рассмотрены критерии остановки работы роевых алгоритмов [150], их квантовые модификации [151], а также аппаратная реализация роевых алгоритмов на основе облаков, вычислительных кластеров и графических процессоров [152–154].

СПИСОК ЛИТЕРАТУРЫ

1. *Li Q., Liu S.-Y., Yang X.-S.* Influence of Initialization on the Performance of Metaheuristic Optimizers // *Appl. Soft Comput.* 2020. V. 91. 106193.
2. *Luke S.* Essentials of Metaheuristics [Электронный ресурс]. Режим доступа: <https://cs.gmu.edu/~sean/book/metaheuristics/>
3. *Boussaid I., Lepagnot J., Siarry P.* A Survey on Optimization Metaheuristics // *Inf. Sci.* 2013. V. 237. P. 82–117.
4. *Kirkpatrick S., Gelatt C.D., Vecchi M.P.* Optimization by Simulated Annealing // *Science.* 1983. V. 220. P. 671–680.
5. *Glover F.* Future Paths for Integer Programming and Links to Artificial Intelligence // *Comput. Oper. Res.* 1986. V. 13. P. 533–549.
6. *Nematollahi A.F., Rahiminejad A., Vahidi B.* A Novel Meta-Heuristic Optimization Method Based on Golden Ratio in Nature // *Soft Comput.* 2020. V. 24. P. 1117–1151.
7. *Wolpert D., Macready W.* No Free Lunch Theorems for Optimization // *IEEE Trans. Evol. Comput.* 1997. V. 1. P. 67–82.
8. *Clerc M.* From Theory to Practice in Particle Swarm Optimization / *Handbook of Swarm Intelligence.* V. 8. Berlin: Springer, 2011. P. 3–36.
9. *Sorensen K.* Metaheuristics—The Metaphor Exposed // *Int. Trans. Oper. Res.* 2015. V. 22. No. 1. P. 3–18.
10. *Camacho-Villalon C.L., Dorigo M., Stützle T.* The Intelligent Water Drops Algorithm: Why It Cannot Be Considered a Novel Algorithm // *Swarm Intell.* 2019. V. 13. P. 173–192.
11. *Weyland D.* A Rigorous Analysis of the Harmony Search Algorithm: How The Research Community Can Be Misled by a “Novel” Methodology // *Int. J. Appl. Metaheuristic Computing.* 2010. V. 1. P. 50–60.
12. *Geem Z.W., Kim J.H., Loganathan G.V.* A New Heuristic Optimization Algorithm: Harmony Search // *Simulation.* 2001. V. 76. P. 60–68.
13. *Piotrowski A.P., Napiorkowski J.J., Rowinski P.M.* How Novel is the “Novel” Black Hole Optimization Approach? // *Inf. Sci.* 2014. V. 267. P. 191–200.
14. *Hatamlou A.* Black Hole: A New Heuristic Optimization Approach for Data Clustering // *Inf. Sci.* 2013. V. 222. P. 175–184.
15. *Shah-Hosseini H.* The Intelligent Water Drops Algorithm: A Nature-Inspired Swarm-Based Optimization Algorithm // *Int. J. Bio-Inspired Computation.* 2009. V. 1. No. 1/2. P. 71–79.
16. *Neri F.* Diversity Management in Memetic Algorithms // *Handbook of Memetic Algorithms.* 2012. SCI. V. 379. P. 153–165.

17. Cuevas E., Oliva D., Zaldivar D., Perez-Cisneros M., Pajares G. Opposition-Based Electromagnetism-Like for Global Optimization // Int. J. Innov. Comput. I. 2012. V. 8. No. 12. P. 8181–8198.
18. Turgut M.S., Turgut O.E., Eliiyi D.T. Island-based Crow Search Algorithm for Solving Optimal Control Problems // Appl. Soft Comput. 2020. V. 90. 106170.
19. Ходашинский И.А., Дудин П.А. Идентификация нечетких систем на основе прямого алгоритма муравьиной колонии // Искусственный интеллект и принятие решений. 2011. № 3. С. 26–33.
20. Kennedy J., Eberhart R. Particle Swarm Optimization // Proc. 1995 IEEE Int. Conf. Neural Networks. Perth: IEEE Service Center, 1995. P. 1942–1948.
21. Yang X.-S., Deb S. Engineering Optimisation by Cuckoo Search // Int. J. Math. Modelling and Numerical Optimisation. 2010. V. 1. No. 4. P. 330–343.
22. Shirazi M.Z., et al. Particle Swarm Optimization with Ensemble of Inertia Weight Strategies // ICSI 2017. LNCS. V. 10385. Heidelberg: Springer, 2017. P. 140–147.
23. Chen D.B., Zhao C.X. Particle Swarm Optimization with Adaptive Population Size and Its Application // Appl. Soft Comput. 2009. V. 9. No. 1. P. 39–48.
24. Chen L., Lu H., Li H., Wang G., Chen L. Dimension-by-Dimension Enhanced Cuckoo Search Algorithm for Global Optimization // Soft Comput. 2019. V. 23. P. 11297–11312.
25. Singh A., Deep K. Artificial Bee Colony Algorithm with Improved Search Mechanism // Soft Comput. 2019. V. 23. P. 12437–12460.
26. Gupta S., Deep K. Cauchy Grey Wolf Optimiser for Continuous Optimisation Problems // J. Exp. Theor. Artif. Intell. 2018. V. 30. P. 1051–1075.
27. Kazimipour B., Omidvar M.N., Li X., Qin A. A Novel Hybridization of Opposition-Based Learning and Cooperative Co-Evolutionary for Large-Scale Optimization / Proc. IEEE Congr. on Evolutionary Computation. Beijing, 2014. P. 2833–2840.
28. Pant M., Thangaraj R., Abraha A. Low Discrepancy Initialized Particle Swarm Optimization for Solving Constrained Optimization Problems // Fundamenta Informaticae. 2009. V. 95. P. 511–531.
29. Brits R., Engelbrecht A.P., van den Bergh F. A Niching Particle Swarm Optimizer // Proc. 4th Asia-Pacific Conf. Simulated Evol. Learning. 2002. P. 692–696.
30. Altinoz O.T., Yilmaz A.E., Weber G. Improvement of the Gravitational Search Algorithm by Means of Low-Discrepancy Sobol Quasi Random-Number Sequence Based Initialization // Adv. Electr. Comp. Eng. 2014. V. 14. No. 3. P. 55–62.
31. Mahdavi S., Rahnamayan S., Deb K. Opposition Based Learning: A Literature Review // Swarm Evol. Comput. 2018. V. 39. P. 1–23.
32. Rahnamayan S., Tizhoosh H.R., Salama M. Opposition-Based Differential Evolution // IEEE Trans. Evol. Comput. 2008. V. 12. No. 1. P. 64–79.
33. Farooq M.U., Ahmad A., Hameed A. Opposition-Based Initialization and a Modified Pattern for Inertia Weight (IW) in PSO // Proc. IEEE Int. Conf. Innov. Intel. Sys. Appl (INISTA). 2017. Number: 17083603.
34. Wang G.-G., Deb S., Gandomi A.H., Alavi A.H. Opposition-Based Krill Herd Algorithm with Cauchy Mutation and Position Clamping // Neurocomputing. 2016. V. 177. P. 147–157.
35. Gao W.-f., Liu S.-y., Huang L.-l. Particle Swarm Optimization with Chaotic Opposition-Based Population Initialization and Stochastic Search Technique // Commun. Nonlinear Sci. Numer. Simulat. 2012. V. 17. P. 4316–4327.

36. *Kazimipour B., Li X., Qin A.K.* A Review of Population Initialization Techniques for Evolutionary Algorithms // Proc. IEEE Congr. Evol. Comput. Beijing, 2014. P. 2585–2592.
37. *Melo V.V., Botazzo Delbem A.C.* Investigating Smart Sampling as a Population Initialization Method for Differential Evolution in Continuous Problems // Inf. Sci. 2012. V. 193. P. 36–53.
38. *Grobler J., Engelbrecht A.P.* A Scalability Analysis of Particle Swarm Optimization Roaming Behaviour // ICSI 2017. LNCS. V. 10385. Heidelberg: Springer, 2017. P. 119–130.
39. *Gao W.-f., Liu S.-y., Huang L.-l.* Enhancing Artificial Bee Colony Algorithm using More Information-Based Search Equations // Inf. Sci. 2014. V. 270. P. 112–133.
40. *Cheng S., Shi Y., Qin Q.* Experimental Study on Boundary Constraints Handling in Particle Swarm Optimization: From Population Diversity Perspective // Int. J. Swarm Intell. Res. 2011. V. 2. P. 43–69.
41. *Salleh M.N.M., et al.* Exploration and Exploitation Measurement in Swarm-Based Metaheuristic Algorithms: An Empirical Analysis / Recent Advances on Soft Computing and Data Mining. Springer, 2018. P. 24–32.
42. *Chaudhary R., Banati H.* Swarm Bat Algorithm with Improved Search (SBAIS) // Soft Comput. 2019. V. 23. P. 11461–11491.
43. *Blackwell T., Kennedy J.* Impact of Communication Topology in Particle Swarm Optimization // IEEE Trans. Evol. Comput. 2019. V. 23. No. 4. P. 689–702.
44. *Cheng S., Shi Y., Qin Q.* Promoting Diversity in Particle Swarm Optimization to Solve Multimodal Problem // Neural Inf. Proc. LNCS, V. 7063. Heidelberg: Springer, 2011. P. 228–237.
45. *Kaucic M.* A Multi-Start Opposition-Based Particle Swarm Optimization Algorithm with Adaptive Velocity for Bound Constrained Global Optimization // J. Glob. Optim. 2013. V. 55. P. 165–188.
46. *Cao Y., et al.* Comprehensive Learning Particle Swarm Optimization Algorithm With Local Search for Multimodal Functions // IEEE Trans. Evol. Comput. 2019. V. 23. No. 4. P. 718–731.
47. *Neri F., Tirronen V., Karkkainen T., Rossi T.* Fitness Diversity Based Adaptation in Multimeme Algorithms: A Comparative Study // IEEE Congr. Evol. Comput. Singapore: IEEE, 2007. INSPEC Accession Number: 9889441.
48. *Ghannami A., Li J., Hawbani A., Alhusaini N.* Diversity Metrics for Direct-Coded Variable-Length Chromosome Shortest Path Problem Evolutionary Algorithms // Computing. 2020.
49. *Cheng S., Shi Y., Qin Q., Zhang Q., Bai R.* Population Diversity Maintenance in Brain Storm Optimization Algorithm // J. Artif. Intell. Soft Comput. Res. 2014. V. 4. No. 2. P. 83–97.
50. *Simon D., Omran M.G., Clerc M.* Linearized Biogeography-Based Optimization with Re-Initialization and Local Search // Inf. Sci. 2014. V. 267. P. 140–157.
51. *Kennedy D.D., Zhang H., Rangaiah G.P., Bonilla-Petriciolet A.* Particle Swarm Optimization with Re-Initialization Strategies for Continuous Global Optimization / Global Optimization: Theory, Developments and Applications. Nova Science Publishers, 2013. P. 1–42.
52. *Merrih-Bayat F.* The Runner-Root Algorithm: A metaheuristic for Solving Unimodal and Multimodal Optimization Problems Inspired by Runners and Roots of Plants in Nature // Appl. Soft Comput. 2015. V. 33. P. 292–303.

53. *Saxena A.* A Comprehensive Study of Chaos Embedded Bridging Mechanisms and Crossover Operators for Grasshopper Optimisation Algorithm // *Expert Syst. Appl.* 2019. V. 132. P. 166–188.
54. *Wang G.-G., et. al.* Chaotic krill herd algorithm // *Inf. Sci.* 2014. V. 274. P. 17–34.
55. *Wang G.-G., Deb S., Zhao X., Cui Z.* A New Monarch Butterfly Optimization with an Improved Crossover Operator // *Oper. Res. Int. J.* 2018. V. 18. P. 731–755.
56. *Zhou L., Ma M., Ding L., Tang W.* Centroid Opposition with a Two-Point Full Crossover for the Partially Attracted Firefly Algorithm // *Soft Comput.* 2019. V. 23. P. 12241–12254.
57. *San P.P., Ling S.H., Nguyen H.T.* Hybrid PSO-based Variable Translation Wavelet Neural Network and Its Application to Hypoglycemia Detection System // *Neural Comput. Applic.* 2013. V. 23. P. 2177–2184.
58. *Saha S.K., Kar R., Mandal D., Ghoshal S.P.* Optimal IIR Filter Design using Gravitational Search Algorithm with Wavelet Mutation // *J. King Saud Univ. Comput. Inf. Sci.* 2015. V. 27. P. 25–39.
59. *Nobahari H., Nikusokhan M., Siarry P.* A Multi-Objective Gravitational Search Algorithm Based on Non-Dominated Sorting // *Int. J. Swarm. Intell. Res.* 2012. V. 3. P. 32–49.
60. *Chen Y., et al.* Dynamic Multi-Swarm Differential Learning Particle Swarm Optimizer // *Swarm Evol. Comput.* 2018. V. 39. P. 209–221.
61. *Yazdani S., Hadavandi E.* LMBO-DE: A Linearized Monarch Butterfly Optimization Algorithm Improved with Differential Evolution // *Soft Comput.* 2019. V. 23. P. 8029–8043.
62. *Luo J., Liu Z.* Novel Grey Wolf Optimization Based on Modified Differential Evolution for Numerical Function Optimization // *Appl. Intell.* 2020. V. 50. P. 468–486.
63. *Zou F., et al.* Teaching-Learning-Based Optimization with Differential and Repulsion Learning for Global Optimization and Nonlinear Modeling // *Soft Comput.* 2018. V. 22. P. 7177–7205.
64. *Мех М.А., Ходашинский И.А.* Сравнительный анализ применения методов дифференциальной эволюции для оптимизации параметров нечетких классификаторов // *Изв. РАН. Теория и системы управления.* 2017. № 4. С. 65–75.
65. *Herrera F., Lozano M., Sanchez A.M.* A Taxonomy for the Crossover Operator for Real-Coded Genetic Algorithms: An Experimental Study // *Int. J. Intell. Syst.* 2003. V. 18. P. 309–338.
66. *Gao S., et al.* Gravitational Search Algorithm Combined with Chaos for Unconstrained Numerical Optimization // *Appl. Math. Comput.* 2014. V. 231. P. 48–62.
67. *Metlicka M., Davendra D.* Chaos Driven Discrete Artificial Bee Algorithm for Location and Assignment Optimisation Problems // *Swarm Evol. Comput.* 2015. V. 25. P. 15–28.
68. *Pluhacek M., Senkerik R., Davendra D.* Chaos Particle Swarm Optimization with Ensemble of Chaotic Systems // *Swarm Evol. Comput.* 2015. V. 25. P. 29–35.
69. *Ma H., et al.* Multi-Population Techniques in Nature Inspired Optimization Algorithms: A Comprehensive Survey // *Swarm Evol. Comput.* 2019. V. 44. P. 365–387.
70. *Blackwell T., Branke J.* Multiswarms, Exclusion, and Anti-Convergence in Dynamic Environments // *IEEE Trans. Evol. Comput.* 2006. V. 10. P. 459–472.
71. *Lung R.I., Dumitrescu D.* Evolutionary Swarm Cooperative Optimization in Dynamic Environments // *Nat. Comput.* 2010. V. 9. P. 83–94.

72. *Corcoran A.L., Wainwright R.L.* A Parallel Island Model Genetic Algorithm for the Multiprocessor Scheduling Problem // Proc. ACM Symp. Appl. Comput. ACM. 1994. P. 483–487.
73. *Lardeux F., Maturana J., Rodriguez-Tello E., Saubion F.* Migration Policies in Dynamic Island Models // Nat. Comput. 2019. V. 18. P. 163–179.
74. *Sutton R., Barto A.* Reinforcement Learning: An Introduction. London: MIT Press, 1998.
75. *Gong Y.J., et al.* Distributed Evolutionary Algorithms and Their Models: A Survey of the State-of-the-Art // Appl. Soft Comput. 2015. V. 34. P. 286–300.
76. *Raidl G.R.* A Unified View on Hybrid Metaheuristics // Proc. Hybrid Metaheuristics, Third Int. Workshop. LNCS V. 4030. Heidelberg: Springer, 2006. P. 1–12.
77. *Ходашинский И.А., Горбунов И.В.* Гибридный метод построения нечетких систем на основе модели островов // Информатика и системы управления. 2014. № 3. С. 114–120.
78. *Lynn N., Ali M.Z., Suganthan P.N.* Population Topologies for Particle Swarm Optimization and Differential Evolution // Swarm Evol. Comput. 2018. V. 39. P. 24–35.
79. *Shi Y., Liu H., Gao L., Zhang G.* Cellular Particle Swarm Optimization // Inf. Sci. 2011. V. 181. P. 4460–4493.
80. *Fang W., Sun J., Chen H., Wu X.* A Decentralized Quantum-Inspired Particle Swarm Optimization Algorithm with Cellular Structured Population // Inf. Sci. 2016. V. 330. P. 19–48.
81. *Huang L., Qin C.* A Novel Modified Gravitational Search Algorithm for the Real World Optimization Problem // Int. J. Mach. Learn. Cybern. 2019. V. 10. P. 2993–3002.
82. *Li C., Yang S.* A General Framework of Multipopulation Methods with Clustering in Undetectable Dynamic Environments // IEEE Trans. Evol. Comput. 2012. V. 16. P. 556–577.
83. *Xia L., Chu J., Geng Z.* A Multiswarm Competitive Particle Swarm Algorithm for Optimization Control of an Ethylene Cracking Furnace // Appl. Artif. Intell. 2014. V. 28. P. 30–46.
84. *Huang C., Li Y., Yao X.* A Survey of Automatic Parameter Tuning Methods for Metaheuristics // IEEE Trans. Evol. Comput. 2020. V. 24. No. 2. P. 201–216.
85. *Poli R.* Mean and Variance of the Sampling Distribution of Particle Swarm Optimizers during Stagnation // IEEE Trans. Evol. Comput. 2009. V. 13. No. 4. P. 712–721.
86. *Sengupta S., Basak S., Peters R.A.* Particle Swarm Optimization: A Survey of Historical and Recent Developments with Hybridization Perspectives // Mach. Learn. Knowl. Extr. 2019. V. 1. P. 157–191.
87. *Calvet L., Juan A.A., Serrat C., Ries J.* A Statistical Learning Based Approach for Parameter Fine-Tuning of Metaheuristics // SORT – Stat. Oper. Res. Trans. 2016. V. 40. P. 201–224.
88. *Birattari M.* Tuning Metaheuristics: A Machine Learning Perspective // SCI. 2009. V. 197.
89. *Hutter F., Hoos H.H., Leyton-Brown K., Stützle T.* ParamILS: An Automatic Algorithm Configuration Framework // J. Artif. Intell. Res. 2009. V. 36. P. 267–306.
90. *Yuan Z., de Oca M.M.A., Birattari M., Stützle T.* Continuous Optimization Algorithms for Tuning Real and Integer Parameters of Swarm Intelligence Algorithms // Swarm Intell. 2012. V. 6. P. 49–75.

91. *Eiben A.E., Smit S.K.* Evolutionary Algorithm Parameters and Methods to Tune Them / Autonomous Search. Springer, 2012. P. 15–36.
92. *Adenso-Diaz B., Laguna M.* Fine-tuning of Algorithms using Fractional Experimental Designs and Local Search // Oper. Res. 2006. V. 54. P. 99–114.
93. *Barbosa E.B.M., Senne E.L.F.* Improving the Fine-Tuning of Metaheuristics: An Approach Combining Design of Experiments and Racing Algorithms // J. Optim. 2017. V. 2017. P. 1–7.
94. *Fallahi M., Amiri S., Yaghini M.* A Parameter Tuning Methodology for Metaheuristics Based on Design of Experiments // Int. J. Eng. Techn. Sci. 2014. V. 2. P. 497–521.
95. *Huang D., Allen T.T., Notz W.I., Zeng N.* Global Optimization of Stochastic Black-Box Systems via Sequential Kriging Meta-Models // J. Glob. Optim. 2006. V. 34. No. 3. P. 441–466.
96. *Audet C., Dennis J.E.* Mesh Adaptive Direct Search Algorithms for Constrained Optimization // SIAM J. Optim. 2006. V. 17. No. 1. P. 188–217.
97. *Montero E., Riff M.-C., Neveu B.* A Beginner's Guide to Tuning Methods // Appl. Soft. Comput. 2014. V. 17. P. 39–51.
98. *Karafotias G., Hoogendoorn M., Eiben A.E.* Parameter Control in Evolutionary Algorithms: Trends and Challenges // IEEE Trans. Evol. Comput. 2015. V. 19. No. 2. P. 167–187.
99. *Zhang J., Chen W.-N., Zhan Z.-H., Yu W.-J., Li Y.-L., Chen N., Zhou Q.* A Survey on Algorithm Adaptation in Evolutionary Computation // Front. Electr. Electron. Eng. 2012. V. 7. No. 1. P. 16–31.
100. *Harrison K.R., Engelbrecht A.P., Ombuki-Berman B.M.* Inertia Weight Control Strategies for Particle Swarm Optimization // Swarm. Intell. 2016. V. 10. No. 4. P. 267–305.
101. *Eberhart R.C., Shi Y.* Tracking and Optimizing Dynamic Systems with Particle Swarms // Proc. IEEE Congr. Evol. Comput. V. 1. Seoul, South Korea, 2001. P. 94–100.
102. *Shi Y., Eberhart R.C.* Empirical Study of Particle Swarm Optimization // Proc. IEEE Congr. on Evol. Comput. 1999. V. 3. P. 1945–1950.
103. *Yang C., Gao W., Liu N., Song C.* Low-Discrepancy Sequence Initialized Particle Swarm Optimization Algorithm with High-Order Nonlinear Time-Varying Inertia Weight // Appl. Soft Comput. 2015. V. 29. P. 386–394.
104. *Jiao B., Lian Z., Gu X.* A Dynamic Inertia Weight Particle Swarm Optimization Algorithm // Chaos Solitons Fractals. 2008. V. 37. No. 3. P. 698–705.
105. *Fan S.K.S., Chiu Y.Y.* A Decreasing Inertia Weight Particle Swarm Optimizer // Eng. Optim. 2007. V. 39. No. 2. P. 203–228.
106. *Chauhan P., Deep K., Pant M.* Novel Inertia Weight Strategies for Particle Swarm Optimization // Memetic Comput. 2013. V. 5. No. 3. P. 229–251.
107. *Chen G., Huang X., Jia J., Min Z.* Natural Exponential Inertia Weight Strategy in Particle Swarm Optimization // Proc. Sixth World Congr. Intelligent Control and Automation. V. 1. IEEE. 2006. P. 3672–3675.
108. *Gao Y.-l., An X.-h., Liu J.-m.* A Particle Swarm Optimization Algorithm With Logarithm Decreasing Inertia Weight and Chaos Mutation // Int. Conf. Comput. Intell. Security. V. 1. IEEE, 2008. P. 61–65.
109. *Feng Y., Teng G.F., Wang A.X., Yao Y.M.* Chaotic Inertia Weight in Particle Swarm Optimization // Proc. Second Int. Conf. Innovative Computing, Information and Control. Kumamoto: IEEE, 2007. P. 475–479.

110. *Kentzoglanakis K., Poole M.* Particle Swarm Optimization with an Oscillating Inertia Weight // Proc. 11th Annual Conf. Genetic Evol. Comput. ACM, 2009. P. 1749–1750.
111. *Ratnaweera A., Halgamuge S.K., Watson H.C.* Self-Organizing Hierarchical Particle Swarm Optimizer with Time-Varying Acceleration Coefficients // IEEE Trans. Evol. Comput. 2004. V. 8. P. 240–255.
112. *Tanweer M.R., Suresh S., Sundararajan N.* Self Regulating Particle Swarm Optimization Algorithm // Inf. Sci. 2015. V. 294. P. 182–202.
113. *Xu G.* An Adaptive Parameter Tuning of Particle Swarm Optimization Algorithm // Appl. Math. Comput. 2013. V. 219. P. 4560–4569.
114. *Adewumi A.O., Arasomwan A.M.* An Improved Particle Swarm Optimiser Based on Swarm Success Rate for Global Optimisation Problems // J. Exp. Theoret. Artif. Intell. 2014. V. 28. P. 441–483.
115. *Yang X., Yuan J., Mao H.* A Modified Particle Swarm Optimizer with Dynamic Adaptation // Appl. Math. Comput. 2007. V. 189. P. 1205–1213.
116. *Zhan Z.-H., Zhang J., Li Y., Chung H.S.-H.* Adaptive Particle Swarm Optimization // IEEE Trans. Syst. Man Cyber. B. 2009. V. 39. P. 1362–1381.
117. *Huang L., Ding S., Yu S., Wang J., Lu K.* Chaos-Enhanced Cuckoo Search Optimization Algorithms for Global Optimization // Appl. Math. Model. 2016. V. 40. P. 3860–3875.
118. *Mirjalili S., Gandomi A.H.* Chaotic Gravitational Constants for the Gravitational Search Algorithm // Appl. Soft Comput. 2017. V. 53. P. 407–419.
119. *Gandomi A., Yang X.-S., Talatahari S., Alavi A.* Firefly Algorithm with Chaos // Commun. Nonlinear Sci. Numer. Simulat. V. 18. 2013. P. 89–98.
120. *Gandomi A.H., Yang X.-S.* Chaotic Bat Algorithm // J. Comput. Sci. 2014. V. 5. P. 224–232.
121. *Juang Y.-T., Tung S.-L., Chiu H.-C.* Adaptive Fuzzy Particle Swarm Optimization for Global Optimization of Multimodal Functions // Inf. Sci. 2011. V. 181. P. 4539–4549.
122. *Melin P., et al.* Optimal Design of Fuzzy Classification Systems using PSO with Dynamic Parameter Adaptation through Fuzzy Logic // Expert Syst. Appl. 2013. V. 40. P. 3196–3206.
123. *Neshat M.* FAIPSO: Fuzzy Adaptive Informed Particle Swarm Optimization // Neural Comput. Applic. 2013. V. 23. P. 95–116.
124. *Gonzalez B., Melin P., Valdez F., Prado-Arechiga G.* A Gravitational Search Algorithm using Fuzzy Adaptation of Parameters for Optimization of Ensemble Neural Networks in Medical Imaging // Proc. Inter. Conf. on Artif. Intell. Las Vegas: CSREA Press, 2017. P. 54–59.
125. *Perez J., et al.* Interval Type-2 Fuzzy Logic for Dynamic Parameter Adaptation in the Bat Algorithm // Soft Comput. 2017. V. 21. P. 667–685.
126. *Amador-Angulo L., Castillo O.* Statistical Analysis of Type-1 and Interval Type-2 Fuzzy Logic in Dynamic Parameter Adaptation of the BCO // Proc. 9th Conf. Europ. Society for Fuzzy Logic and Technology. Atlantis Press, 2015. P. 776–783.
127. *Abdel-Basset M., Wang G.-G., Sangaiah A.K., Rushdy E.* Krill Herd Algorithm Based on Cuckoo Search for Solving Engineering Optimization Problems // Multimed. Tools Appl. 2019. V. 78. P. 3861–3884.
128. *Galvez J., Cuevas E., Becerra H., Avalos O.* A Hybrid Optimization Approach Based on Clustering and Chaotic Sequences // Int. J. Mach. Learn. Cybern. 2020. V. 11. P. 359–401.

129. *Caraffini F., Neri F., Epitropakis M.* HyperSPAM: A Study on Hyper-Heuristic Coordination Strategies in the Continuous Domain // *Inf. Sci.* 2019. V. 477. P. 186–202.
130. *Chen X., Ong Y.-S., Lim M.-H., Tan K.C.* A Multi-Facet Survey on Memetic Computation // *IEEE Trans. Evol. Comput.* 2011. V. 15. P. 591–607.
131. *Bartoccini U., Carpi A., Poggioni V., Santucci V.* Memes Evolution in a Memetic Variant of Particle Swarm Optimization // *Mathematics.* 2019. V. 7. 423.
132. *Duan Q., Liao T.W., Yi H.Z.* A Comparative Study of Different Local Search Application Strategies in Hybrid Metaheuristics // *Appl. Soft Comput.* 2013. V. 13. P. 1464–1477.
133. *Lopez-Garcia M., Garcia-Rodenas R., Gonzalez A.G.* Hybrid Meta-Heuristic Optimization Algorithms for Time-Domain-Constrained Data Clustering // *Appl. Soft Comput.* 2014. V. 23. P. 319–332.
134. *de Oca M.A.M., Cotta C., Neri F.* Local Search // *Handbook of Memetic Algorithms.* 2012. SCI. V. 379. P. 29–41.
135. *Lai X., Hao J.-K.* A Tabu Search Based Memetic Algorithm for the Max-Mean Dispersion Problem // *Comput. Oper. Res.* 2016. V. 72. P. 118–127.
136. *Yu Y., et al.* CBSO: A Memetic Brain Storm Optimization with Chaotic Local Search // *Memetic Comput.* 2018. V. 10. P. 353–367.
137. *Petalas Y.G., Parsopoulos K.E., Vrahatis M.N.* Memetic Particle Swarm Optimization // *Ann. Oper. Res.* 2007. V. 156. P. 99–127.
138. *Wang H., Moon I., Yang S., Wang D.* A Memetic Particle Swarm Optimization Algorithm for Multimodal Optimization Problems // *Inf. Sci.* 2012. V. 197. P. 38–52.
139. *Fister I., Fister I. Jr., Brest J., Zumer V.* Memetic Artificial Bee Colony Algorithm for Large-Scale Global Optimization // 2012 IEEE Congr. Evol. Comput. Brisbane: IEEE, 2012. P. 1–8.
140. *Sudholt D.* Parametrization and Balancing Local and Global Search // *Handbook of Memetic Algorithms.* SCI. 2012. V. 379. P. 55–72.
141. *Wu G., Mallipeddi R., Suganthan P.N.* Ensemble Strategies for Population-Based Optimization Algorithms—A Survey // *Swarm Evol. Comput.* 2019. V. 44. P. 695–711.
142. *Li C., Yang S., Nguyen T.T.* A Self-Learning Particle Swarm Optimizer for Global Optimization Problems // *IEEE Trans. Syst. Man Cybern. Part B.* 2012. V. 42. P. 627–646.
143. *Wang H., et al.* Multi-Strategy Ensemble Artificial Bee Colony Algorithm // *Inf. Sci.* 2014. V. 279. P. 587–603.
144. *Lynn N., Suganthan P.N.* Ensemble Particle Swarm Optimizer // *Appl. Soft Comput.* 2017. V. 55. P. 533–548.
145. *Pillay N., Qu R.* Hyper-Heuristics: Theory and Applications. Cham: Springer, 2018.
146. *Del Ser J., et al.* Bio-inspired Computation: Where We Stand and what's Next // *Swarm Evol. Comput.* 2019. V. 48. P. 220–250.
147. *Elaziz M.A., Mirjalili S.* A Hyper-Heuristic for Improving the Initial Population of Whale Optimization Algorithm // *Knowl. Based Syst.* 2019. V. 172. P. 42–63.
148. *Miranda P., Prudencio R., Pappa G.* H3ad: A Hybrid Hyper-Heuristic for Algorithm Design // *Inf. Sci.* 2017. V. 414. P. 340–354.
149. *Yang X.-S.* Nature-Inspired Optimization Algorithms: Challenges and Open Problems // *J. Comput. Sci.* 2020. 101104.
150. *Bassimir B., Schmitt M., Wanka R.* Self-Adaptive Potential-Based Stopping Criteria for Particle Swarm Optimization with Forced Moves // *Swarm. Intell.* 2020. V. 14. P. 285–311.

151. *Li P., Zhao Y.* A Quantum-Inspired Vortex Search Algorithm with Application to Function Optimization // Nat. Comput. 2019. V. 18. P. 647–674.
152. *Nedjah N., Mourelle L.M.* Hardware for Soft Computing and Soft Computing for Hardware // SCI. V. 529. Cham: Springer, 2014.
153. *Li D., et al.* A General Framework for Accelerating Swarm Intelligence Algorithms on FPGAs, GPUs and Multi-Core CPUs // IEEE Access. 2018. V. 6. P. 72327–72344.
154. *Damaj I., Elshafei M., El-Abd M., EminAydin M.* An Analytical Framework for High-Speed Hardware Particle Swarm Optimization // Microprocess Microsyst. 2020. V. 72. 102949.

Статъя представена к публикации членом редколлегии В.М. Вишневским.

Поступила в редакцию 25.06.2020

После доработки 31.10.2020

Принята к публикации 08.12.2020