

ЭВОЛЮЦИЯ ГЕНЕТИЧЕСКИХ АЛГОРИТМОВ МНОГОКРИТЕРИАЛЬНОЙ ОПТИМИЗАЦИИ

Д.А. Ачкасов

ФГБОУ ВО «Воронежский государственный лесотехнический университет
имени Г.Ф. Морозова»

Статья посвящена анализу и описанию генетических алгоритмов для решения задач многокритериальной оптимизации. Рассматриваются такие алгоритмы как VEGA и FFGA, выявляются их ключевые ограничения, включая склонность к специализации и отсутствие механизмов поддержания разнообразия решений. Рассмотрен, который интегрирует концепцию силы особей, внешний архив для хранения недоминируемых решений и процедуру кластеризации для обеспечения равномерного покрытия Парето-фронта. Проведенный сравнительный анализ демонстрирует, что последовательное развитие методов от VEGA к SPEA позволило эффективно решать проблемы сходимости и разнообразия,

Ключевые слова: оптимизация, метод взвешенной суммы, VEGA, FFGA, NSGA, SPEA.

EVOLUTION OF GENETIC ALGORITHMS FOR MULTICRITERIA OPTIMIZATION

D.A. Achkasov

Voronezh State University of Forestry and Technologies named after G.F. Morozov

The article analyzes and details the evolution of genetic algorithms for solving multi-criteria optimization problems. It considers pioneering algorithms such as VEGA (Vector Evaluated Genetic Algorithm) and FFGA (Fitness Function Genetic Algorithm), identifying their key limitations, including a tendency towards specialization and a lack of mechanisms for maintaining solution diversity. Particular focus is placed on the more advanced SPEA (Strength Pareto Evolutionary Algorithm), which integrates the concept of individual strength, an external archive for storing non-dominated solutions, and a clustering procedure to ensure uniform coverage of the Pareto front. The comparative analysis demonstrates that the sequential development of methods from VEGA to SPEA effectively addressed convergence and diversity issues, establishing multi-objective evolutionary

algorithms as a powerful tool for finding optimal trade-offs in complex systems with conflicting criteria.

Key words: Data Mining, statistics, forecasting, moving average method, sales analysis, time series.

Задачи проектирования, управления и планирования в технике, экономике и научных исследованиях характеризуются возрастающей сложностью и наличием множества конфликтующих критериев эффективности. Такие проблемы не могут быть адекватно решены с помощью классических методов однокритериальной оптимизации, которые требуют сведения всех целей к одной скалярной функции, что не отражает всей сложности реальной ситуации. Выходом из этой ситуации является использование методов многокритериальной оптимизации (МКО), целью которых является не поиск единственного «лучшего» решения, а нахождение фронта **Парето-оптимальных решений**. Однако нахождение и аппроксимация фронта Парето сопряжены со значительными вычислительными трудностями, особенно для задач с большей размерностью (более трех критериев) и невыпуклыми областями решений, но решение возможно получить эвристически. Модификации генетических алгоритмов позволяют за одну процедуру оптимизации получить приближенное, но хорошо распределенное множество Парето-оптимальных решений. Это привело к созданию отдельного класса методов, рассмотренных далее. Актуальность темы обусловлена постоянной потребностью в мощных и надежных инструментах для поддержки принятия решений в сложных многокритериальных системах, возникающих в самых разных областях человеческой деятельности.

Постановку задачи многокритериальной оптимизации можно представить следующим образом: есть множество целевых функций $\vec{Q}(\vec{x}) = Q_1(x), Q_2(x), \dots, Q_n(x)$, наряду с ними есть область решений D_x и критериев D_Q . Если есть несколько частных критериев, можно рассмотреть задачу нахождения вектора который обеспечивает минимальное значение по каждому частному критерию.

$$\min Q_1(\vec{x}), \min Q_2(\vec{x}), \dots, \min Q_s(\vec{x}),$$

$$D_x = \left\{ \frac{\vec{x}}{g_i(\vec{x})} \geq 0, i = 1, 2, \dots, m \right\}$$

Область согласия это множество критериев, где выполняется следующий критерий: при выборе между двумя векторами альтернативных решений значения целевых функций в одном варианте лучше чем в другом. Если в этой

области нет противоречия между частными критериями оптимальности и область критериев состоит только из такой области согласия, то существует только одна точка $\vec{x} \in D_x$, где частные критерии согласованы между собой, то есть при движении к $\vec{x}$ значение всех компонент $Q_1(\vec{x})$ ухудшаются. Эта точка является оптимальным решением. То есть если при изменении одного параметра все остальные параметры становятся хуже – это оптимальная точка. Обычно критерии являются противоречивыми и минимум по каждому критерию достигается в различных точках, тогда уменьшение одного приводит к увеличению других – это эффективные (Парето-оптимальные) точки. В данных точках решение нельзя улучшить по всем критериям одновременно, это совокупность точек, которые «не хуже других» по совокупности критериев [1].

Проблема состоит в том, что построение полного Парето-фронта для числа критериев >3 часто невозможна по причине вычислительной сложности. Примером могут быть такие NP полные задачи как нахождение оптимального маршрута. Тем не менее для многих задач возможно построить частичный Парето-фронт, в частности используя генетические алгоритмы.




Рисунок 1 – Фронт Парето

Модели оптимизации одномерной функции исследуют отдельную часть фронта Парето. В том случае, если фронт задачи невыпуклый во всей области решений, часть точек фронта Парето окажутся ненайденными при помощи одномерных моделей оптимизации, таких как взвешенная сумма. Ключевое преимущество многоцелевой модели состоит именно в том, что она рассматривает всю вектор-функцию, а значит с её помощью можно найти и все эффективные точки.

Генетический алгоритм часто используется в своем обычном виде, но существует так же ряд его модификаций, адаптированных для задач многокритериальной оптимизации (VEGA, FFGA, NSGA, SPEA).

В VEGA селекция производится отдельно для каждого критерия и все полученные в результате подпопуляции объединяются в одну большую

популяцию, к которой применяются операторы кроссинговера и мутации. Его основная идея заключается в *векторной оценке* приспособленности особей. Процедура алгоритма на каждом поколении выглядит следующим образом: популяция размера N случайным образом делится на k равных подпопуляций, где k — количество целевых функций. Для i -й подпопуляции селекция (например, рулетка или турнир) проводится на основе значения только i -й целевой функции, игнорируя все остальные. Это означает, что особи, наилучшие по одному конкретному критерию, имеют высокую вероятность быть отобранными в соответствующую подпопуляцию. Далее все отобранные особи из k подпопуляций объединяются в одну общую популяцию размера N . К объединенной популяции применяются стандартные операторы кроссинговера и мутации для создания нового поколения. Главное достоинство VEGA — его концептуальная простота и минимальные отличия от канонического ГА. Однако ему присущ серьезный недостаток — склонность к сходимости к крайним точкам Парето-фронта. Это происходит из-за отсутствия механизма, явно поощряющего особи за хорошие значения по нескольким критериям одновременно. В результате покрытие Парето-фронта получается неравномерным и неполным [2].

FFGA имеет процедуру распределения особей по рангам, основываясь на концепции доминирования по Парето. Процедура присвоения ранга включает следующие шаги: все особи, которые не доминируются никакой другой особью в популяции, получают наивысший ранг (ранг 1). Эти особи формируют первый, наилучший, Парето-фронт текущей популяции. Ранг 2 и далее временно удалив из рассмотрения особей с рангом 1, находят особи, не доминируемые в оставшейся части популяции, и присваивают им ранг 2. Процесс повторяется рекурсивно до тех пор, пока всем особям в популяции не будет присвоен ранг. После ранжирования приспособленность особи обычно назначается обратно пропорционально ее рангу. Такой подход создает постоянное селективное давление в направлении истинного Парето-фронта, так как особи с меньшим рангом имеют больше шансов на размножение. FFGA явно способствует поиску компромиссных решений, поскольку особи, хорошие по нескольким критериям, с большей вероятностью получают низкий ранг. Однако FFGA не имеет механизма для обеспечения *разнообразия* решений на одном и том же фронте.

VEGA и FFGA не способны обеспечить равномерное покрытие множества Парето. Алгоритмы NPGA и SREA, рассмотренные ниже, способны обеспечить хорошее покрытие, но, чтобы это реализовать, им необходимо использовать значительные затраты на вычисления.

NSGA использует, как и FFGA, метод сортировки по недоминированию. Его существенным отличием является механизм дистанции скученности для обеспечения равномерного распределения по Парето. Сортировка по принципу отсутствия доминирования — это метод, используемый для классификации совокупности решений по различным уровням фронтов Парето. Решение считается не доминирующим, если ни одно другое решение в совокупности не превосходит его по всем критериям. Первый фронт содержит не доминирующие решения, а последующие фронты формируются путём удаления решений из предыдущих фронтов и поиска следующего набора не доминирующих решений. Особи, которые не находятся под строгим доминированием какой-либо другой особи в популяции, получают ранг 1. Рекурсивно определяются другие ранги. Каждому индивиду, который еще не был ранжирован и в котором строго доминируют индивиды с рангом 1, ..., $k - 1$, присваивается ранг k . Очевидно, что индивид тем интереснее, чем ниже его ранг [3].

Алгоритм SPEA сочетает в себе механизм отбора на основе Парето-доминирования с явной процедурой поддержания разнообразия, используя *внешний архив* для хранения наилучших найденных недоминируемых решений. На протяжении всей работы алгоритм поддерживает внешний архив, в котором хранятся все недоминируемые решения, найденные на данный момент. Для предотвращения переполнения архива и обеспечения равномерного распределения решений по Парето-фронту используется метод *кластеринга*. Когда количество недоминируемых решений в архиве превышает заданный лимит, применяется алгоритм кластеризации (например, метод среднего связывания), который группирует похожие решения. Затем в каждом кластере оставляется только одна репрезентативная особь, что позволяет сократить архив до нужного размера.

Проведенный анализ эволюции генетических алгоритмов для многокритериальной оптимизации наглядно демонстрирует последовательное решение ключевых проблем, стоящих перед данным классом методов. Введение концепции ранжирования по Парето в алгоритме FFGA позволило создать более направленное селективное давление в сторону истинного фронта. Качественный скачок связан с интеграцией элитизма и явных механизмов нишеобразования. Современные методы, берущие свое начало от SPEA и NSGA, доказали свою высокую эффективность при работе со сложными многокритериальными задачами, имеющими невыпуклые и разрывные фронты. Дальнейшие исследования в этой области видятся в адаптации данных

алгоритмов для задач большой размерности, работе в условиях неопределенности и интеграции с методами машинного обучения.

Список литературы

1. А.В. Лотов, Многокритериальные задачи принятия решений / А. В. Лотов, И.И. Пospelova ; Московский государственный университет им. М.В. Ломоносова. – Москва, 2008. – 197 с.
2. Simon Wietheger, A Mathematical Runtime Analysis of the Non-dominated Sorting Genetic Algorithm III / Simon Wietheger, Benjamin Doerr // Материалы тридцать второй Международной совместной конференции по искусственному интеллекту, основная программа. – 2023. – С. 5657-5665.
3. Ачкасов Д.А. Изучение и моделирование эвристических алгоритмов оптимизации / Д.А. Ачкасов, К.В. Зольников, Н.Н. Литвинов // Моделирование систем и процессов. – 2025. – №1. – С. – DOI: 10.12737/2219-0767-2025-17-28 .

References

1. A.V. Lotov, Multicriteria decision-making tasks / A.V. Lotov, I.I. Pospelova: Lomonosov Moscow State University. – Moscow, 2008. – 197 p.
2. Simon Wietheger, A Mathematical Runtime Analysis of the Non-dominated Sorting Genetic Algorithm III / Simon Wietheger, Benjamin Doerr // IJCAI-23. – 2023. – P. 5657-5665.
3. Achkasov D.A. Study and modeling of heuristic optimization algorithms / D.A. Achkasov, K.V. Zolnikov, N.N. Litvinov // Modeling of systems and processes. – 2025. – №1. – P. – DOI: 10.12737/2219-0767-2025-17-28 .