

СРАВНЕНИЕ АЛГОРИТМОВ ОПТИМИЗАЦИИ В НЕСТАЦИОНАРНЫХ ЗАДАЧАХ

Д.А. Ачкасов¹

¹ФГБОУ ВО «Воронежский государственный лесотехнический университет имени Г.Ф. Морозова»

Аннотация. Многие прикладные задачи оптимизации характеризуются наличием нескольких противоречивых критериев, а также изменением условий с течением времени. Такие задачи называются задачами динамической многокритериальной оптимизации (Dynamic Multi-objective Optimization, DMOO). Классическим примером является планирование маршрута в транспортной сети, где веса ребер (время проезда, стоимость, риск) могут меняться из-за пробок, погодных условий или других факторов. Для решения многокритериальных задач хорошо зарекомендовали себя эволюционные алгоритмы, такие как NSGA-II и SPEA2. Однако их поведение в динамических условиях исследовано недостаточно. Цель данной работы – сравнительный анализ эффективности этих алгоритмов с различными стратегиями реагирования на изменения.

Ключевые слова: многокритериальная оптимизация, оптимизация в нестационарной среде, эволюционные алгоритмы, генетические алгоритмы

COMPARISON OF OPTIMIZATION ALGORITHMS IN NON-STATIONARY PROBLEMS

D.A. Achkasov¹

¹ Voronezh State University of Forestry and Technologies named after G.F. Morozov

Abstract. Many applied optimization problems are characterized by the presence of several contradictory criteria, as well as changing conditions over time. Such tasks are called Dynamic Multi-objective Optimization (DMOO) tasks. A classic example is route planning in a transportation network, where the weights of the edges (travel time, cost, risk) may vary due to traffic jams, weather conditions, or other factors. Evolutionary algorithms such as NSGA-II and SPEA2 have proven themselves well for solving multi-criteria problems. However, their behavior in dynamic conditions has

not been sufficiently studied. The purpose of this paper is to compare the effectiveness of these algorithms with different strategies for responding to changes.

Keywords: multi-criteria optimization, optimization in a non-stationary environment, evolutionary algorithms, genetic algorithms

Введение

В многокритериальной оптимизации есть своя особенность – целевых функций несколько. И когда ищешь решение, нужно учитывать их все. Проблема в том, что эти функции обычно конфликтуют. Нет такого решения, которое было бы оптимальным сразу по всем параметрам – тогда задача была бы тривиальной. Приходится выбирать компромисс, при котором значения целевых функций приемлемы в каком-то смысле. Целевые функции можно оптимизировать по Парето – найти множество недоминирующих решений, каждое из которых не хуже других по какому-то параметру [1].

Многие задачи оптимизации живут в условиях, которые меняются со временем. Это называется оптимизацией в нестационарной среде. Сложность в том, что фронт Парето тоже меняется во времени.

Формально такую задачу на дискретном интервале времени можно записать так:

$$\{ f_1(x, a(t)), f_2(x, a(t)), \dots, f_k(x, a(t)) \} \rightarrow \min \quad (1)$$

То есть есть вектор целевых функций, описывающих параметры оптимизируемого объекта. А вектор $\backslash(a(t)\backslash$) может включать и другие измеряемые параметры.

В публикациях [1,2] приводят разные способы классификации таких задач – в зависимости от того, как происходят изменения.

- По скорости изменений. Чем быстрее всё меняется, тем меньше времени на адаптацию.

- По степени изменений. Если изменения небольшие, можно использовать то, что получили раньше.

- По предсказуемости. Изменения бывают предсказуемые или случайные.

Есть два способа учитывать изменения в процессе оптимизации. Можно каждый раз, когда условия поменялись, решать новую задачу с нуля. А можно использовать то, что получили на предыдущем шаге, как отправную точку для следующей генерации.

Подходы к решению таких задач обычно строят на основе существующих генетических алгоритмов. Добавляют механизмы, которые повышают разнообразие, пытаются предсказывать изменения, используют несколько популяций или механизмы памяти – чтобы не забывать, что было раньше.

Алгоритм NSGA-2

NSGA-2 – один из основных многокритериальных генетических алгоритмов. Как работает сортировка недоминируемых решений? У нас есть общая популяция. Она состоит из популяции родителей P и популяции потомков Q . Её размер – $2N$, где N – размер популяции родителей. Далее решения во множестве R сортируются. В подмножество F_1 попадают все недоминируемые решения – это первый недоминируемый фронт. В F_2 – решения, которые недоминируемы уже во множестве $(R \setminus F_1)$, и так далее [3].

Когда формируется новая популяция $(P_{(i+1)})$, подмножества недоминируемых фронтов добавляются по очереди – пока размер очередного фронта не превысит допустимый. В этом случае решения сортируются по степени скученности. Для каждого решения считается расстояние до соседних – чтобы в популяцию попадали разнообразные варианты.

Алгоритм SPEA2

SPEA2 – ещё один популярный алгоритм многокритериальной оптимизации. Его особенность в том, что кроме популяции решений используется архив недоминируемых решений. Чтобы архив не разрастался, индивиды кластеризуются по степени удалённости друг от друга, и в архиве остаётся только представитель кластера. Архив помогает алгоритму лучше приближать фронт Парето [4].

Ещё там считается пригодность (fitness) индивидов. Сначала каждому индивиду присваивают значение силы S . Этот параметр – сколько других индивидов доминируют над данным. Но тут важно: высокое значение S не означает, что решение близко к фронту Парето. Поэтому далее вычисляется R , которое является суммой значений сил индивидов, доминирующих над рассматриваемым.

$$R(i) = \sum_{j \in P_t + P_t^*, j < i} S(j) \quad (2)$$

Результирующая пригодность:

$$F(i) = \frac{1}{1+R(i)} \quad (3)$$

Данные

Когда мы переходим от одного момента времени к другому, начальную популяцию можно сформировать по-разному. Вариантов несколько. Можно сделать полный перезапуск алгоритма – начать всё с чистого листа. Можно взять популяцию, которая получилась на предыдущем шаге. А можно сделать смешанную – что-то от старого, что-то новое. Надо проверить, есть ли разница в точности и в том, как быстро алгоритм сходится, при разных подходах.

Такие эксперименты приведены в публикациях [1]. В качестве тестовых задач был взят набор CEC2018 Dynamic Multi-objective Optimization Benchmark Problems. Вид задач изменяется в зависимости от значения параметра t . Для оценки точности полученных решений используется Inverted Generation Distance (IGD), которая показывает степень различия между исходным и найденным значениями. Для нестационарной задачи можно использовать усредненную меру MIGD. Так же используется мера удалённости фронта от некоторой наихудшей точки MHV.

Численные эксперименты проводились с использованием двух разных значений скорости изменений.




Рисунок 1 – Диаграммы значений суммарных рангов использованных алгоритмов

На рис. 1 показаны диаграммы значений рангов. Видно, что существенной разницы между NSGA-2 и SPEA2 нет.

Заключение

В ходе экспериментального исследования на наборе тестовых нестационарных задач многокритериальной оптимизации проведено сравнение работы

алгоритмов NSGA-2 и SPEA-2 при различных стратегиях формирования популяции. Установлено, что при медленном характере изменений внешних условий предпочтительной является стратегия, использующая популяцию, полученную на предыдущем временном шаге. В данном случае задача претерпевает незначительные изменения, вследствие чего ранее найденные эффективные решения сохраняют свою актуальность. При быстрых изменениях среды ни одна из рассмотренных стратегий не демонстрирует устойчивого превосходства – однозначный лидер отсутствует.

Отсутствие статистически значимых различий в суммарных рангах между NSGA-II и SPEA-2 (Рис. 1) объясняется сходством их селективного давления в динамических условиях. Оба алгоритма при сходимости к текущему фронту Парето характеризуются ускоренной потерей популяционного разнообразия, что повышает их чувствительность к резким изменениям внешней среды.

Интересно отметить, что при медленных изменениях эффективность подхода с переносом популяции ожидаемо выше. Это подтверждает гипотезу о том, что предыдущее оптимальное решение является хорошей отправной точкой, и алгоритму требуется лишь незначительная "настройка" (микро-адаптация) под новые условия. В этом случае среда выполняет роль небольшого возмущения, а не полной замены задачи.

Полученные результаты позволяют наметить пути для дальнейшей работы. Во-первых, представляет интерес гибридизация рассмотренных алгоритмов с методами машинного обучения для предсказания изменения параметров среды (вектора $a(t)$). Во-вторых, перспективным направлением является разработка мета-эвристик, способных в режиме реального времени переключаться между стратегиями (рестарт, память, предсказание) в зависимости от наблюдаемых характеристик потока изменений.

Список литературы

1. Рурич М.А., Вахнин А.В., Сопов Е.А. Сравнение эффективности различных подходов к формированию популяции при решении задач многокритериальной оптимизации // Сибирский аэрокосмический журнал. 2022. Т.23, №2. С.227-240. DOI:10.31772/2712-8970-2022-23-2-227-240.
2. Бугаев, Ю. В. Анализ моделей и алгоритмов оптимизации раскрытия одномерных лесоматериалов / Ю. В. Бугаев, Л. А. Коробова, И. Ю. Шурупова // Моделирование систем и процессов. – 2024. – Т. 17, № 4. – С. 23-31. – DOI 10.12737/2219-0767-2024-17-4-23-31. – EDN MRHWHP.

3. Шагеев, Д. А. Поиск решения проблемы выбора формы свёртки локальных векторов с целью повышения точности измерений в методе анализа иерархий / Д. А. Шагеев // Моделирование систем и процессов. – 2024. – Т. 17, № 3. – С. 95-105. – DOI 10.12737/2219-0767-2024-93-103. – EDN FUFKOH.

4. Yazdani D., Cheng R. F Survey of Evolutionary Continuous Dynamic Optimization Over Two Decades-Part A// IEEE Transactions on Evolutionary Computation. 2021. No 25(4). P. 609-629.

References

1. Rurich M.A., Vakhnin A.V., Sopov E.A. Comparison of the effectiveness of various approaches to population formation in solving multi-criteria optimization problems // Siberian Aerospace Journal. 2022. Vol.23, No. 2. pp.227-240. DOI:10.31772/2712-8970-2022-23-2-227-240.

2. Bugaev, Yu. V. Model analysis and algorithms for optimizing the cutting of one-dimensional timber / Yu.V. Bugaev, L. A. Korobova, I. Y. Shur-pov // Modeling of systems and processes. – 2024. – Vol. 17, No. 4. – pp. 23-31. – DOI 10.12737/2219-0767-2024-17-4-23-31. – REGISTRATION number MRHWHP.

3. Shageev, D. A. Search for a solution to the problem of choosing the form of convolution of local vectors in order to increase the accuracy of measurements in the hierarchy analysis method / D. A. Shageev // Modeling of systems and processes. – 2024. – VOL. 17, No. 3. – PP. 95-105. – In doi 10.12737/2219-0767-2024-93-103. – ED. FUFKOH.

4. Yazdani D., Cheng R. F Survey of Evolutionary Continuous Dynamic Optimization Over Two Decades-Part A// IEEE Transactions on Evolutionary Computation. 2021. No 25(4). P. 609-629.