

УДК 519.6

СЕРИЙНЫЕ ЗАДАЧИ ОПТИМИЗАЦИИ В САПР И НАСТРОЙКА АЛГОРИТМОВ ИХ РЕШЕНИЯ

Т.А. Агасиев*МГТУ им. Н.Э. Баумана*

Россия, 105005, Москва, 2-я Бауманская ул.5

E-mail: taaalex@mail.ru

А.П. Карпенко*МГТУ им. Н.Э. Баумана*

Россия, 105005, Москва, 2-я Бауманская ул.5

E-mail: apkarpenko@mail.ru

Ключевые слова: глобальная параметрическая оптимизация, автоматизированное проектирование, настройка алгоритмов оптимизации, метаоптимизация, суррогатное моделирование.

Аннотация: Целью работы является разработка математического и программного обеспечения для автоматизации настройки алгоритмов решения серийных задач параметрической оптимизации проектных решений в САПР. Задачи исследования: формализовать определение серийной задачи параметрической оптимизации проектных решений в САПР; формализовать постановку задачи настройки параметров на основе прогнозирования эффективности алгоритма; разработать методику настройки алгоритмов решения серийных задач, включающую метод оценки особенностей задачи, метод построения аппроксимирующей модели индикатора эффективности алгоритма; выполнить программную реализацию разработанного математического обеспечения; исследовать эффективность разработанного математического и программного обеспечения при решении тестовых задач оптимизации и прикладной серийной задачи параметрической оптимизации проектных решений.

1. Введение

Структурно-параметрический синтез сложных инженерных изделий включает в себя решение большого числа задач параметрической оптимизации проектных решений. При проектировании различных объектов, схожих по конструкции и техническим характеристикам, приходится многократно решать "схожие" задачи оптимизации. Например, при проектировании новых моделей или модификаций пассажирских самолетов одного семейства многократно решают задачи оптимизации геометрии аэродинамических поверхностей и различных элементов фюзеляжа [1]. Серийные задачи имеют похожие варьируемые параметры, критерии оптимальности и топологии области поиска, но могут отличаться ландшафтом целевой функции. Виду многократного решения различных экземпляров серийной задачи целесообразно применение узкоспециализированных алгоритмов оптимизации, разработанных с учетом особенностей этой серийной задачи [2].

Алгоритмы оптимизации на основе суррогатного моделирования различают, прежде всего, по типу правил выбора следующей точки в области поиска для расчета значения целевой функции [3]. Если аппроксимирующая модель позволяет не только спрогнозировать значение целевой функции, но и оценить степень достоверности

полученного прогноза, то применяют правила выбора следующей точки на основе максимизации некоторой функции предпочтения (*acquisition function*). Рассматриваем суррогатную модель целевой функции на основе гауссовских процессов. Алгоритм оптимизации в таком случае относят к классу алгоритмов байесовской оптимизации.

Выделяют методы однократной и перманентной настройки алгоритмов оптимизации [4]. Новым перспективным направлением исследований в данной области является перманентная настройка на основе прогнозирования наилучших стратегий алгоритма с учетом характерных признаков решаемой задачи (*FBAC, Feature-Based Algorithm Configuration*) [5]. Наиболее эффективным и универсальным подходом к прогнозированию наилучших стратегий является построение аппроксимирующей модели индикатора эффективности алгоритма.

Представляем авторскую методику настройки алгоритмов байесовской оптимизации *DEPM (Decomposed Empirical Performance Model)*, включающую в себя оригинальный метод ландшафтного анализа и двухэтапный метод прогнозирования наилучших стратегий алгоритма в процессе его нормальной эксплуатации при решении экземпляров серийной задачи.

2. Определение серийной задачи оптимизации

Рассматриваем задачу q глобальной безусловной оптимизации

$$\min_{X \in D_X} f(X) = f(X^*) = f^*.$$

где X - $|X|$ -мерный вектор варьируемых параметров (размерность задачи q); $D_X \subset \mathfrak{R}^{|X|}$ - область поиска; $f(X) \in \mathfrak{R}^1$ - целевая функция; X^*, f^* - искомые оптимальный вектор X и значение целевой функции.

Результатом оценки особенностей задачи q является вектор *характерных признаков* $C(q)$, рассчитанный алгоритмом *ландшафтного анализа* a_C с использованием *ландшафтной выборки* $C(q) = C(q, L, a_C)$.

Серийной задачей Q называем совокупность задач q , векторы характерных признаков $C(q)$ которых принадлежат некоторой области $D_C = D_C(Q, a_C)$ пространства характерных признаков, определенной алгоритмом ландшафтного анализа a_C . Задачу оптимизации $q \in Q$ называем *экземпляром серийной задачи* Q .

Вектор B свободных параметров алгоритма $a = a(B)$ называется *стратегией алгоритма*. Множество D_B допустимых стратегий определяет набор алгоритмов $A(D_B) = \{a(B), B \in D_B\}$.

Индикатор эффективности алгоритма $a(B)$ при решении задачи q с вектором характерных признаков $C(q)$ обозначаем $e(a(B), C(q), I) = e(B, C, I)$, где $I \in D_I$ - вычислительный бюджет задачи, определяемый как максимально допустимое число испытаний целевой функции $f(X)$; D_I - множество допустимых бюджетов при решении экземпляров серийной задачи Q .

Аппроксимирующую модель индикатора эффективности $e(B, C, I)$ на множествах D_C, D_B, D_I называем *мета-моделью* и обозначаем $\hat{e}(B, C, I)$. Минимальному значению функции $\hat{e}(B, C, I)$ при заданных векторе C и бюджете I соответствует спрогнозированная наилучшая стратегия $\hat{B}^*(C, I)$.

2. Постановка задачи настройки алгоритма оптимизации на основе прогнозирования наилучших стратегий

Задача настройки параметров алгоритма оптимизации для экземпляра $q \in Q$ серийной задачи ставим как задачу мета-оптимизации (*M-задачу*)

$$(1) \quad \min_{B \in D_B} e(B, C, I) = e(B^*, C, I).$$

Для оценки характерных признаков задачи $q \in Q$ выбираем алгоритм ландшафтного анализа a_C из набора доступных алгоритмов A_C , который максимизирует критерий качества ландшафтного анализа $\varphi(a_C, Q)$ для экземпляров серийной задачи Q :

$$\min_{a_C \in A_C} \varphi(a_C, Q) = \varphi(a_C^*, Q).$$

Найденную наилучшую стратегию B^* используем для решения всех экземпляров q серийной задачи Q . Таким образом, *одно-индикаторную M-задачу* для серийной задачи Q , которой соответствует область характерных признаков D_C , записываем в виде

$$\text{opt}_{B \in D_B} e(B, D_C, I) = e(B^*, D_C, I).$$

В качестве индикатора эффективности $e(B, D_C, I)$ используем усредненные значения индикатора $e(B, C, I)$ при решении экземпляров этой серийной задачи, то есть полагаем, что $e(B, D_C, I) = \bar{e}(B, C, I)$, где $C \in D_C$.

Прямой поиск наилучшей стратегии $B^*(C, I)$ предполагает решение задачи оптимизации с различными стратегиями $B \in D_B$ при бюджете I , что нецелесообразно ввиду высокой вычислительной сложности экземпляров q прикладных серийных задач Q . Задача настройки на основе прогнозирования наилучших стратегий алгоритма состоит в построении мета-модели $\hat{e}(B, C, I)$ индикатора эффективности на множествах D_B, D_C, D_I и отыскании наилучшей стратегии $\hat{B}^*(C, I)$ для решения задачи $q \in Q$ с вектором характерных признаков $C \in D_C$ и бюджетом $I \in D_I$:

$$\min_{B \in D_B} \hat{e}(B, C, I) = \hat{e}(\hat{B}^*, C, I) \approx e(B^*, C, I).$$

Мета-модель $\hat{e}(B, C, I)$ строим на основе результатов решения *настроечных* задач $q^t \in Q$, имеющих низкую вычислительную сложность. Спрогнозированную наилучшую стратегию $\hat{B}^*(C, I)$ используем в качестве приближенного решения задачи (1).

3. Программное обеспечение и вычислительный эксперимент

Программный комплекс, содержащий программные компоненты САПР, реализующие специализированное математическое обеспечение, называем *базовым*.

Программный комплекс для автоматизации настройки алгоритмов решения серийных задач оптимизации *DEPM Tuner (Decomposed Empirical Performance Model Tuner)*, который реализует разработанное математическое обеспечение, предоставляет необходимые инструменты для расчета характерных признаков решаемых задач q , построения аппроксимирующих моделей индикатора эффективности $\hat{e}(B, C, I)$ и прогнозирования наилучших стратегий $B^*(C, I)$.

С архитектурной точки зрения разработанное программное обеспечение разделено на серверную и клиентскую части. Серверная часть содержит программы для сложных с вычислительной точки зрения расчетов, выполняющихся на высокопроизводительных вычислительных системах – *HPC* кластерах. Клиентская часть предоставляет удобный программный и графический интерфейсы для подготовки экземпляра задачи оптимизации, отслеживания процесса его решения и анализа результатов. Программный комплекс интегрирован со свободной реализацией алгоритма оптимизации на основе суррогатного моделирования целевой функции.

Исследование эффективности разработанного математического и программного обеспечения выполнено 1) при решении тестовых (настроечных) задач оптимизации, 2) при решении практически значимой задачи оптимизации.

Целью вычислительного эксперимента с тестовыми задачами оптимизации является исследование точности прогнозирования наилучших стратегий алгоритма при высокой степени неоднородности значений характерных признаков настроечных задач оптимизации. Набор настроечных задач оптимизации составлен на базе доступных тестовых функций для исследования эффективности алгоритмов оптимизации. Ввиду высокой вычислительной сложности эксперимента используем задачи оптимизации с размерностью $|X| = 2$.

В качестве практически значимой рассматриваем задачу оптимизации одного цилиндра 4-х тактного бензинового двигателя с непрямым впрыском объемом 0,25 литра в рабочем режиме 10000 оборотов в минуту. Задача подготовлена на базе демонстрационного примера прикладной задачи оптимизации, включенной в поставку программной платформы *pSeven* [6], в которой использованы открытая библиотечная математическая модель двигателя и упрощенная 3D модель геометрии двигателя. Варьируемыми параметрами являются диаметр цилиндра, ход поршня, коэффициент сжатия, зазор между днищем поршня и головкой цилиндра, длительность впрыска, массовый расход топлива. В качестве критерия оптимальности используем скалярную свертку выходных параметров двигателя

$$f(X) = \lambda_1 y_1 + \lambda_2 y_2,$$

где y_1 – масса двигателя; y_2 – крутящий момент; λ_1, λ_2 – весовые коэффициенты.

Усредненный крутящий момент двигателя рассчитываем на основе результатов моделирования газодинамики с использованием математической модели двигателя в программной системе *Simcenter Amesim*. Для расчета массы двигателя применяем упрощенную 3D модель двигателя в программной системе *Siemens NX*. Численное моделирование работы механических частей двигателя, инжектора и камеры сгорания выполнены с помощью библиотеки *IFP-Engine*, включенной в состав *Simcenter Amesim*. Для проведения вычислительного эксперимента выбран относительно небольшой при данном числе варьируемых параметров бюджет $I = 128$. Начальная выборка, которую используем в качестве ландшафтной для оценки вектора характерных признаков решаемой задачи и прогнозирования наилучшей стратегии, содержит $N_L = 64$ точки. После построения начальной суррогатной модели целевой функции выполняем 64 итерации алгоритма байесовской оптимизации в соответствии с установленным бюджетом.

4. Заключение

В работе получены следующие основные результаты:

- формализована серийная задача оптимизации;
- представлены формальные постановки задач настройки алгоритмов оптимизации проектных решений для серийных задач параметрической оптимизации с использованием методов ландшафтного анализа и прогнозирования наилучших стратегий;
- предложена методика настройки алгоритмов параметрической оптимизации проектных решений в процессе их эксплуатации, учитывающая характерные признаки серийной задачи оптимизации и объем доступных вычислительных ресурсов;
- предложен метод аппроксимации индикатора эффективности алгоритма при решении серийных задач оптимизации проектных решений;

- создан программный комплекс *DEPM Tuner*, реализующий разработанное математическое обеспечение для автоматизации настройки алгоритма;
- выполнен масштабный вычислительный эксперимент, указывающий на высокую эффективность и практическую значимость разработанного математического и программного обеспечения.

Список литературы

1. Grihon S. Structure sizing optimization capabilities at AIRBUS // World Congress of Structural and Multidisciplinary Optimisation. Cham: Springer, 2017. P. 719-737.
2. Priem R. et al. An efficient application of Bayesian optimization to an industrial MDO framework for aircraft design // AIAA AVIATION 2020 FORUM. 2020. P. 3152.
3. Saini B. S., Lopez-Ibanez M., Miettinen K. Automatic surrogate modelling technique selection based on features of optimization problems // Proceedings of the Genetic and Evolutionary Computation Conference Companion. 2019. P. 1765-1772.
4. Eiben A.E., Michalewicz Z., Schoenauer M., Smith J.E. Parameter Control in Evolutionary Algorithms // Parameter Setting in Evolutionary Algorithms. Springer, 2007. P. 19-46.
5. Kerschke P., Trautmann H. Automated algorithm selection on continuous black-box problems by combining exploratory landscape analysis and machine learning // Evolutionary computation. 2019. Vol. 27, No. 1. P. 99-127.
6. Бурнаев Е. и др. Многодисциплинарная оптимизация, анализ данных и автоматизация инженерных расчётов с помощью программного обеспечения комплекса pSeven // CAD. 2014. №. 4. С. 1-15.