

一种优化迭代权因子的组合代理模型构建方法

李志华 曾慧毅 聂超 刘婷婷

(杭州电子科技大学机械工程学院, 杭州 310018)

摘要: 代理模型常被用来取代复杂工程问题中的仿真模型。为了提高代理模型的效率、精度和鲁棒性,提出一种优化迭代权因子的组合代理模型构建方法。首先采用留一交叉验证策略和预测平方和 P 来计算初始权因子,然后对权因子进行迭代,并在每次迭代的过程中对其进行更新,直至最终得到的组合代理模型达到理想的预测精度。为了验证该方法的有效性,对3个基准问题和1个工程实例构建了3种元模型和5种组合代理模型,并从效率、精度和鲁棒性等方面进行性能比较。结果表明本文所提出的方法不仅能得到高精度和高鲁棒性的代理模型,而且能有效缩短模型的构建时间。

关键词: 元模型; 组合代理模型; 权因子; 预测精度

中图分类号: TH122; TP391 **文献标识码:** A **文章编号:** 1000-1298(2016)07-0391-07

Optimal Iterative Weight Factors Method for Constructing Ensemble of Surrogate Model

Li Zhihua Zeng Huiyi Nie Chao Liu Tingting

(College of Mechanical Engineering, Hangzhou Dianzi University, Hangzhou 310018, China)

Abstract: Surrogate models are often used to replace expensive simulation models in complicated engineering problems. The common practice is to construct multiple metamodels based on a common training data set, evaluate the accuracy, and then use only a single model perceived as the best while discarding the rest. This practice has some shortcomings as it does not take full advantage of the resources devoted to constructing different metamodels and increases the risk of adopting an inappropriate model. However, ensemble technique is an effective way to make up for the shortfalls of traditional strategy. In order to improve the efficiency, accuracy and robustness of the surrogate model, an optimal iterative weight factors method for constructing ensemble of surrogate model was proposed. At first, the leave-one-out cross validation strategy and PRESS criterion were presented to calculate initial weight factors. Then, an iterative process for the weight factors was conducted and at the same time the weight factors were updated until an ideal prediction accuracy of the ultimate ensemble of surrogate model was reached. To evaluate the effectiveness of the proposed method, three meta-models and five ensembles of surrogate model for three benchmark problems and an engineering problem were constructed to compare their performances of efficiency, accuracy and robustness. Results show that the proposed method can not only get a higher accuracy and robustness surrogate, but also shorten the time of constructing surrogate model evidently.

Key words: metamodel; ensemble of surrogate model; weight factor; prediction accuracy

引言

复杂机电产品的设计往往涉及众多学科、多种

因素,而且各个学科、因素之间的相互作用、相互耦合,使得产品设计优化过程异常复杂。传统的利用仿真分析来获得优化结果的方法对复杂机电产品的

设计已越来越力不从心,而代理模型方法能够极大地降低复杂产品设计优化过程中的庞大计算量,在复杂工程问题的分析和优化中应用广泛^[1-5]。代理模型方法是利用拟合和插值技术来分析实验设计点,在满足设计精度的条件下,对复杂、隐式或未知的函数关系进行简化替代,从而构建出源函数或仿真模型的近似模型,然后再基于该近似模型进行优化设计。

代理模型中,常用的元模型有:多项式回归模型(PRS)、Kriging 模型(KRG)、径向基函数模型(RBF)、支持向量回归模型(SVR)等。由于缺乏足够的信息来描述响应与输入变量之间的关系,因此对于某一个复杂工程问题,很难知道哪一个元模型是匹配的^[6]。此外,由于元模型的预测精度受实验设计(DOE)类型、样本点数量和响应面类型(例如:线性、非线性、平滑、粗糙)等因素的影响比较大^[7],因此,事先要选择一个合适的元模型具有很大的困难。

为了提高代理模型的适应性,一个合理的选择是使用多个元模型的线性组合,即组合代理模型,它能充分利用各元模型的预测性能来提高响应的整体预测精度。目前国内外已提出了多种组合代理模型的构建方法,其大致可以分为 3 类。第 1 类是根据样本在设计空间内的相似性来构建组合代理模型^[8],即对样本进行分类以组成不同的群集,然后对每个群集构建一个局部代理模型,最后将它们在整个设计空间内光滑连接,以构成全局组合代理模型。这类构建方法,其模型精度对初始样本的依赖性较强。第 2 类是作为一个优化问题来构建组合代理模型。它可分成两小类:①通过最小化局部误差(如预测方差、最大绝对误差等)来获得组合代理模型的权因子,如 ZERPA 等^[9]通过最小化组合代理模型中的预测方差来获得权因子,ACAR 等^[10]通过最小化组合代理模型中的最大绝对误差来获得权因子。②通过最小化全局误差(如广义交叉验证均方根误差、均方根误差等)来获得组合代理模型的权因子,如 GOEL 等^[11]和 TOAL 等^[12]通过最小化组合代理模型中的广义交叉验证均方根误差来获得权因子,JIANG 等^[13]通过最小化组合代理模型中的均方根误差来获得权因子等。潘峰^[14]综合比较了这两小类组合代理模型的构建方法,指出它们的精度和鲁棒性还有待提高;周晓剑^[15]指出该类方法所提出的最优化问题并不能保证所求的解是全局最优,有时容易陷入局部最优,有时甚至没有最优解。当然,一般情况下,第 2 类组合代理模型的构建方法能较好地提高模型的精度,但同时也大大增加了建模时

间。第 3 类是利用迭代权因子的策略来构建组合代理模型,即在每次获得权因子之后判断是否满足收敛准则,若不满足则继续迭代,直至获得满足精度要求的代理模型。如周晓剑^[15]通过多次循环预测方差倒数的策略来构建组合代理模型的方法;ZHOU 等^[16]基于算术平均迭代策略获得权因子的计算方法等。这类方法能在模型精度和建模时间之间取得较好的平衡,但若初始权因子选取不当,则会导致迭代时间过长。

综上所述,尽管国内外对组合代理模型的构建方法进行了一些研究,但在模型的效率、精度和鲁棒性等方面仍不尽人意。为此,本文提出一种优化迭代权因子的组合代理模型构建方法。

1 组合代理模型

1.1 加权组合代理模型公式

由于各个元模型对于给定的源函数具有不同的近似精度,因此,为了提高代理模型的适应性和整体预测精度,将各个元模型乘以不同的权因子以构成加权组合代理模型,用于近似源函数 $y(x)$ 的组合代理模型可以表示为

$$\hat{y}_e(x) = \sum_{i=1}^M \omega_i \hat{y}_i(x) \tag{1}$$

其中

$$\sum_{i=1}^M \omega_i = 1$$

式中 x ——输入变量

$\hat{y}_e(x)$ ——组合代理模型的预测响应值

M ——元模型的个数

ω_i ——第 i 个元模型的权因子

$\hat{y}_i(x)$ ——第 i 个元模型的预测响应值

通常,对源函数近似精度较高的元模型具有较大的权因子,反之亦然。

PRS 元模型具有构造简单、计算量小、线性拟合精度高的特点;KRG 元模型具有局部拟合精度高的特点;RBF 元模型具有非线性拟合精度高的特点。因此,本文考虑的组合代理模型同大多数文献一样,也是由 PRS、KRG 和 RBF 3 个元模型来构成,不同之处在于权因子的计算方法,因为它在很大程度上会影响代理模型的效率、精度和鲁棒性。

1.2 留一交叉验证策略

评价代理模型预测精度的指标主要有:均方根误差 R_{RMSE} 、预测平方和 P 、相关系数 R 等。为了提高建模效率,采用 P 和留一交叉验证策略^[17]来计算初始权因子。假设利用 p 个样本构建了一个代理模型,则利用留一交叉验证策略来得到 P 的步骤如下:将这 p 个样本点进行编号,分别为 $p_1, p_2, \cdots, p_p$;

将第 p_1 个样本点作为测试点,代入代理模型,得到其响应值 $y(X^{p_1})$;将其余 $p-1$ 个样本重新构造代理模型,并将第 p_1 个样本点代入到该新建的模型中,得到一个新的响应值 $\hat{y}(X^{p_1})$,这种响应值称为留一响应值。以此类推,可以得到 p 个留一响应值,这样就可最终得到 P 为

$$P = \sum_{i=1}^p \sqrt{1/[p(y(X^{p_i}) - \hat{y}(X^{p_i}))^2]} \tag{2}$$

1.3 初始权因子

由于 P 越小,模型精度越高,而对源函数近似精度较高的元模型通常具有较大的权因子,因此计算 PRS、KRG 和 RBF 3 个元模型所对应的初始权因子公式为

$$\omega_i^0 = \frac{\frac{1}{P_i}}{\sum_{j=1}^3 \frac{1}{P_j}} \quad (i=1,2,3) \tag{3}$$

2 优化迭代的权因子计算方法

2.1 模型构建方法

前面提到,由于第 2 类构建方法是通过优化求解局部误差或全局误差来获得权因子的,因此其建模时间较长;而第 3 类构建方法,由于源模型(或源函数)的性态未知,很难选取到一组恰当的初始权因子,若盲目选取,则会导致建模时间过长。为了提高建模效率,首先在初始采样的基础上(采 p 个样本点),得到 3 个初始的 PRS、KRG 和 RBF 元模型,虽然这些元模型精度还不高,但仍能反映出源函数在设计空间上的趋势,然后利用留一交叉验证策略和 P 来计算每个元模型对应的初始权因子,避免了初始权因子选取时的盲目性。为了提高模型的精度和鲁棒性,在初始权因子的基础上,采用 R_{RMSE} 的最大、最小值以及整体精度,作为收敛判断准则,对权因子作进一步的迭代求解,直至模型达到理想的预测精度。

本文提出的优化迭代权因子的计算方法具有如下特点:由于初始权因子不是盲目选取的,而是通过留一交叉验证策略和 P 得到的,因此在较好的初始权因子的基础上进行迭代,其迭代次数要比第 3 类现有方法少很多。克服了第 2 类方法所存在的不足(如耗时长、局部最优、一次性获得的权因子难以达到理想的预测精度等)。本文首先采用计算量小的方法(即不采用优化的方法,而采用留一交叉验证策略,它能提高样本的使用效率^[17])计算出初始权因子,然后进行权因子迭代,以得到更加精确和更具鲁棒性的代理模型。本文采用 R_{RMSE} 的最大、最小值

以及整体精度作为收敛判断准则,克服了第 3 类现有方法只考虑最高和最低的元模型精度而没有考虑模型的整体精度来进行局部收敛判断的缺陷,这更有利于模型精度的提高。

本算法的具体步骤如下:

(1)首先利用拉丁超立方采样(LHD)方法^[18],在设计空间进行采样,得到 p 个样本点,并仿真计算得到它们的真实响应值。

(2)运用留一交叉验证策略和 P 来计算每个元模型所对应的初始权因子 $\omega_1^0, \omega_2^0, \omega_3^0$ 。

(3)再次利用 LHD 采样,得到 n_s 个测试样本点,并仿真计算得到它们的真实响应值;然后根据前面 p 个样本点及其响应值所构建的各个元模型,计算每个元模型的 R_{RMSE} ,并分别乘上相应的权因子,得到子模型的 R_{RMSE}^* 。

(4)根据各 R_{RMSE}^* 的大小,分别找到最大和最小的 R_{RMSE}^* ,记为 $R_{\text{RMSE}_{\text{Worst}}}^*$ 和 $R_{\text{RMSE}_{\text{Best}}}^*$ 。

(5)迭代停止判定准则:

$$\text{While } (R_{\text{RMSE}_{\text{Worst}}}^* - R_{\text{RMSE}_{\text{Best}}}^* > \text{tol} \text{ 或 } \sum_{i=1}^3 R_{\text{RMSE}_i}^* > \varepsilon) \text{ Do } \{$$

用加权代理模型(初始组合代理模型或者上一次迭代之后更新的组合代理模型)来替换 $R_{\text{RMSE}_{\text{Worst}}}^*$ 对应的子模型中的元模型,替换之后,合并 3 个子模型中相同元模型的权因子,从而得到组合代理模型新的权因子}

(6)转到步骤(3),直至步骤(5)中的 While 语句不满足,然后退出循环,获得最佳的权因子 $\omega_1^n, \omega_2^n, \omega_3^n$ 。

这里, R_{RMSE} 表示代理模型的均方根误差, tol, ε 为预定的误差值。

$$R_{\text{RMSE}} = \sqrt{\frac{1}{n_s} \sum_{k=1}^{n_s} (y(X_k) - \hat{y}(X_k))^2} \tag{4}$$

式中 X_k ——第 k 个测试样本点

$y(X_k)$ ——点 X_k 处的真实响应值

$\hat{y}(X_k)$ ——代理模型在点 X_k 处的预测响应值

步骤(3)~(6)的伪代码如下:

$i=0$;

Do { $R_{\text{RMSE}_1}^* = R_{\text{RMSE}_1} \omega_1^i$; // 第 1 个子模型对应的均方根误差

$R_{\text{RMSE}_2}^* = R_{\text{RMSE}_2} \omega_2^i$; // 第 2 个子模型对应的均方根误差

$R_{\text{RMSE}_3}^* = R_{\text{RMSE}_3} \omega_3^i$; // 第 3 个子模型对应的均方根误差

$\omega_1^{\Delta} = \omega_1^i$;

$\omega_2^{\Delta} = \omega_2^i$;
 $\omega_3^{\Delta} = \omega_3^i$;
 $R_{RMSE_{Worst}}^* = \text{MAX}(R_{RMSE_1}^*, R_{RMSE_2}^*, R_{RMSE_3}^*)$; // 找到 3 个子模型对应均方根误差中最大值
 $R_{RMSE_{Best}}^* = \text{MIN}(R_{RMSE_1}^*, R_{RMSE_2}^*, R_{RMSE_3}^*)$; // 找到 3 个子模型对应均方根误差中最小值
 $cond1 = R_{RMSE_{Worst}}^* - R_{RMSE_{Best}}^*$; // 判断条件 1
 $cond2 = \sum_{i=1}^3 R_{RMSE_i}^*$; // 判断条件 2
 $\text{Model}(R_{RMSE_{Worst}}^*) = \text{Model}\left(\sum_{j=1}^3 \omega_j^i \text{Sur}_j\right)$; // 最大均方根误差对应的元模型被组合代理模型替换
 $i++$;
 $\text{Model}\left(\sum_{j=1}^3 \omega_j^i \text{Sur}_j\right) = \text{Model}_{\text{combine}}$; // 合并子模型中相同元模型的权因子, 构成新的组合代理模型
While($cond1 > tol \parallel cond2 > \varepsilon$)
 $\omega_1^n = \omega_1^{\Delta}$;
 $\omega_2^n = \omega_2^{\Delta}$;
 $\omega_3^n = \omega_3^{\Delta}$;
代码中子模型等于元模型乘上相应的权因子。

2.2 模型构建流程

模型构建流程如图 1 所示。

3 实例

选用 3 个基准问题和 1 个工程实例来建立代理模型, 并进行性能比较测试。

3.1 基准问题

下面 3 个基准问题^[19], 分别代表了低维、中维和高维问题。

Branin-Hoo




图 1 模型构建流程图

Fig. 1 Flow chart of model building

$$f(x,y) = \left(y - \frac{5.1x^2}{4\pi^2} + \frac{5x}{\pi} - 6\right)^2 +$$
$$10\left(1 - \frac{1}{8\pi}\right)\cos(x) + 10$$

($x \in [-5, 10], y \in [0, 15]$)

Hartman-3

$$f(X) = - \sum_{i=1}^4 c_i \exp\left(- \sum_{j=1}^3 a_{ij}(x_j - p_{ij})^2\right)$$

($x_j \in [0, 1]$)

Hartman-6

$$f(X) = - \sum_{i=1}^4 c_i \exp\left(- \sum_{j=1}^6 a_{ij}(x_j - p_{ij})^2\right)$$

($x_j \in [0, 1]$)

对于 Hartman-3 和 Hartman-6, 其参数 c_i 、 a_{ij} 、 p_{ij} 取值见表 1 和表 2^[19]。

表 1 函数 Hartman-3 的参数

Tab.1 Parameters of function Hartman-3

<i>i</i>	<i>a_{ij}</i>			<i>c_i</i>	<i>P_{ij}</i>		
	<i>j</i> = 1	<i>j</i> = 2	<i>j</i> = 3		<i>j</i> = 1	<i>j</i> = 2	<i>j</i> = 3
1	3.0	10.0	30.0	1.0	0.368 90	0.117 0	0.267 3
2	0.1	10.0	35.0	1.2	0.469 90	0.438 7	0.747 0
3	3.0	10.0	30.0	3.0	0.109 10	0.873 2	0.554 7
4	0.1	10.0	35.0	3.2	0.038 15	0.574 3	0.882 8

表 2 函数 Hartman-6 的参数

Tab.2 Parameters of function Hartman-6

<i>i</i>	<i>a_{ij}</i>						<i>c_i</i>	<i>P_{ij}</i>					
	<i>j</i> = 1	<i>j</i> = 2	<i>j</i> = 3	<i>j</i> = 4	<i>j</i> = 5	<i>j</i> = 6		<i>j</i> = 1	<i>j</i> = 2	<i>j</i> = 3	<i>j</i> = 4	<i>j</i> = 5	<i>j</i> = 6
1	10.0	3.0	17.0	3.5	1.7	8.0	1.0	0.131 2	0.169 6	0.556 9	0.012 4	0.882 8	0.588 6
2	0.05	10.0	17.0	0.1	8.0	14.0	1.2	0.232 9	0.413 5	0.830 7	0.373 6	0.100 4	0.999 1
3	3.0	3.5	1.7	10.0	17.0	8.0	3.0	0.234 8	0.145 1	0.352 2	0.288 3	0.304 7	0.665 0
4	17.0	8.0	0.05	10.0	0.1	14.0	3.2	0.404 7	0.882 8	0.873 2	0.574 3	0.109 1	0.038 1

3.2 磁流变制动器问题

磁流变制动器是一种新型线控制动器,为了改进制动器的性能,文献[20]提出了一种由 5 个变量构成的优化设计方案,其目标是最大化制动器的制动力矩和最小化制动器的质量。由于制动力矩既与磁路参数有关,又与结构参数有关,因此需要通过 ANSYS 的仿真分析得到。这里,需要构建制动力矩的代理模型,其 5 个设计变量及取值范围如表 3 所示^[20]。

表 3 制动器的设计变量及范围

Tab.3 Design variables and range of brake mm	
设计变量	取值范围
制动盘最小工作半径 R_1	25 ~ 60
制动盘最大工作半径 R_2	70 ~ 130
制动器内腔半径 R_3	110 ~ 145
制动盘厚度 l_1	5 ~ 30
外壳厚度 l_2	5 ~ 30

3.3 实验设计

对于以上测试问题,采用拉丁超立方采样方法进行采样。为了降低随机因素的影响,同时参考文献[15,20],根据问题维数的不同,随机选取 20 ~ 1 000 组训练样本,每组由 12 ~ 56 个训练样本点组成。此外,由于要进行模型精度的判断,因此需要添加额外 n_s 个测试样本点,具体如表 4 所示。

表 4 各问题使用的训练点和测试点数目

Tab.4 Numbers of training and testing points using in problems				
问题	设计变量	训练样本	训练样本	测试样本
	个数	组数	点个数	点个数
Branin-Hoo	2	1 000	12	4
Hartman-3	3	1 000	20	6
Hartman-6	6	200	56	12
制动器问题	5	20	42	10

3.4 预测精度指标

相关系数 R 可反映代理模型的全局误差大小,其值越接近于 1,代理模型的预测精度则越高。由于实验需要重复多次(如 200、1 000 次),因此用 R 的均值及变化系数 ψ ^[12] 来评价代理模型的预测精度。

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}}$$

(5)

式中 n ——测试样本点的数目
 y_i ——第 i 个测试样本点的真实响应值
 $\bar{y}$ —— n 个真实响应值的平均值
 $\hat{y}_i$ ——第 i 个测试样本点的预测响应值

$\bar{\hat{y}}$ —— n 个预测响应值的平均值

$$\psi = \frac{\delta}{\mu}$$

(6)

式中 δ ——相关系数 R 的标准差
 μ ——相关系数 R 的均值

4 结果与分析

首先,对进行比较的各种组合代理模型进行标记,部分标记沿用 ACAR 等^[6]的标签。基于固定权因子(即 $\omega_1 = \omega_2 = \omega_3 = 1/3$)的组合代理模型标记为 EA,基于预测方差的组合代理模型标记为 EV,基于广义交叉验证均方根误差的组合代理模型标记为 EG,基于算术平均迭代的组合代理模型标记为 ER,本文提出的优化迭代权因子的组合代理模型标记为 EGR。其次,为了便于进行性能比较,将结果以箱线图的形式^[21]表达,它可以直观反映出数据分布的分散程度。箱线图矩形内部的横线表示中位数,矩形上下两端分别对应数据的上、下四分位数,矩形端外的两条线段分别对应数据的上、下四分位距,这两条线段表示异常值截断处,异常值截断处之外的点为异常值,用 + 表示。最后,为了清晰起见, R 的均值和 ψ 值以表格的形式列出。

4.1 相关系数

对 3 个基准问题和工程实例建立各种代理模型,其相关系数 R 如图 2 所示。从图中可以看出:①3 个元模型(PRS、KRG 和 RBF)在 4 个问题中,要么矩形内部的横线位置较低,要么矩形上下两端的距离较大,要么矩形端外的两条线段的距离较大,要么异常值过多,说明没有一个元模型能对所有的问题都拟合得很好。②在矩形内部的横线位置方面,各组合代理模型均高于横线最低的元模型,在矩形上下两端的距离、矩形端外两条线段的距离、以及异常值方面,各组合代理模型均小于精度最低的元模型,说明组合代理模型的预测性能要优于精度最低的元模型。③大多数组合代理模型的矩形上下两端的距离、矩形端外线段的距离、以及异常值都比元模型的要小,说明组合代理模型的鲁棒性一般要优于单个元模型。④在所有的问题中,EGR 和 ER 有着相似的箱线图,且优于其它的代理模型,但是 EGR 的箱线图总体上还是好于 ER,说明 EGR 的鲁棒性是最好的。

对 3 个基准问题和工程实例建立的各种代理模型,其相关系数 R 的均值和 ψ 如表 5 所示。从表中可以看出:大部分组合代理模型的相关系数均值和 ψ 都要优于元模型(即均值高于元模型、 ψ 值低于元模型),说明组合代理模型的预测精度一般要高于




图 2 各测试问题代理模型的相关系数

Fig.2 Correlation coefficients of test problems by using surrogate models

表 5 各测试问题代理模型的相关系数均值和 ψ

Tab.5 Mean and ψ values of correlation coefficient of test problems by using surrogate model

代理模型	Branin-Hoo		Hartman-3		Hartman-6		制动器问题	
	均值	ψ	均值	ψ	均值	ψ	均值	ψ
RBF	0.884 3	0.062 3	0.724 9	0.167 4	0.958 6	0.018 4	0.826 3	0.070 5
KRG	0.848 7	0.105 7	0.866 4	0.064 9	0.945 6	0.022 6	0.804 7	0.079 3
PRS	0.804 9	0.081 2	0.884 5	0.047 6	0.976 5	0.013 5	0.833 5	0.074 2
EG	0.897 9	0.056 4	0.898 5	0.030 4	0.988 5	0.006 8	0.857 3	0.056 1
EV	0.889 5	0.061 4	0.900 4	0.030 4	0.987 1	0.005 2	0.854 1	0.057 9
EA	0.872 7	0.071 4	0.871 8	0.047 9	0.973 6	0.009 4	0.832 9	0.067 2
ER	0.902 3	0.053 8	0.892 6	0.031 2	0.984 3	0.004 7	0.874 4	0.049 6
EGR	0.913 9	0.051 2	0.910 5	0.028 8	0.992 1	0.003 5	0.886 3	0.043 9

单个元模型;在所有的 问题中,EGR 的相关系数的均值最大,均高于其他代理模型;此外,在所有问题中,EGR 的相关系数的 ψ 最小,均低于其他代理模型,说明 EGR 的鲁棒性最好。

4.2 代理模型的构建速度

建立各种代理模型所需的时间如表 6 所示(计算机为:Inter i3 - 2310M, CPU: 2.1 GHz, RAM:

6.0 GB)。从表中可以看出:元模型构建的时间最短;组合代理模型中,EA 构建的时间最短,因为 EA 的权因子是固定的(即 $\omega_1 = \omega_2 = \omega_3 = 1/3$);EV 和 EG 的构建时间相近,因为它们都是通过最优化预测方差或广义均方根误差,一次性获得权因子;EGR 比 EG、EV 和 ER 的构建时间要短,因为它是在较好的初始权因子的基础上进行的迭代。

表 6 构建各种代理模型所需的时间

Tab.6 Comparison of time to build surrogate models

问题	RBF	KRG	PRS	EG	EV	EA	ER	EGR
Branin-Hoo	3.482	3.725	3.417	5.817	5.627	4.387	6.462	5.392
Hartman-3	5.494	5.734	5.078	8.233	7.940	6.744	10.509	7.887
Hartman-6	9.622	9.831	9.287	15.493	14.784	11.853	20.462	14.613
制动器问题	1 873.4	1 933.6	1 804.6	2 734.8	2 574.5	2 008.1	3 027.9	2 319.4

5 结论

(1)单个元模型不能很好地适应各种源函数或

源模型,组合代理模型比单个元模型的适应性更强。

(2)尽管单个元模型的构建时间比组合代理模型要短,但组合代理模型的精度和鲁棒性一般要优

于单个元模型。

(3)为了能更精确地近似源函数或源模型,采用预设的固定权因子的方法是不可取的,而应根据源函数或源模型的性态来动态地获取权因子。

(4)在所测试的问题中,本文方法得到的代理模型(即 EGR)预测精度和鲁棒性高于其它代理模型;其构建时间比 EG、EV 和 ER 短。说明本文所提出的方法不仅能得到高精度和高鲁棒性的代理模型,而且能有效缩短模型的构建时间。

参 考 文 献

1 SANCHEZ E, PINTOS S, QUEIPO N V. Toward an optimal ensemble of kernel-based approximations with engineering applications [J]. Structural and Multidisciplinary Optimization, 2008, 36(3): 247 – 261.

2 杨勇, 张为民, 杨涛. 基于 Kriging 元模型的机床进给驱动系统动态特性优化[J]. 农业机械学报, 2013, 44(5): 288 – 293.
YANG Yong, ZHANG Weimin, YANG Tao. Dynamic performance optimization of machine tool feed drive system based on Kriging model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(5): 288 – 293. (in Chinese)

3 崔杰, 张维刚, 谢伦杰, 等. 基于 Kriging 代理模型的碰撞安全性稳健性分析[J]. 汽车工程, 2013, 35(1): 51 – 55.
CUI Jie, ZHANG Weigang, XIE Lunjie, et al. Robust analysis of collision safety based on Kriging model[J]. Automotive Engineering, 2013, 35(1): 51 – 55. (in Chinese)

4 张扬, 张维刚, 马桃, 等. 基于全局敏感性分析和动态代理模型的复杂非线性系统优化设计方法[J]. 机械工程学报, 2015, 51(4): 126 – 131.
ZHANG Yang, ZHANG Weigang, MA Tao, et al. Optimization design method of complex nonlinear system based on global sensitive analysis and dynamic surrogate[J]. Journal of Mechanical Engineering, 2015, 51(4): 126 – 131. (in Chinese)

5 刘鹏, 范立云, 白云, 等. 高速电磁阀磁力近似模型的构建与分析[J]. 农业工程学报, 2015, 31(16): 96 – 101.
LIU Peng, FAN Liyun, BAI Yun, et al. The construction and analysis of high-speed electromagnetic valve electromagnetic force approximation model[J]. Transactions of the CSAE, 2015, 31(16): 96 – 101. (in Chinese)

6 ACAR E, RAIS R M. Ensemble of metamodels with optimized weight factors[J]. Structural and Multidisciplinary Optimization, 2009, 37(3): 279 – 294.

7 熊芬芬. 稳健优化设计中代理模型不确定性的研究[J]. 机械工程学报, 2014, 50(19): 136 – 143.
XIONG Fenfen. Robust design optimization considering metamodel uncertainty[J]. Journal of Mechanical Engineering, 2014, 50(19): 136 – 143. (in Chinese)

8 ZHAO Dong, XUE Deyi. A multi-surrogate approximation method for metamodeling[J]. Engineering with Computers, 2011, 27(2): 139 – 153.

9 ZERPA L E, QUEIPO N V, PINTOS S, et al. An optimization methodology of alkaline-surfactant-polymer flooding processes using field scale numerical simulation and multiple surrogates[J]. Journal of Petroleum Science and Engineering, 2005, 47(3 – 4): 197 – 208.

10 ACAR E. Effect of error metrics on optimum weight factor selection for ensemble of metamodels [J]. Expert Systems with Applications, 2015, 42(5): 2703 – 2709.

11 GOEL T, HAFTKA R T, SHYY W, et al. Ensemble of surrogates[J]. Structural and Multidisciplinary Optimization, 2007, 33(3): 199 – 216.

12 TOAL D J J, KEANE A J. Performance of an ensemble of ordinary, universal, non-stationary and limit Kriging predictors[J]. Structural and Multidisciplinary Optimization, 2013, 47(6): 893 – 903.

13 JIANG Xue, LU Wenxi, HOU Zeyu. Ensemble of surrogate-based optimization for identifying an optimal surfactant-enhanced aquifer remediation strategy at heterogeneous DNAPL-contaminated sites[J]. Computers & Geosciences, 2015, 84(3): 37 – 45.

14 潘峰. 组合近似模型方法研究及其在轿车车身轻量化设计的应用[D]. 上海: 上海交通大学, 2011.
PAN Feng. The research of ensemble of surrogates and it's application in the lightweight design of the car body[D]. Shanghai: Shanghai Jiao Tong University, 2011. (in Chinese)

15 周晓剑. 基于递归预测方差倒数的元模型组合构建[J]. 南京邮电大学学报: 自然科学版, 2015, 35(1): 102 – 108.
ZHOU Xiaojian. Ensemble of meta-models based on recursive the reciprocal of predicted variance [J]. Journal of Nanjing University of Posts and Telecommunications: Natural Science Edition, 2015, 35(1): 102 – 108. (in Chinese)

16 ZHOU X, MA Y, LI X. Ensemble of surrogates with recursive arithmetic average [J]. Structural and Multidisciplinary Optimization, 2011, 44(5): 651 – 671.

17 MAO Wentao, MU Xiaoxia, ZHENG Yanbin, et al. Leave-one-out cross-validation-based model selection for multi-input multi-output support vector machine[J]. Neural Computing and Applications, 2014, 24(2): 441 – 451.

18 ZHU H, LIU L, LONG T, et al. A novel algorithm of maximin latin hypercube design using successive local enumeration[J]. Engineering Optimization, 2012, 44(5): 551 – 564.

19 ZHANG J, CHOWDHURY S, MESSAC A. An adaptive hybrid surrogate model [J]. Structural and Multidisciplinary Optimization, 2012, 46(2): 223 – 238.

20 李志华, 喻军, 曾宁, 等. 圆盘式磁流变制动器仿真优化设计[J]. 农业机械学报, 2015, 46(10): 364 – 369.
LI Zhihua, YU Jun, ZENG Ning, et al. Simulation and optimization design of disc-type magnetorheological brake [J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(10): 364 – 369. (in Chinese)

21 VIANA F A C, HAFTKA R T, WATSON L T. Efficient global optimization algorithm assisted by multiple surrogates[J]. Journal of Global Optimization, 2013, 56(2): 669 – 689.