

支持向量机替代模型的遗传优化设计

向国齐^{1,3}, 严志坚², 黄大贵¹

(1. 电子科技大学机械电子学院 成都 610054; 2. 中国电子科技集团公司第十研究所 成都 610036;
3. 攀枝花学院机电学院 四川 攀枝花 617000)

【摘要】针对实际工程中常见的性能函数不能显式表示的优化问题,提出一种基于支持向量机替代模型的遗传优化设计方法。利用试验设计选取合适的设计参数样本点,通过实验或数值仿真获得响应输出,结合遗传算法构建具有参数优化功能的支持向量机替代模型;将支持向量机模型作为目标性能函数,结合其他约束条件完成优化模型的建立,并应用遗传算法进行优化,形成一套准确、高效、适应性强的优化方法。以典型电子装备功分器的结构尺寸优化为例,采用均匀试验设计和高频电磁场仿真软件HFSS获取替代模型训练的学习样本,建立功分器模型的幅度比、相位差和驻波3个响应面目标函数,并对该多目标优化问题进行遗传寻优。

关键词 遗传算法; 代理模型; 优化设计; 支持向量机

中图分类号 TH122

文献标识码 A

doi:10.3969/j.issn.1001-0548.2009.03.034

Genetic Optimization Design Based on Support Vector Regression Metamodeling

XIANG Guo-qi^{1,3}, YAN Zhi-jian², and HUANG Da-gui¹

(1. School of Mechatronics Engineering, University of Electronic Science and Technology of China Chengdu 610054;

2. Southwest Institute of Electronic Technology Chengdu 610036; 3. School of Mechanical Engineering, Panzhihua University Panzhihua Sichuan 617000)

Abstract Aiming at the optimization design problem with implicit objective performance functions, a genetic optimization design method based on the support vector regression (SVR) metamodeling is proposed. Appropriate design parameter samples are selected by experimental design theories, and the response samples are obtained from the experiments or numerical simulations. By applying the genetic algorithm (GA) to optimize the parameters of SVR, the metamodel is constructed and treated as the objective performance functions. In combination with other constraints, the optimization model is formed and solved by GA. The structure optimization of a microwave power divider is adopted as an example to illustrate the effectiveness of this design method. The learning samples are obtained from uniform design theory and the high frequency electromagnetic field finite element analysis codes (HFSS). Three response-surface objective functions for the magnitude, phase, and VSWR of the microwave power divider model are obtained and the multi-objective optimization problem is solved.

Key words genetic algorithm; metamodeling; optimization design; support vector machine

在优化设计问题中常遇到性能目标与设计变量之间不具有显式的函数关系式,且通常表现为高度非线性、多参数、复杂的问题。传统的方法主要依靠经验反复调用数值仿真模型进行计算,存在耗时多、效率低、难以得到全局最优等缺点。因此,寻求准确、高效的优化设计方法具有重要意义。

响应面模型、Kriging模型和神经网络是目前研究中最常用的替代模型^[1-3]。响应面模型易于实现,但是逼近非线性问题的能力较差;Kriging模型虽然对非线性问题有较高的准确度,但模型的获取和使

用难度较大;神经网络存在“过学习”现象,模型的精度和泛化能力依赖其结构和大量的学习样本,且结构的选取缺乏理论指导。支持向量机(SVM)建立在统计学VC维理论和结构风险最小原理基础上,较好地解决了小样本、非线性、高维数、局部极小点等实际问题,具有很强的泛化能力,是一种专门解决小样本情况问题非参数回归建模技术的有效方法^[4-6]。遗传算法的高度并行、随机和自适应搜索能力使得它能够很好地反映全局信息,具有很强的鲁棒性,尤其适合处理传统优化方法难以解决的复杂

收稿日期: 2008-02-20; 修回日期: 2008-11-25

基金项目: 国家973重大基础研究项目(613580202)

作者简介: 向国齐(1974-),男,博士生,主要从事智能机电系统、机电耦合等方面的研究。

的非线性问题^[7]。

因此,通过构建高效、准确的支持向量机替代模型,替代实际优化中的实验或数值计算,极大地减少了计算量;将支持向量机替代模型与遗传算法相结合,可以很好地解决目标函数非显式的优化问题。

1 支持向量机替代模型

1.1 支持向量回归机(SVR)

给定样本集 $D = \{(x_i, y_i) | i = 1, 2, \dots, l\}$, 其中 $x_i \in R^n$ 为 n 维输入样本, $y_i \in R$ 为输出样本。支持向量回归的目的是通过训练样本,用回归函数 $f(x) = wx + b$ 拟合输入样本与输出样本之间的关系,考虑允许拟合误差,引入非负松弛因子 ξ_i 和 ξ_i^* , 函数的拟合问题转化为优化问题:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (1)$$

$$y_i - wx_i - b \leq \varepsilon + \xi_i$$

$$\text{s.t.} \quad wx_i + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \quad i = 1, 2, \dots, n \quad (2)$$

利用最优化方法的对偶原理,可以转换得到对偶形式为:

$$W(\alpha, \alpha^*) = -\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle + \\ \sum_{i=1}^n (\alpha_i - \alpha_i^*) y_i - \sum_{i=1}^n (\alpha_i + \alpha_i^*) \varepsilon \quad (3)$$

$$\text{s.t.} \quad \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C \quad i = 1, 2, \dots, n \quad (4)$$

由式(3)、式(4)可得到支持向量机拟合函数为:

$$f(x) = wx + b = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle x, x_i \rangle + b \quad (5)$$

非线性回归使用非线性映射,把数据映射到高维特征空间进行线性回归,在高维特征空间用核函数替代线性问题中的内积运算,即:

$$K(x_i, x_j) = \varphi(x_i) \varphi(x_j) \quad (6)$$

最后得到的支持向量机拟合函数为:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (7)$$

1.2 SVR参数选取

SVR参数 C 、 σ 和 ε 的取值与学习样本和实际问题相关。参数 C 是在结构风险和样本误差之间作出折衷,较大的 C 值允许较小的误差,较小的 C 值则允许

较大的误差。核宽度 σ 与学习样本的输入空间范围相关,样本输入空间范围越大, σ 取值越大;反之,样本输入空间范围越小,则 σ 取值越小。不敏感参数 ε 则与噪声水平相关,实际应用中常常根据预先估计的噪声水平来确定参数 ε 。对于多变量回归问题,参数 ε 、 C 、 σ 取值范围分别为^[8-9]:

$$\varepsilon \in [0, 5\sigma] \quad \sigma^2 = \frac{3l^{1/5}}{3l^{1/5} - 1} \sum_{i=1}^l (y_i - \hat{y}_i)^2 \quad (8)$$

$$C_{\min} = \max(|\bar{y} + 3\sigma|, |\bar{y} - 3\sigma|) \quad (9)$$

$$\sigma^i = (0.1 \sim 1) \|x_{\max}^i - x_{\min}^i\| \\ i = 1, 2, \dots, d \quad (10)$$

式中 l 为样本数据数量; \hat{y}_i 为令 $\varepsilon = 0$ 训练SVR回归模型,得到对应各输入的输出; \bar{y} 和 σ 为数据集中 y 的均值和方差。

1.3 遗传算法优化SVR参数

将遗传算法应用于SVR参数优化时,优化算法的目标函数是选取最佳的参数组合,使得SVR回归与参考模型具有最小的均方误差,适应度函数为:

$$F(\varepsilon, C, \sigma) = \text{MSE} = \sqrt{\frac{1}{k} \sum_{i=1}^k (y_i - f(x))^2} \quad (11)$$

式中 k 为样本数; y 为数据集的真值; $f(x)$ 为数据集的SVR预测值。

算法的基本步骤为: (1) 迭代次数 $t=0$; (2) 随机选择实数编码的初始种群 $P(t)$; (3) 针对 $P(t)$ 中的个体训练SVR,计算个体适应度函数值 $F(t)$; (4) 若种群中最优个体所对应的适应度函数值满足要求或达到设定的迭代次数,转到步骤(7); (5) $t=t+1$; (6) 应用选择、交叉以及变异算子产生新的种群,转到步骤(3); (7) 给出最佳的核参数 σ 、 ε 以及 C 参数,用其训练数据集以获得回归模型。

2 遗传优化算法设计

2.1 优化理论模型

一般多目标优化模型的数学形式为:

$$\min f = [f_1(x), f_2(x), \dots, f_i(x), \dots, f_n(x)]$$

$$\text{s.t.} \quad \begin{cases} g_j(x) \leq 0 \\ x_{k\min} \leq x_k \leq x_{k\max} \end{cases}$$

$$i = 1, 2, \dots, n \quad j = 1, 2, \dots, m \quad k = 1, 2, \dots, p \quad (12)$$

式中 $f_i(x)$ 为第 i 个目标函数; $g_j(x)$ 为第 j 个约束函数; $x_{k\min}$ 、 $x_{k\max}$ 为第 k 维设计变量 x_k 的上下界。

目标函数和约束函数是设计变量的函数,一般不具有显式的表达式,通常用实验或数值仿真方法计算。由于采用支持向量机替代模型,则优化模型

表示为:

$$\begin{aligned} \min F &= [Y_1^*, Y_2^*, \dots, Y_l^*, \dots, Y_n^*] \\ Y_i^* &= f_i(x) \quad i=1, 2, \dots, n \\ g_j(x) &\leq 0 \quad j=1, 2, \dots, l \\ \text{s.t. } \{G_j^* = g_j(x)\} &\leq 0 \quad j=l+1, \dots, m \\ x_{k \min} &\leq x_k \leq x_{k \max} \quad k=1, 2, \dots, p \end{aligned} \quad (13)$$

式中 Y_i^* 和 G_j^* 为第*i*个目标函数和第*j*个约束函数的替代模型近似值; 前*l*个约束为常规约束, 后(*m-l*)个约束为支持向量机模型约束。

2.2 SVR替代模型遗传优化算法设计

本文提出的基于SVR替代模型的优化设计方法是试验设计、SVR和GA计算方法的耦合。首先利用试验设计选取合适的实验方案, 通过实验或数值仿真获得样本点; 然后利用MATLAB语言编制的SVR程序构建具有自动参数优化功能的支持向量机替代模型; 将支持向量机模型作为目标性能函数, 结合其他常规约束条件建立优化模型; 最后利用GA程序计算优化模型的最优值。基于支持向量机替代模型的遗传优化算法流程如图1所示。

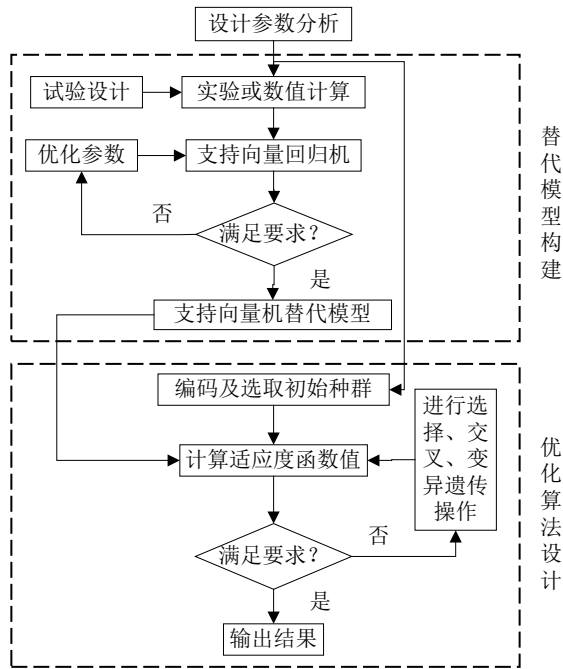


图1 SVR-GA算法优化流程图

3 算例

本文以天馈系统的功分器结构优化为例, 来验证该方法的有效性。功分器结构如图2所示, 功分器优化设计的目标为两输出端口的幅度比、相位差以及驻波值分别满足0.5、0和1。设计变量有*L*、*R*等10个, 取值范围如表1所示。




图2 功分器结构示意图

表1 设计变量的取值范围

设计变量	取值范围/mm	设计变量	取值范围/mm
<i>L</i>	[6.8, 9.2]	<i>V</i> ₁	[0.75, 0.85]
<i>R</i>	[6.8, 9.2]	<i>R</i> ₂	[0.38, 0.62]
<i>H</i> ₂	[2.6, 2.7]	<i>V</i> ₂	[0.48, 0.62]
<i>H</i> ₁	[0.48, 0.72]	<i>A</i>	[5.5, 6.5]
<i>R</i> ₁	[0.15, 0.25]	<i>B</i>	[1, 2]

3.1 均匀试验设计进行样本选择

为了利用SVR建立设计变量(输入)与响应(输出)之间的非线性映射关系, 必须有目的的设计SVR的学习样本。均匀试验设计^[10]既提高试验点“均匀分散”的程度, 使试验点具有更好的代表性, 又可用较少的试验获得较多的信息。

本文选用均匀试验设计采样数据试验点, 首先对功分器的各设计变量均取25个水平, 进行10个因子、25个水平均匀试验设计, 获得25组设计变量的数据作为高频电磁场有限元软件HFSS的输入, 分别计算出功分器的驻波、幅度比和相位差; 同理, 再设计一个10个因子、11个水平的均匀试验设计, 获得11组数据。然后分别对25组学习数据和11组校验数据作归一化处理, 从而获取SVR的学习样本和校验样本。

3.2 替代模型训练

根据样本数据规模和输入变量维数, 由式(8)~式(10), 确定SVR的3个参数范围为 $C \in [0, 50]$, $\epsilon \in [0, 0.1]$, $\sigma \in [0, 0.1]$ 。

遗传算法对SVR的参数自动寻优时, 控制参数设置初始种群大小为100, 最大代数数为20, 交叉率为0.4, 变异率为0.1。获得SVR的3个参数的优化结果为 $C=33.5$, $\sigma=0.036$, $\epsilon=0.098$ 。

本文用检验数据对该SVR模型进行测试, 获得SVR替代模型的均方误差(RMSE)和最大绝对误差(MAE)。为了与其他近似替代模型法比较, 在同样

的试验样本基础上,采用BP神经网络建立了驻波、幅度比和相位差的替代模型,其误差分析结果如表2所示。由表2可知,支持向量机模型的误差小,精度高,表明SVR建立了正确的函数非线性映射关系。

表2 不同替代模型的误差分析

模型	SVR模型		BPNN模型	
	MAE	RMSE	MAE	RMSE
驻波	0.091	0.094 774	0.121	0.126 346
幅度比	0.075	0.076 165	0.096	0.107 791
相位差	0.529	0.087 828	0.872	0.112 135

3.3 基于SVR替代模型的GA优化

功分器优化属于多目标优化问题。采用权重系数变换法,对3个目标函数赋予相同的权重,转化为单目标优化问题。

利用GA进行优化,取种群数为100,交叉率为0.5,变异率为0.001,进化代数200。

优化结果为: $L=8.213\ 0\ \text{mm}$; $R=7.875\ 4\ \text{mm}$; $H_2=2.659\ 8\ \text{mm}$; $H_1=0.587\ 62\ \text{mm}$; $R_1=0.211\ 17\ \text{mm}$; $V_1=0.818\ 49\ \text{mm}$; $R_2=0.501\ 74\ \text{mm}$; $V_2=0.594\ 57\ \text{mm}$; $A=5.484\ 4\ \text{mm}$; $B=1.498\ 1\ \text{mm}$ 。

表3给出了GA优化的幅度比、相位差、驻波结果和理想性能目标值的比较。为了分析模型的精度对优化设计结果的影响,采用BP神经网络模型进行优化求解。表3表明,基于支持向量机替代模型的GA优化结果比BP神经网络模型更接近理想值,替代模型精度的高低决定了最终优化结果的好坏。为验证所建立的支持向量机替代模型的计算效率,将优化的结构进行电磁场有限元数值计算,给出了有限元模型和支持向量机替代模型的计算时间比较。结果表明,基于支持向量机替代模型的计算效率为有限元模型的几千倍,且比BP神经网络模型稍好,有利于大规模优化迭代计算。

表3 优化结果和计算效率对比

	幅度比	相位差	驻波	计算时间/s
SVR模型	0.504 9	-1.445 8	1.014 2	0.018
BPNN模型	0.505 6	-1.831 5	1.021 7	0.021
有限元模型	0.496 5	1.033 3	1.008 3	31
理想性能目标	0.5	0	1	/

4 结论

本文提出了一种基于支持向量机替代模型的遗传优化设计方法,通过试验设计和数值仿真生成学习样本,利用具有优化参数功能的支持向量机构建

替代模型,以替代模型为基础建立优化模型,采用遗传算法对其优化模型求解。算例表明,该方法准确、高效、可行。

试验设计和数值计算的样本选择、支持向量机替代模型构建和遗传优化过程可实现完全分离,减小优化计算量,为目标函数无显式关系的优化问题提供一种新的方法。

参 考 文 献

- [1] MYERS R H, MONTGAMERY D C, VINING G G, et al. Response surface methodology: a retrospective and literature survey[J]. Journal of Quality Technology, 2004, 36(1): 53-77.
- [2] WACKERNAGEL H. Multivariate geo-statistics[M]. Heidelberg: Springer-Verlag, 1995.
- [3] 李 烁, 徐元铭, 张 俊. 复合材料加筋结构的神经网络响应面优化设计[J]. 机械工程学报, 2006, 42(11): 115-119.
LI Shuo, XU Yuan-ming, ZHANG Jun. Neural network response surface optimization design for composite stiffened structures[J]. Chinese Journal of Mechanical Engineering, 2006, 42(11): 115-119.
- [4] VAPNIK V N. Statistical learning theory[M]. New York: Springer, 1998.
- [5] MARCELINO L, IGNACIO S. Support vector regression for the simultaneous learning of a multivariate function and its derivatives[J]. Neurocomputing, 2005, 69: 42-61.
- [6] XU Hai-xiang, ZHU Guang-xi, TIAN Jin-wen. Image segmentation based on support vector machine[J]. Journal of Electronic Science and Technology of China, 2005, 3(3): 226-230.
- [7] 陈国良, 王煦法, 庄镇权. 遗传算法及其应用[M]. 北京: 人民邮电出版社, 1996.
CHEN Guo-liang, WANG Xu-fa, ZHUANG Zheng-quan. Genetic algorithm and application[M]. Beijing: Posts & Telecom Press, 1996.
- [8] CHERKASSKY V, YUNQIAN M. Practical selection of SVM parameters and noise estimation for SVM regression[J]. Neural Networks, 2004, 17: 113-126.
- [9] ATHANASSIA C, BERNHARD S, ALEX J S. Experimentally optimal ν in support vector regression for different noise models and parameter settings[J]. Neural Networks, 2004, 17: 127-141.
- [10] 方开泰. 均匀设计和均匀设计表[M]. 北京: 科学出版社, 1994.
FANG Kai-tai. Uniform design[M]. Beijing: Science Press, 1994.

编辑 税 红