

文章编号:1000-8055(2012)02-0438-07

基于 SVR-PSO 改进算法的航空发动机 稳定性控制

王 磊¹, 谢寿生¹, 蒋爱武^{1,2}, 苗卓广¹, 翟旭升¹

(1. 空军工程大学 工程学院, 西安 710038;

2. 中国人民解放军 95095 部队, 南宁 530048)

摘 要: 在多变量发动机寻优控制中,用支持向量回归算法(SVR)对粒子群优化算法(PSO)进行改进可以有效避免局部最优解的出现.将改进算法应用于航空发动机实时稳定性控制,根据发动机仿真计算程序计算出发动机在各工作点处的稳定裕度,根据控制参数的变化域进行全局寻优,寻找满足压缩系统稳定裕度最小的工作点.仿真和分析表明:该算法实时性高,收敛速度快,具有较强的全局寻优能力,能在保证发动机稳定裕度最小的同时有效降低涡轮前温度和耗油率.

关 键 词: 粒子群算法;支持向量回归算法;航空发动机;稳定性寻优控制;稳定裕度

中图分类号: V231.3

文献标志码: A

Aero-engine stability seeking control based on improved SVR-PSO

WANG Lei¹, XIE Shou-sheng¹, JIANG Ai-wu^{1,2},MIAO Zhuo-guang¹, ZHAI Xu-sheng¹

(1. The Engineering Institute, Air Force Engineering University, Xi'an 710038, China;

2. Unit 95095 of Chinese People's Liberation Army, Nanning 530048, China)

Abstract: In the seeking control of multivariable aero-engine, general optimization algorithm may find the locally optimal solution. An improved algorithm based on particle swarm optimization (PSO) and support vector regression (SVR) was applied to aero-engine stability seeking control, setting the lower limits for surge margin to keep aero-engine working stably. The working point with minimum surge margin was searched globally. The simulation results show that the designed stability control algorithm could reduce the surge margin while keeping the thrust constant and reduce the turbine inlet temperature and specific fuel consumption effectively.

Key words: particle swarm optimization (PSO); support vector regression (SVR); aero-engine; stability seeking control; surge margin

传统的飞机推进系统要求发动机在整个飞行包线范围内有足够的可用稳定裕度,以保证发动机即使在最恶劣的工作点都能正常工作,随着飞机飞行环境的日益拓展,这种设计方法必然会带来较大的性能损失.稳定性寻优控制(stability

seeking control,简称 SSC)利用控制算法减小对部件稳定裕度的要求,将稳定性检查加入到发动机的控制逻辑中去,实时地计算出降稳因子的影响,对风扇和压气机稳定性进行在线评估,允许控制系统将喘振裕度减至最小,从而提高发动机

收稿日期:2011-03-12; 修订日期:2011-09-01

作者简介:王磊(1983—),男,河南济源人,博士生,研究领域为航空发动机综合数字控制.

性能^[1].

稳定性寻优控制^[2-5]实际为带约束的最优化问题,常用的求解方法有可行方向法、梯度投影法、既约梯度法等,这些常规优化算法容易陷入局部最优解,存在其自身的局限性,往往很难获取最优化问题的全局最优解.此外,对于发动机这样一个非线性非常严重的系统,如果控制变量的偏差较大时,这种小偏差数学模型描述的发动机工作状态有可能与实际情况存在很大的误差,根据常规优化算法计算出来的发动机最优工作点有可能要劣于原来的工作点,因此,使用常规的优化算法,只能对发动机性能在控制参数很小的变化范围内进行局部最优化,只是在现有控制规律周围对控制变量进行调整以获取性能的提升.传统发动机的最优性能往往是在工作线的边界获得,如温度限制处、转速限制处、稳定裕度限制处,这样可以通过简单的反馈控制将工作点移至边界线以实现发动机性能的提升,然而现在的先进发动机往往拥有多个控制变量,为实现所需要的性能存在着多种不同的控制模式,这样对于那种最优工作点远离由发动机控制规律确定的当前工作点的情况,用常规优化算法很难获取这个最优工作点,必须得采用能在发动机控制参数整体变化域中进行全局寻优的优化算法.

1 Support vector regression-particle sware optimization (SVR-PSO) 改进算法

1.1 小种群 PSO 算法^[6]

粒子群优化算法 (particle swarm optimization, 简称 PSO) 随机产生一个初始种群并赋予每个微粒一个随机速度,在飞行过程中,微粒的速度通过自身以及同伴的飞行经验来进行动态调整,整个群体有飞向更好搜索区域的能力^[7].由于基本 PSO 算法存在着早熟收敛及收敛较慢这两个难题,以及种群的多样性会随着迭代次数增加而下降过快、有可能收敛不到全局最优解等缺点,研究者们提出了多种方法来改进算法的性能,包括设置了不同的惯性权重 ω 随时间变化来增强算法的全局搜索性能^[8-9]等,这些方法都能有效地改进基本 PSO 算法的性能.但对于一些计算量很大、实时性要求高的优化问题,PSO 算法虽然能够获取问题的最优解,却不能满足问题的实时性要求.本文采用缩小种群规模的方法来减少运算量,同时为消除种群规模减小带来的样本多样性不足的

矛盾,引入一个粒子速度和位置重新初始化的过程,并引入变异操作来增强算法的搜索能力.

目标函数:

$$\min\{Q(x) : x \in \Omega \subset R^n\},$$

$$Q : \Omega \subset R^n \rightarrow R^1 \quad (1)$$

其中 Ω 为 R^n 中的非空集合,表示问题 $\Omega(x)$ 的可行域.

算法步骤归纳如下:

Step 1 设定群体的规模 M ,初始化群体中每一个微粒的位置 $x_i^{(0)}$ 及速度 $v_i^{(0)}$,设置计数器 count 并置为 0.

Step 2 count = count + 1; 当 count 的值达到一定的次数时,对整个种群进行重新初始化操作,并置 count 为 0,以提高种群多样性.

Step 3 计算群体中每个微粒的适应度 $Q(x_i)$.

Step 4 对群体中的每个微粒,以其当前位置的适应度 $Q(x_i)$ 与其经历过的最佳位置 p_i 的适应度 $Q(p_i)$ 相比较,若当前适应度 $Q(x_i)$ 要优于微粒最佳位置的适应度 $Q(p_i)$,则更新微粒的最佳位置 p_i 的值为当前位置 x_i ,并更新 $Q(p_i)$.

Step 5 对群体中的每个微粒,以其当前适应度 $Q(x_i)$ 与整个群体最佳位置 p_g 的适应度 $Q(p_g)$ 相比较,若当前适应度 $Q(x_i)$ 要优于整个群体最佳位置的适应度 $Q(p_g)$,则更新整个群体最佳位置 p_g 的值为当前位置 x_i ,并更新 $Q(p_g)$.

Step 6 依据式(2)更新群体中每个微粒的位置 x_i 和速度 v_i ,“认知(cognition)”和“社会(social)”参数分别为 c_1 和 c_2 , $r_1^{(k)}$ 和 $r_2^{(k)}$ 为随机变量.

$$\begin{cases} v_{i,d}^{(k+1)} = \omega \times v_{i,d}^{(k)} + c_1 \times r_1^{(k)} \times (p_{i,d}^{(k)} - x_{i,d}^{(k)}) + \\ \quad c_2 \times r_2^{(k)} \times (p_{g,d}^{(k)} - x_{i,d}^{(k)}) \\ x_{i,d}^{(k+1)} = x_{i,d}^{(k)} + v_{i,d}^{(k+1)} \end{cases} \quad (2)$$

Step 7 对整个种群进行变异操作,以增强搜索能力.变异算法为

$$x_i = \begin{cases} x_i + \delta(t, \rho_{\max}) \cdot \Delta x & \text{if } R = 0 \\ x_i + \delta(t, \rho_{\min}) \cdot \Delta x & \text{if } R = 1 \end{cases} \quad (3)$$

$$\text{s. t. } x_{\min} \leq \Delta x + x_i \leq x_{\max}$$

其中 Δx 为随机变量, R 为只取 0 和 1 的随机数, $\delta(t, \rho)$ 返回一个 $[0, \rho]$ 上的随机数, $\delta(t, \rho)$ 按下式定义:

$$\delta(t, \rho) = \rho \cdot (1 - r^{(1-t/T)^b}) \quad (4)$$

这里, r 是一个在区间 $[0, 1]$ 上满足均匀分布的随机变量, T 为最大迭代次数, b 是一个系统参数,决定了随机扰动对迭代次数 t 的依赖程度.

Step 8 对终止迭代条件进行判断,若满足算法的终止迭代条件则停止计算,若不满足则返回 Step 2 继续进行计算。

1.2 SVR 算法

支持向量回归算法^[10-12]SVR(support vector regression)对于给定的训练样本 $\{(x_1, y_1), \dots, (x_l, y_l)\}$, 首先使用一个非线性映射 φ 把数据映射到一个高维特征空间,再在高维特征空间进行线性回归^[13]。设线性函数为

$$f(x) = \langle \omega, \varphi(x) \rangle + b \quad (5)$$

其中 $\langle \omega, \varphi(x) \rangle$ 表示两个向量的内积。

优化问题是

$$\begin{aligned} \min \quad & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s. t.} \quad & \begin{cases} f(x_i) - y_i \leq \xi_i^* + \epsilon, i = 1, \dots, l \\ y_i - f(x_i) \leq \xi_i + \epsilon, i = 1, \dots, l \\ \xi_i, \xi_i^* \geq 0, i = 1, \dots, l \end{cases} \end{aligned} \quad (6)$$

目标函数中第一项使函数更为平坦,从而提高泛化能力,第二项则为减小误差,常数 C 对两者做出折中。 ϵ 为一正常数, $f(x_i)$ 与 y_i 的差别小于 ϵ 时不计入误差,大于 ϵ 时误差计为 $|f(x_i - y_i)| - \epsilon$ 。

这也是一个凸二次规划问题,根据对偶理论可得

$$\begin{aligned} \max \quad & W(\alpha, \alpha^*) = -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \\ & \langle \varphi(x_i), \varphi(x_j) \rangle + \\ & \sum_{i=1}^l (\alpha_i - \alpha_i^*) y_i - \sum_{i=1}^l (\alpha_i + \alpha_i^*) \epsilon \\ \text{s. t.} \quad & \begin{cases} \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, \dots, l \end{cases} \end{aligned} \quad (7)$$

运用支持向量机理论对未知函数进行回归估计就需要对二次规划问题(QP)进行求解,由于所转化的二次规划问题(7)较为复杂,可以采用改进的双阈值序列最小优化算法求解。

对于问题(7),其最优解必然满足

$$\alpha_i, \alpha_i^* = 0, \quad i = 1, \dots, l \quad (8)$$

依据 Karush-Kuhn-Tucker 最优化条件(KKT 条件)作为算法终止的判断准则,运用分解算法来求解由支持向量机理论描述的二次规划问题。由于篇幅限制,对于 SVR 算法中邻域的选取、支持向量数以及核函数的选择在文献^[14]中均有说明,在此不再赘述。函数回归估计的支持向量机算法具体步骤参见文献^[14]。

1.3 SVR-PSO 改进算法

由于 PSO 算法依概率来寻找问题的全局最优解,整个寻优过程带有随机性,对于简单的目标函数,算法能准确地寻找出全局最优解,但对于复杂的目标函数,PSO 算法往往不能找出最优解,而只能找到一个满足算法终止迭代条件的在最优解附近的近似解,而且对于每一次计算,这个近似解往往是不一样的;同样对 SVR 算法,从理论上讲能找到最逼近未知函数的函数式,但由于在 KKT 判断条件中引入了松弛因子,因此所获取的函数逼近式未必就是最好的。根据上述 PSO 算法及 SVR 算法的缺点,运用 SVR 来改善 PSO 的全局寻优能力:

1) 对于给定的最优化问题,运用 PSO 算法对其进行求解,算法在满足终止迭代条件时则停止计算,找到当前最优解 p_g 。

2) 对于当前最优解 p_g ,在其邻域内选取若干点 x_i 并计算其函数值 $Q(x_i)$,根据这些数据对运用 SVR 算法在该邻域内对目标函数进行回归估计,再对回归估计出的函数关系式在该邻域内进行寻优以找到一个新的最优解 p'_g ,若新解 p'_g 优于原来的解 p_g ,则将新解 p'_g 作为最优化问题所要求的最优解,否则仍将 p_g 作为问题的最优解。

为了检测改进算法的有效性,本文选择以下 6 个函数作为测试函数:

Sphere

$$f(x) = \sum_{i=1}^n x_i^2$$

Quadric

$$f(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$$

Rosenbrock

$$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2) + (x_i - 1)^2]$$

Griewank

$$f(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$$

Rastrigrin

$$f(x) = \sum_{i=1}^n [x_i^2 - A \cos(2\pi x_i) + A], A = 10$$

Schaffer F7

$$f(x) =$$

$$\sum_{i=1}^{n-1} (x_i^2 + x_{i+1}^2)^{0.25} [\sin(50(x_i^2 + x_{i+1}^2)^{0.1}) + 1]$$

对于以上 6 个测试函数,其维数均取为 3,

PSO 算法的最大迭代次数取为 100, PSO 种群规模取为 20, 算法在区间 $[-200, 200]^N$ 内进行最优解搜索, 当 PSO 算法终止后, 在当前最优解的某邻域内取点进行 SVR 回归估计, 并用 PSO 算法对回归估计的函数关系式在该邻域内进行最优解搜索, 计算结果如表 1 所示。

在表 1 中, 左边为 PSO 算法经迭代计算而获取的由各测试函数描述的最优化问题的解以及其函数值, 右边为根据 SVR 回归估计的函数式在给

定邻域内的最优解以及将最优解代入测试函数的函数值, 可以看出, 对于由 PSO 算法获取的最优化问题的当前最优解, 通过选择合适的邻域, 在其邻域内运用 SVR 算法对目标函数(目标函数形式可能是未知的)进行回归估计, 并对回归估计的函数式在该邻域内进行最优解搜索, 从计算结果可以看出, 这种方法能够改善 PSO 算法的全局搜索能力。

表 1 用 SVR 改善 PSO 全局寻优能力的计算结果

Table 1 Results of global optimization by SVR-PSO

函数	PSO 结果		SVR-PSO 结果	
	全局最优解	最优函数值	全局最优解	最优函数值
Sphere	(0.139666, -0.122517, 0.121828)	0.049359	$(1.0576 \times 10^{-2}, -7.8202 \times 10^{-4}, 2.4726 \times 10^{-3})$	1.18578×10^{-4}
Quadric	(-0.057926, 0.0250609, -0.067696)	0.0159052	(0.0256529, 0.0565367, -0.029581)	0.00924204
Rosenbrock	(-0.717964, 0.653253, 0.291823)	6.79024	(0.547798, 0.290591, 0.0768469)	0.722528
Griewank	$(1.77504 \times 10^{-5}, -4.43837, 5.43321)$	0.012321	(0.0630391, 0.099811, -0.0835348)	0.0056337
Rastrigrin	(0.955908, 0.043198, -0.0441872)	2.04792	(0.0431981, -0.043198, -0.043198)	1.10388
Schaffer F7	(7.8983, 120.122, -148.477)	0.0066756	(-51.3225, -51.378, 51.2303)	0.00188329

2 稳定性控制最优化问题设计

航空发动机稳定性控制的前提首先是要具备精准的发动机仿真模型以实时评估发动机在当前工作点的稳定裕度, 并根据先进的优化算法以获取将压缩系统稳定裕度降至最低的发动机控制参数调节量, 以对发动机工作状态进行调节, 发挥发动机的潜在性能。此外, 当发动机即将处于不稳定工作时, 主动控制技术需要知道将发动机控制参数调节到什么位置, 以保证发动机的正常工作且满足发动机的性能损失很小。

采用 SVR-PSO 改进算法来对发动机进行稳定性控制研究, 根据发动机仿真计算程序计算出高、低压压气机在各工作点处的稳定裕度, 运用优化算法依控制参数的变化域进行全局寻优, 寻找满足压缩系统稳定裕度最小的工作点, 通过设置高、低压压气机的最小稳定裕度(程序中设置为 2), 当工作点压气机稳定裕度小于该数值时, 就判定发动机即将进入不稳定工作, 优化算法开始寻找满足发动机稳定正常工作且保证高、低压压气机稳定裕度较小、发动机推力基本保持不变, 涡轮前温度和耗油率最好能有所降低的控制变量。

用于发动机稳定性控制的最优化问题可描述为

$$\min (S_{mf}, S_{mhc}, T_4^*, s_{fc})$$

$$\text{s. t. } \begin{cases} W_{f, \min} < W_f < W_{f, \max} \\ W_{f, af, \min} < W_{f, af} < W_{f, af, \max} \\ A_{8, \min} < A_8 < A_{8, \max} \\ \alpha_{1, \min} < \alpha_1 < \alpha_{1, \max} \\ \alpha_{2, \min} < \alpha_2 < \alpha_{2, \max} \\ \bar{n}_{l, \min} < \bar{n}_l < \bar{n}_{l, \max} \\ \bar{n}_{h, \min} < \bar{n}_h < \bar{n}_{h, \max} \\ S_{mf, \min} < S_{mf} \\ S_{mhc, \min} < S_{mhc} \\ p_3^* < p_{3, \max}^* \\ F = \text{const} \end{cases} \quad (9)$$

其中 S_{mf} 为低压喘振裕度, S_{mhc} 为高压喘振裕度, T_4^* 为涡轮前温度, s_{fc} 为单位耗油率, F 为发动机推力, W_f 为主供油量, $W_{f, af}$ 为加力供油量, A_8 为喷口面积, α_1, α_2 分别为低压、高压进口导流叶片角度, $\bar{n}_l$ 为低压转子相对转速, $\bar{n}_h$ 为高压转子相对转速, p_3^* 为高压出口总压。

采用 SVR-PSO 改进算法对上述最优化问题进行求解, 依据惩罚函数法将 PSO 算法的目标函数设计为

$$\min \gamma_1 \frac{S_{mf, \text{new}}}{S_{mf, \text{old}}} + \gamma_2 \frac{S_{mhc, \text{new}}}{S_{mhc, \text{old}}} + \gamma_3 \frac{T_{4, \text{new}}^*}{T_{4, \text{old}}^*} + \gamma_4 \frac{s_{fc, \text{new}}}{s_{fc, \text{old}}} + \sigma \left(\frac{F_{\text{new}}}{F_{\text{old}}} - 1 \right)^2 \quad (10)$$

其中 σ 是一个很大的正数, $\gamma_1, \gamma_2, \gamma_3, \gamma_4$ 的数值可

以根据权衡的侧重点进行调整,这里 γ_1 和 γ_2, γ_3 和 γ_4 取相同的数值. 在式(9)的约束条件中,要求推力 F 保持恒定,实际应用中发动机推力保证在原来数值的 $\pm 2\%$ 范围内变化即可,通过在目标函数中加入 $\sigma(F_{\text{new}}/F_{\text{old}} - 1)^2$ 项,来保证推力变化最小. 基于小种群的 PSO 算法最大迭代次数设置为 50,种群规模取 10,在控制参数的整体变化域中对发动机性能进行全局寻优,找到满足目标函数式(10)最小的工作点.


3 仿真及结果分析

运用 SVR-PSO 改进算法分别对涡扇发动机处于涡轮前温度未达到极限值的中间状态(intermediate state)、涡轮前温度达到极限值的大状态(high power state)以及加力状态(afterburner state)时,进行发动机稳定性控制应用研究. 本文仿真是在发动机处于以上三种状态时,对发动机工作点进行稳态优化. 图 1 为 SVR-PSO 改进算法对部分状态点进行发动机稳定性控制的优化过


程,图 2~图 6 为中间状态、大状态和加力状态下,用改进算法进行稳定性控制前后,部分参数的变化情况.

以图 1(a)为例,对于一维 sinc 函数,算法对回归函数逼近度指标的优化过程在第 6 次迭代时出现跳跃,说明算法已经找到一个更好的函数式,此后算法的最优解在相当长的一段迭代时期内(大于 10 次)保持不变,根据 PSO 算法的迭代终止条件,认为此时算法已找到问题的最优解,即找到了最好的描述目标函数的函数关系. 由图 1 可知在 50 次迭代内可以找到该状态下的全局最优解,计算速度较快且具有较好的收敛性. 在 CPU 双核主频 1.5 GHz、内存 1 GB 的计算机上,整个寻优过程能在 3 s 内完成,能够满足实时控制要求.


图 2~图 6 为三种状态下,采用 SVR-PSO 改进算法对发动机各状态进行稳定性控制后部分参数的变化情况. 对于涡轮前温度未达到极限值的中间状态而言,发动机稳定性控制通过调节发动机的控制参数,可以有效降低涡轮前温度,对发动




(a) $\alpha_1 = -13.46$; $\alpha_2 = 0$; $A_8 = 2779.91$; $W_f = 0.9771$;
 $W_{\text{lat}} = 0$ (intermediate state)



(b) $\alpha_1 = -6.67$; $\alpha_2 = 0$; $A_8 = 2779.93$; $W_f = 1.2022$;
 $W_{\text{lat}} = 0$ (intermediate state)



(c) $\alpha_1 = 0$; $\alpha_2 = 0$; $A_8 = 2779.95$; $W_f = 1.8489$;
 $W_{\text{lat}} = 0$ (high power state)



(d) $\alpha_1 = 0$; $\alpha_2 = 0$; $A_8 = 2779.95$; $W_f = 1.8189$;
 $W_{\text{lat}} = 0$ (high power state)








图1 部分状态点的优化过程

Fig. 1 Optimization of some working point

图2 中间状态优化前后 T_4 变化情况Fig. 2 T_4 of intermediate state in optimization图4 加力状态优化前后 s_{fc} 变化情况Fig. 4 s_{fc} of afterburner state in optimization图3 大状态优化前后 s_{fc} 变化情况Fig. 3 s_{fc} of high power state in optimization图5 加力状态优化前后 S_{mf} (风扇端振裕度) 变化情况Fig. 5 S_{mf} of afterburner state in optimization

机耗油率影响不大;对于涡轮前温度达到极限值的发动机较大工作状态,稳定性控制通过调节控制参数,可以降低稳定裕度,减小耗油率,耗油率下降幅度比较小;对于发动机加力工作状态,在保证发动机安全可靠工作的前提下,重新分配主燃烧室和加力燃烧室的燃油流量,提高燃油的燃

烧效率,发动机稳定性控制通过调节各控制参数,可以大幅度降低发动机的稳定裕度及耗油率,而整个优化过程始终能保持发动机推力基本不变.此外,发动机稳定性控制能对发动机稳定裕度进行严格监控,满足发动机始终工作在预设的稳定




图 6 加力状态优化前后 S_{mhc} (高压压气机喘振裕度) 变化情况

Fig. 6 S_{mhc} of afterburner state in optimization

裕度以上,当发动机陷入或即将陷入不稳定工作状态时,优化算法将给出合适的调节参数以保证发动机稳定工作。

4 结 论

研究表明,使用 SVR-PSO 改进算法能够对航空发动机进行实时稳定性控制,而且也解决了 PSO 算法只能找到一个最优解附近的近似解以及 SVR 算法函数逼近式的准确性不高的问题。SVR-PSO 改进算法收敛速度快,且具有较高的全局寻优能力,优化效果显著,在始终保持较小稳定裕度的前提下,实时调整控制参数,使发动机的潜力得到了充分的发挥,同时控制各部件协调工作,系统性能得到提高。

参考文献:

- [1] 刘大响,叶培梁,胡骏,等. 航空燃气涡轮发动机稳定性设计与评定技术[M]. 北京:航空工业出版社,2004.
- [2] Orme J S, DeLaat J C, Southwick R D, et al. Development and testing of a high stability engine control (HISTEC) system[R]. NASA/TM-1998-206562, 1998.
- [3] Southwick R D, Gallops G W, Kerr L J, et al. High stability engine control (HISTEC) flight test results[R]. AIAA-

1998-3757, 1998.

- [4] DeLaat J C, Southwick R D, Gallops G W, et al. The high stability engine control (HISTEC) program-flight demonstration phase[R]. AIAA-1998-3756, 1998.
- [5] DeLaat J C, Southwick R D, Gallops G W. High stability engine control (HISTEC)[R]. AIAA-1996-2586, 1996.
- [6] 蒋爱武. 飞机推进系统综合性能寻优及稳定性控制研究[D]. 西安:空军工程大学, 2010.
JIANG Aiwu. Research of aero-engine performance seeking control and stability seeking control[D]. Xi'an: Air Force Engineering University, 2010. (in Chinese)
- [7] Kennedy J, Eberhart R C. Particle swarm optimization [C]//Proceedings of the IEEE International Conference on Neural Networks, Perth, Australia; IEEE, 1995:1942-1948.
- [8] Shi Y H, Eberhart R C. Parameter selection in particle swarm optimization[C]//Proceedings of the 7th Annual Conference on Evolutionary Programming. San Diego: IEEE, 1998:97-102.
- [9] Shi Y H, Eberhart R. Empirical study of particle swarm optimization[C]//Proceedings of the IEEE Congress on Evolutionary Computation, Washington D C, US; IEEE, 1999:1945-1950.
- [10] Smola A J, Scholkopf B. A tutorial on support vector regression[R]. NeuroCOLT TR-98-030, 1998.
- [11] Burges C J C. A Tutorial on support vector machines for pattern recognition[J]. Data Mining and Knowledge Discovery, 1998, 2(2):121-167.
- [12] Cortes C, Vapnic V. Support-vector networks[J]. Machine Learning, 1995, 20(3):273-297.
- [13] 孙德山, 吴金培. 支持向量回归中的预测信任度[J]. 计算机科学, 2003, 30(8):126-127.
SUN Deshan, WU Jinpei. Predicting credibility based on support vector regression[J]. Journal of Computer Science, 2003, 30(8):126-127. (in Chinese)
- [14] 蒋爱武, 谢寿生. 基于支持向量机和粒子群算法的压气机特性计算[J]. 航空动力学报, 2010, 25(11):2571-2577.
JIANG Aiwu, XIE Shousheng. Method to achieve compressor characteristics maps based on SVM and PSO[J]. Journal of Aerospace Power, 2010, 25(11):2571-2577. (in Chinese)