

基于优化智能网络的发动机推力指令模型

潘 阳,李秋红,顾书文,李业波
(南京航空航天大学 能源与动力学院,南京 210016)

摘要:针对航空发动机性能退化缓解控制中推力指令模型输入量有限问题,提出 1 种双智能网络串联的推力指令建模方法。其中子模型 I 采用 BP 网络映射与推力密切相关的气路参数,其输出作为子模型 II 的输入;子模型 II 采用优化极端学习机(ELM)算法,输出为额定发动机推力,并以此推力为性能退化缓解控制指令。为了减小 ELM 网络规模,提高推力指令模型实时性,采用微分进化算法(DE)优化 ELM 初始网络参数。数字仿真验证表明:各飞行包线内推力指令模型预测值最大相对误差小于 4%,远优于单一神经网络最大 8.17%和单一极端学习机最大 14.5%的误差,模型推力指令计算时间仅需 0.64ms,实时性好,验证了该推力指令模型的有效性。

关键词:推力指令模型;性能退化缓解;极端学习机;微分进化算法;航空发动机

中图分类号:V233.7

文献标识码:A

doi:10.13477/j.cnki.aeroengine.2016.02.010

Aeroengine Thrust Command Model Based on Optimized Intelligent Networks

PAN Yang, LI Qiu-hong, GU Shu-wen, LI Ye-bo

(College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: To solve the problem of input information deficient in thrust command model used in Performance Deterioration Mitigating Control (PDMC) of aeroengine, a series of connection structure of double intelligent networks model was proposed to model the thrust. In sub-model I, a BP network was adopted to map the gas-path parameters which have closely correlation with thrust. The outputs of sub-model I were used as inputs of sub-model II. The Extreme Learning Machine (ELM) was adopted in sub-model II to estimate the nominal thrust of the engine which was used as the thrust command for PDMC. Differential Evolution (DE) was used to optimize the network parameters of ELM in order to simplify the network scale and improve the calculation speed. The result of digital simulation shows that the max relative error of thrust model is less than 4%, far better than the 8.17% error of single BP network and the 14.5% error of single ELM network. It takes only 0.64 ms in the thrust command calculation process of the model. The results demonstrate the effectiveness and real-time of proposed aeroengine thrust command model.

Key words: thrust command model; performance deterioration mitigation; extreme learning machine; differential evolution; aeroengine

0 引言

性能退化缓解控制(Performance Deterioration Mitigating Control, PDMC)为了使得航空发动机发生性能退化后,仍然能够保持额定推力,在现有控制的基础上附加外回路推力控制的方式来解决此问题^[1-3]。推力指令模型反映当前工作状态下飞机对发动机推力的需求,是 PDMC 系统的重要组成部分。国内外对此研究比较欠缺,通常以额定发动机部件级模型、3

维插值表格(高度、马赫数、油门杆角度插值)来计算推力指令,在实际应用中,影响控制系统的实时性,如果仅单独采用现有智能映射方法,则无法满足性能退化缓解控制的精度需求,为此本文针对推力指令简化模型的设计展开研究工作。常用的简化模型包括小偏差状态变量模型、平衡流型模型、智能网络模型等。状态变量模型可以在小偏差范围内模拟控制参数和气动热力参数间的响应关系^[4-5]。平衡流型模型在状态变量模型的基础上,通过线性插值和相似变换使得模型

收稿日期:2015-04-09 基金项目:航空科学基金(20110652003)、中央高校基本科研业务专项基金(NN2012033)资助

作者简介:潘阳(1991),男,在读硕士研究生,研究方向为航空发动机故障诊断;E-mail:499735168@qq.com。

引用格式:潘阳,李秋红,顾书文,等.基于优化智能网络的发动机推力指令模型[J].航空发动机,2016,42(2):51-56.PAN Yang, LI Qiu-hong, GU Shu-wen, et al. Aeroengine thrust command model based on optimized intelligent networks [J]. Aeroengine, 2016, 42(2): 51-56.

的适用范围增大,近年得到广泛应用^[6-7]。智能映射模型采用神经网络或支持向量机^[8-9]等方法设计,常用于参数预测^[10],如推力估计^[11-12],传感器故障诊断^[13-14]等方面。**NASA**采用“状态变量模型+神经网络”的方法建立简化模型,并结合**Kalman**滤波器使得模型具有自适应能力^[15]。

本文提出基于双智能网络串联的推力指令建模方法。推力指令模型采用离线训练在线使用的模式,首先在发动机额定状态下,以 H 、 Ma 、 PLA 映射和推力密切相关的气路参数,形成子模型 I;然后将模型 I 的输出作为子模型 II 的输入,映射发动机额定状态下的推力,为性能退化缓解控制提供指令。

1 推力指令简化模型结构

推力指令模型与常规简化模型不同,它计算的是不同工作状态下飞机对发动机的推力需求,反映的是额定发动机的推力,不受发动机性能退化的影响,因此其输入不能包含发动机的气路参数和控制量信息,这些信息会因发动机性能退化而改变。因此推力指令模型的可用输入只有高度 H , 马赫数 Ma 以及油门杆角度 PLA ,使得常规的简化模型建立方法无法满足要求。

由于发动机是强非线性系统,仅采用这 3 个量作为输入直接对额定推力进行映射其效果较差,因此本文将推力指令模型的训练步骤分为 2 个子模型:子模型 I 以 H 、 Ma 和 PLA 为输入,对与推力密切相关的发动机气路参数进行映射;子模型 II 以子模型 I 的输出加上 H 、 Ma 为输入,输出为额定发动机推力 F ,这种双层智能网络结构,在子模型 II 中包含了额定状态下的发动机气路参数信息,有效解决了推力指令简化模型输入信息不足的问题。

基于集成学习思想,对 2 个子模型采取不同的训练方法。鉴于子模型 I 各输出参数对于整个推力指令简化模型精度影响较大,本文对子模型 I 采用经典 BP 神经网络训练^[16],而对于子模型 II 为单输出模块,关系到最终的推力指令精度,对其采取优化极端学习机算法 (ELM) 训练^[17-18],以微分进化 (Differential evolution, DE) 算法对 ELM 输入层权值以及隐含层偏置进行优化,以提高网络映射能力及实时性。子模型 I 与子模型 II 进行串联后形成推力指令简化模型,其结构如图 1 所示。

图中子模型 I 采用 BP 网络映射得到的和推力密

切相关的气路参数预测值,子模型 II 基于子模型 I 获得的预测值结合高度、马赫数映射推力指令。整个网络采取离线训练方式,得到网络参数后形成

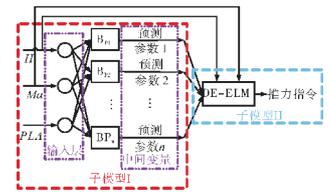


图 1 推力指令简化模型结构

推力指令简化模型。下面对子模型 I 进行设计。

2 基于 BP 网络的子模型 I

子模型 I 输入为 H 、 Ma 、 PLA ,输出为与发动机推力密切相关的气路参数,为子模型 II 提供更多的输入信息。

通过计算发动机各截面气路参数与额定推力 F 之间的相关性,选取相关性较高且包含信息丰富的组合作为子模型 I 的输出,包括高压压气机出口温度 T_3 ,低压涡轮出口压力 P_{46} ,低压涡轮出口温度 T_{46} ,尾喷管喉道温度 T_8 ,发动机总温比 T_{ER0} 。

对子模型 I 的每个输出单独建立 BP 网络,为了提高网络映射精度,本文将飞行包线按高度分为 0~5、5~10、10~15、15~20 km 4 个子包线,分别在子包线内建立推力简化模型。

在训练过程中,通过遍历搜索在所有包线内 BP 神经网络的隐含层节点都设定为 40。隐含层激励函数选为 $tansig$,输出层激励函数选为 $logsig$ 。在 4 个高度子包线内子模型 I 各输出参数预测相对误差平均值及最大值见表 1。

表 1 子模型 I 的 BP 网络训练平均误差及最大误差

中间变量	种类	高度包线 /km							
		0-5		5-10		10-15		15-20	
		Mean	Max	Mean	Max	Mean	Max	Mean	Max
T_3	训练	7.966E-04	1.20E-02	1.132E-03	1.45E-02	8.690E-04	1.60E-02	5.259E-04	3.10E-03
	测试	1.043E-03	2.61E-02	1.285E-03	1.63E-02	1.024E-03	2.19E-02	6.022E-04	3.10E-03
P_{46}	训练	2.530E-03	3.40E-02	2.318E-03	2.09E-02	4.016E-03	4.16E-02	2.435E-03	3.19E-02
	测试	2.878E-03	4.37E-02	2.565E-03	3.35E-02	4.307E-03	4.21E-02	2.729E-03	2.54E-02
T_{46}	训练	9.094E-04	1.27E-02	8.189E-04	1.17E-02	1.539E-03	2.33E-02	6.718E-04	4.90E-03
	测试	1.089E-03	1.92E-02	9.639E-04	1.35E-02	1.646E-03	2.43E-02	7.087E-04	3.90E-03
T_8	训练	1.037E-03	9.60E-03	1.107E-03	1.66E-02	1.651E-03	2.66E-02	1.106E-03	8.60E-03
	测试	1.324E-03	3.55E-02	1.253E-03	1.99E-02	1.787E-03	3.08E-02	1.641E-03	4.71E-02
T_{ER}	训练	1.317E-03	1.59E-02	1.237E-03	1.97E-02	1.878E-03	2.67E-02	6.828E-04	5.40E-03
	测试	1.624E-03	2.59E-02	1.384E-03	2.21E-02	2.023E-03	2.63E-02	8.223E-04	9.00E-03

从表中可见,虽然子模型 I 输出的发动机参数训练以及测试相对误差平均值均在 5%以内,但其最大

误差超过 4.71%，若以单独 BP 网络建立推力指令模型，势必会引起推力偏离期望值。因此仅以 H、Ma、PLA 作为输入，进行推力指令计算是不能满足性能退化缓解控制需求的。

3 基于优化 ELM 的子模型 II

子模型 II 采用 ELM 算法设计。ELM 算法预测精度随着隐含层节点数的增加而提高，但过多的隐含层节点数势必会使得网络结构复杂，降低计算实时性，因此本文希望在保证计算精度的前提下，将 ELM 隐含层节点数控制为 40 个以提高计算速度。由于 ELM 算法的输入层权值以及隐含层偏置均在初始化时随机生成，不能保证 ELM 获得最优的结果，而子模型 II 的映射能力直接关系到推力指令的精度，为此对子模型 II 的网络参数进行优化设计。

本文要进行优化的极端学习机初始化参数较多，采用微分进化算法^[9]对其进行优化，以获得相同预测精度下隐含层节点更少的 ELM 网络，提高推力指令简化模型实时性和精度。

3.1 微分进化算法

微分进化(DE)算法在收敛速度和稳定性方面都有极为出色的表现，是近年来最热门的进化算法，具有保存最优解并与种群内部进行信息共享的特点。算法的基本思想是利用向量差的操作规则从初始种群开始进行交叉、变异等操作，通过不断迭代计算实现优胜劣汰，引导个体向最优解逼近^[20]。其算法流程如下：

(1)参数设置。设定待优化参数维数为 D，种群规模为 N_p ，放缩因子为 F，交叉常量为 C_R 。

(2)初始化。在问题的搜索空间中随机产生初代种群 $x(0)$ ，并计算每个个体的适应度 $f_{fit}(x_i(0))$ 。

$$x_{i,j}(0) = x_{j,min} + \text{rand}(0,1) \times (x_{j,max} - x_{j,min}) \quad (1)$$

式中： $i \in \{1, 2, \dots, N_p\}$ ； $j \in \{1, 2, \dots, D\}$ ； $x_{j,min}$ 和 $x_{j,max}$ 为解空间中第 j 维的上、下界； $\text{rand}(0,1)$ 为 (0,1) 区间内的随机数。

(3)变异。在目标个体 x_i 之外随机选取另外 3 个不同的个体 x_{r_1} 、 x_{r_2} 及 x_{r_3} ，将 2 个互异的个体向量相减产生差分向量，将得到的差分向量乘以 1 个系数并与另一随机选出的向量相加，生成变异个体 v_i 。

$$v_i = x_{r_1} + F \cdot (x_{r_2} - x_{r_3}) \quad (2)$$

式中：F 为定值放缩因子； $r_1, r_2, r_3 \in [1, N_p]$ 且 $r_1 \neq r_2 \neq r_3 \neq i$ 。

(4)交叉。按照给定的交叉率 C_R 将目标个体 x_i 与变异个体 v_i 进行混合交叉生成交叉个体 u_i 。

$$u_{i,j} = \begin{cases} v_{i,j}, & \text{rand}(0,1) \leq C_R \\ x_{i,j}, & \text{rand}(0,1) > C_R \end{cases} \quad (3)$$

(5)选择。当前迭代次数为 n，交叉个体 $u_i(n)$ 与原目标个体 $x_i(n)$ 进行贪婪选择，择优生成新 1 代的种群个体 $x_i(n+1)$ 。

$$x_i(n+1) = \begin{cases} u_i(n), & \text{fit}[u_i(n)] \geq \text{fit}[x_i(n)] \\ x_i(n), & \text{else} \end{cases} \quad (4)$$

式中： N_p ； $\text{fit}(\cdot)$ 为适应度算子。

(6)检验是否满足结束条件。若满足则停止循环，输出问题的最优解，如不满足则继续迭代，重复(3)~(5)的过程。

3.2 基于 DE 算法优化的 ELM 算法

在 ELM 算法中，给定 1 个训练数据集 $\chi = \{x_j, t_j\}_1^N$ ，其中输入数据 $x_j = [x_{j1}, \dots, x_{jn}]^T \in R^n$ ，期望输出数据 $t_j = [t_{j1}, \dots, t_{jm}]^T \in R^m$ ，并设隐含层激励函数为 $g(x)$ ，则含有 \tilde{N} 个隐含层节点的 ELM 的数学模型为

$$t_j = \sum_{i=1}^{\tilde{N}} \beta_i g(w_i x_j + b_i), \quad j=1, 2, \dots, N \quad (5)$$

式中： $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 为连接输入层节点与隐含层第 i 个节点的权值； b_i 为隐含层第 i 节点的偏置； $\beta_i = [\beta_{i1}, \dots, \beta_{im}]^T$ 为连接隐含层第 i 节点和输出层节点的权值。

式(5)可以表达为

$$H\beta = T \quad (6)$$

隐含层矩阵 H 的第 i 个隐含层节点的输出，即第 i 列元素 h_i 为

$$h_i = \begin{bmatrix} g(w_{i1} x_1 + b_i) \\ g(w_{i2} x_2 + b_i) \\ \dots \\ g(w_{iN} x_N + b_i) \end{bmatrix}_{N \times 1} \quad (7)$$

输出权值 β 为

$$\beta = H^+ T \quad (8)$$

式中： H^+ 为 H 的广义逆矩阵。

由于 ELM 的输入层权值与及隐含层偏置是随机给定的，只通过广义逆矩阵修正输出层权值，需要较多的隐含层节点数量来保证精度，这就增加了网络规模的复杂性，降低了实时性^[21]。

为了提高 ELM 算法在线使用时的计算速度，减

少映射使用隐含层节点数量,采用 DE 算法对 ELM 的输入层权值和隐含层偏置进行优化,成为 DE-ELM 算法,对子模型 II 进行训练。以 T_3 、 P_{46} 、 T_{46} 、 T_8 和 T_{ER} 共 5 个子模型 I 的输出加上 H 、 Ma 作为输入,额定发动机推力 F 为输出,采用 DE-ELM 算法进行训练。

在 DE 算法中,种群规模以及迭代次数越多,优化结果越接近最优解,但会急剧增加优化耗时;缩放因子 F 过小会引起算法过早收敛,难以跳出局部最优,而过大则会使得 DE 算法收敛速度降低,根据经验 F 取 0.6 具有较好的优化效果;通常交叉常量 C_R 较好的取值范围为 $[0.3, 0.9]$,较大的 C_R 会加快 DE 算法收敛速度^[20]。

在训练子模型 II 时,DE-ELM 算法中的设置 ELM 隐含层节点数设置为 40 个,经过多次尝试,设定 DE 算法的种群规模 N_p 为 100,放缩因子 F 为 0.6,交叉常量 C_R 为 0.9,最大迭代次数 $N_{max}=500$,在较短的优化时间内具有最佳优化效果,定义适应度函数为 ELM 训练样本数据预测误差绝对值之和的倒数,其形式为

$$fit(x_i) = \frac{1}{\sum_{k=1}^N |e_k|} \quad (9)$$

式中: N 为 ELM 训练样本数据容量; e_k 为第 k 个 ELM 训练样本预测值的相对误差。

将 DE-ELM 算法与 ELM 算法预测结果进行对比(其节点数通过遍历获得)。在映射达到相同平均误差水平的情况下,隐含层节点数量见表 2。

从表中可见,DE-ELM 算法相较于 ELM 算法,在达到同等映射精度的情况下所需的隐含层节点数量更少,网络规模小,映射的实时性更好。

表 2 ELM 网络优化前后效果对比

H/km	算法	隐含层节点数	平均误差
0-5	ELM	71	4.08E-04
	DE-ELM	40	4.04E-04
5-10	ELM	75	3.37E-04
	DE-ELM	40	3.35E-04
15-20	ELM	73	5.91E-04
	DE-ELM	40	5.88E-04
15-20	ELM	65	3.58E-04
	DE-ELM	40	3.57E-04

4 发动机推力指令简化模型仿真

以某型双轴涡扇发动机为例,将子模型 I 和子模型 II 串联,形成如图 1 所示的推力指令简化模型,以高度、马赫数、油门角度为输入,对发动机推力指令进行计算,不同包线分区内,推力指令计算相对误差如图 2 所示。值得指出的是,子模型 I 和子模型 II 均采用离线训练方法,在实际使用时,只需将网络参数代入,基于隐含层和输出层激励函数进行计算,即可获得推力指令,不需要进行在线训练,同时由于模型输入只与 H 、 Ma 、 PLA 有关,获得的推力指令反映发动机的额定推力需求,不随发动机的个体差异而变化,可以为性能退化缓解控制提供指令。

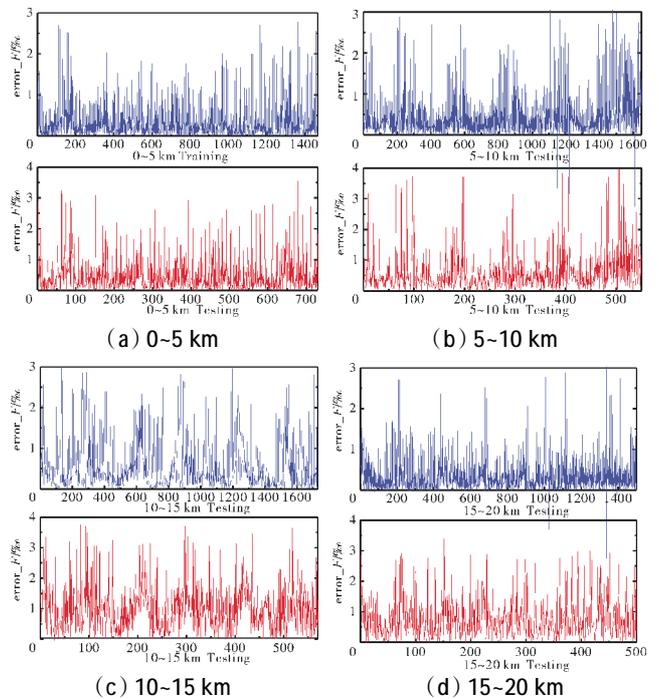


图 2 推力指令简化模型预测误差

从图中可见,本文提出的基于 BP 网络以及 DE-ELM 算法的双层结构推力简化模型具有良好的预测精度和泛化能力,训练样本最大相对误差小于 3%,测试样本最大相对误差小于 4%。经测试,推力指令简化模型 1 次计算耗时 0.64 ms,远快于部件级模型迭代计算时间,可以用于性能退化缓解控制的推力指令计算。

为了进一步验证本文所提出的推力指令简化模型的优势,以 H 、 Ma 、 PLA 为输入,将直接采用单独 BP 网络或 ELM 进行额定推力估计的结果与推力指令简化模型进行误差对比,结果见表 3。

表3 推力指令预测误差对比

H/km	误差种类	ELM		BP		推力指令简化模型	
		Mean	Max	Mean	Max	Mean	Max
0-5	训练	1.78E-02	9.57E-02	5.13E-03	5.38E-02	4.04E-04	3.68E-03
	测试	2.67E-02	1.45E-01	5.50E-03	5.99E-02	4.27E-04	3.94E-03
5-10	训练	1.90E-02	1.10E-01	6.49E-03	8.17E-02	3.35E-04	2.95E-03
	测试	1.87E-02	9.09E-02	7.36E-03	5.56E-02	3.76E-04	3.93E-03
10-15	训练	1.93E-02	1.04E-01	5.43E-03	4.89E-02	5.88E-04	2.99E-03
	测试	1.91E-02	1.10E-01	5.67E-03	5.28E-02	6.04E-03	3.74E-03
15-20	训练	1.97E-02	9.15E-02	4.45E-03	4.16E-02	3.47E-04	2.71E-03
	测试	1.92E-02	7.21E-02	4.80E-03	4.20E-02	3.83E-04	3.50E-03

通过表中的对比可见,采用单一神经网络进行推力指令计算时,虽然计算平均误差不大,但在各子包线内的最大误差均超过4%,而单一的极端学习机的最大计算误差则均超过7.2%。而本文所提出的双智能网络推力指令简化模型,包线推力计算最大相对误差为4‰,远优于单一神经网络最大8.17%和单一极端学习机最大14.5%的误差,验证了双智能网络在推力指令计算中的优势。

本文提出的推力简化模型通过离线训练获取网络参数,在实际应用过程中仅需编程构建网络结构,相较于机载模型计算过程更为简单,具有良好的工程应用前景。

5 结论

本文提出1种基于双智能网络的推力指令简化模型设计方法,采用2个子模型串联的结构,分别用BP神经网络和DE-ELM网络训练2个子模型,其工作模式为离线训练在线使用。

(1)DE-ELM算法在相同映射精度的前提下,简化了ELM网络规模。

(2)基于双智能网络的推力指令简化模型最大预测误差小于4‰,计算时间小于0.64 ms,具有较高的精度和实时性。

(3)推力指令简化模型工程实现简单,将离线训练参数存储后,通过编程计算可以实现在线实时获取额定推力指令。

(4)双智能网络串联的结构为实现高精度简化模型提供了有益的思路。

参考文献:

[1] Garg S. Controls and health management technologies for intelligent

aerospace propulsion systems[R]. AIAA-2004-0949.

[2] Garg S. NASA Glenn research in controls and diagnostics for intelligent aerospace propulsion systems[R]. NASA-TM-2005-214036.

[3] 李业波,李秋红,黄向华,等.航空发动机性能退化缓解控制技术[J].航空动力学报,2012,27(4):930-936.

LI Yebo, LI QiuHong, HUANG Xianghua, et al. Performance deterioration mitigation control of aero-engine [J]. Journal of Aerospace Power, 2012, 27(4): 930-936. (in Chinese)

[4] Weiss M, Bucco D. Adjoint method for hybrid guidance loop state-space models [J]. Journal of Guidance, Control, and Dynamics, 2014, 38(4): 1-9.

[5] 胡宇,杨月诚,张世英,等.基于改进拟合法的涡扇发动机状态变量模型建立方法[J].推进技术,2013,34(3):405-410.

HU Yu, YANG Yuecheng, ZHANG Shiyong, et al. Establishment of turbofan engine state variable model based on improved fitting method [J]. Journal of Propulsion Technology, 2013, 34(3): 405-410. (in Chinese)

[6] 赵辉,牛军,姜云峰,等.基于平衡流形模型的航空发动机线性建模方法[J].推进技术,2011,32(3):377-382.

ZHAO Hui, NIU Jun, JIANG Yunfeng, et al. Linear modeling of aero engines based on equilibrium manifold model [J]. Journal of Propulsion Technology, 2011, 32(3): 377-382. (in Chinese)

[7] 李述清,张胜修,胡卫红.基于平衡流形的航空发动机LPV建模方法[J].推进技术,2011,32(1):21-25.

LI Shuqing, ZHANG Shengxiu, HU Weihong. Equilibrium-manifold based linear parameter varying modeling for aeroengine [J]. Journal of Propulsion Technology, 2011, 32(1): 21-25. (in Chinese)

[8] ZHAO Y, SUN J. Recursive reduced least squares support vector regression[J]. Pattern Recognition, 2009, 42(5): 837-842.

[9] Basudhar A, Missoum S. Reliability assessment using probabilistic support vector machines [J]. International Journal of Reliability and Safety, 2013, 7(2): 156-173.

[10] Ghafir M F A, Li Y G, Wang L. Creep life prediction for aero gas turbine hot section component using artificial neural networks [J]. Journal of Engineering for Gas Turbines and Power, 2014, 136(3): 1-9.

[11] Peyada N, Ghosh A. Aircraft parameter estimation using neural network based algorithm [C]//Atmospheric Flight Mechanics Conference. Chicago: AIAA Press, 2009: 5941-5950.

[12] 赵永平,孙健国,王前宇,等.基于K-均值聚类和约简最小二乘支持向量回归机的推力估计器设计[J].航空动力学报,2010,25(5): 1177-1183.

ZHAO Yongping, SUN Jianguo, WANG Qianyu, et al. Thrust estimator design based on K-means clustering and reduced least squares support vector regression [J]. Journal of Aerospace Power, 2010, 25(5): 1177-1183. (in Chinese)

[13] 冯志刚,王祁,徐涛,等.基于小波包和支持向量机的传感器故障诊断方法[J].南京理工大学学报(自然科学版),2008,32(5): 609-614.

- FENG Zhigang, WANG Qi, XU Tao, et al. Sensor fault diagnosis based on wavelet packet and support vector machines [J]. Journal of Nanjing University of Science and Technology (Natural Science), 2008, 32(5): 609-614. (in Chinese)
- [14] Van E, Chu Q P. Sensor fault detection and isolation for redundant air data sensors[R]. AIAA-2014-1147.
- [15] Vloponi A. Enhanced self tuning on-board real-time model (eSTORM) for aircraft engine performance health tracking [R]. NASA-CR-2008-215272.
- [16] 李萍, 曾令可, 税安泽, 等. 基于 MATLAB 的 BP 神经网络预测系统的设计[J]. 计算机应用与软件, 2008, 25(4): 149-150, 184.
- LI Ping, ZENG Lingke, SHUI Anze, et al. Design of forecast system of back propagation neural network based on MATLAB [J]. Computer Applications and Software, 2008, 25(4): 149-150, 184. (in Chinese)
- [17] 王新迎, 韩敏. 基于极端学习机的多变量混沌时间序列预测[J]. 物理学报, 2012, 61(8): 97-105.
- WANG Xinying, HAN Min. Multi-variate chaotic time series prediction based on extreme learning machine [J]. Acta Physica Sinica, 2012, 61(8): 97-105. (in Chinese)
- [18] 赵永平, 王康康. 具有增加删除机制的正则化极端学习机的混沌时间序列预测[J]. 物理学报, 2013, 62(24): 82-89.
- ZHAO Yongping, WANG Kangkang. Chaotic time series prediction using add-delete mechanism based regularized extreme learning machine[J]. Acta Physica Sinica, 2013, 62(24): 82-89. (in Chinese)
- [19] Storn R, Price K. Differential evolution: a simple and efficient heuristic for global optimization over continuous spaces [J]. Journal of Global Optimization, 1997, 11(4): 341-359.
- [20] 段海滨, 张祥银, 徐春芳. 仿生智能计算[M]. 北京: 科学出版社, 2011: 90-92.
- DUAN Haibing, ZHANG Xiangyin, XU Chunfang. Bioinspired computing[M]. Beijing: Science Press, 2011: 90-92. (in Chinese)
- [21] Matej C, Shin H L, Marjan M. Exploration and exploitation in evolutionary algorithms: a survey [J]. ACM Computing Surveys, 2013, 45(3): 21-33.
- [21] 李业波. 智能航空发动机性能退化缓解控制技术研究[D]. 南京: 南京航空航天大学, 2014.
- LI Yebo. Research on intelligent aeroengine performance deterioration mitigating control[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2014. (in Chinese)

(编辑: 赵明菁)