# 基于粒子群核极限学习机的涡扇 发动机加速过程模型辨识<sup>\*</sup>

赵姝帆,李本威,钱仁军,朱飞翔

(海军航空大学 航空基础学院,山东烟台 264001)

摘 要:针对解析法建立涡扇发动机加速过程模型精度和实时性不高的问题,提出了一种基于粒子 群核极值学习机 (PSO-KELM)的涡扇发动机加速过程模型数据驱动辨识方法,构建涡扇发动机加速过 程模型,结合加速过程试车数据,利用 PSO-KELM 方法对该加速模型进行辨识。试验结果表明:低压 转子转速、高压转子转速和低压涡轮出口燃气总温都较好地逼近了试车数据,最大相对误差均值分别为 1.013%,0.355%和1.055%,平均计算时间为0.04ms。精度和实时性均优于反向传播神经网络和粒子群 支持向量回归方法,可用于发动机状态监控和性能优化控制。

关键词:涡扇发动机;加速过程;核极限学习机;数据驱动;模型辨识 中图分类号:V233.7 文献标识码:A 文章编号:1001-4055 (2020) 10-2358-09 DOI: 10.13675/j.cnki. tjjs. 190586

# Turbofan Engine Model Identification of Acceleration Process Based on Particle Swarm Optimization Kernel Extreme Learning Machine

ZHAO Shu-fan, LI Ben-wei, QIAN Ren-jun, ZHU Fei-xiang

(Aviation Foundation College, Naval Aeronautical University, Yantai 264001, China)

**Abstract**: In order to solve the problem of low accuracy and real-time in establishing the model of turbofan engine acceleration process by analytic method, a data-driven method on identifying the turbofan engine acceleration process model based on kernel extreme learning machine (KELM) optimized by particle swarm optimization (PSO) was proposed. Firstly, a turbofan engine acceleration process model was constructed. Then, PSO-KELM was adopted to identify the model using engine acceleration process test data. The results show that identification results of the low-pressure rotor speed, the high-pressure rotor speed and the low-pressure turbine outlet gas temperature are all close to measured data, the mean maximum relative errors are 1.013%, 0.355% and 1.055%, respectively, and the mean computing time is 0.04ms. The precision and real-time are better than back propagation (BP) neural network method and PSO-support vector regression (SVR). This method can be used for engine condition monitoring and performance optimization control.

Key words: Turbofan engine; Acceleration process; Kernel extreme learning machine; Data-driven; Model identification

<sup>\*</sup> 收稿日期: 2019-08-27;修订日期: 2019-09-24。

基金项目:国家自然科学基金 (51505492);山东省自然科学基金 (ZR2016FQ19);泰山学者建设工程专项经费。

通讯作者:赵姝帆,博士生,研究领域为航空发动机健康管理。E-mail: lightoffreedom@163.com

引用格式: 赵妹帆,李本威,钱仁军,等.基于粒子群核极限学习机的涡扇发动机加速过程模型辨识[J]. 推进技术,2020, 41(10):2358-2366. (ZHAO Shu-fan, LI Ben-wei, QIAN Ren-jun, et al. Turbofan Engine Model Identification of Acceleration Process Based on Particle Swarm Optimization Kernel Extreme Learning Machine[J]. Journal of Propulsion Technology, 2020, 41(10):2358-2366.)

# 1 引 言

加速过程是航空发动机典型的动态过程,与起 动和减速过程相比,加速性能对航空发动机和飞机 性能有更直接和明显的影响[1]。它在很大程度上决 定了飞机的机动性,从而确保飞机能够完成爬升、紧 急着陆和逃逸复飞等动作[2-3]。航空发动机加速模型 在发动机性能仿真、状态监控、控制规律设计和传感 器故障检测等方面具有重要作用[4],同时快速准确的 加速模型也是发动机智能控制的基础。随着全权限 数字电子控制系统(FADEC)在军用发动机和民用发 动机中引入,航空发动机控制正从基于传感器的控 制向基于模型的控制改进<sup>[5]</sup>。NASA的智能发动机控 制(IEC)计划和综合高性能涡轮发动机技术 (IHPTET)计划报道,这种基于模型的控制概念将通 过模型充分发掘发动机的潜力<sup>[6-7]</sup>。延寿控制<sup>[8]</sup>、主 动稳定性控制<sup>[9]</sup>和性能寻优控制<sup>[10]</sup>等航空发动机先 进控制技术均基于发动机动态模型实现不同控制目 的[11-12]。因此,建立一个快速、准确的加速过程模型对 于发动机状态监控和加速性能优化具有重要意义。

航空发动机是一个多变量、非线性和复杂的气 动热力学系统,建立精确的发动机加速过程模型具 有较大的困难。常用的建模方法主要有解析法和数 据驱动的方法[13],采用解析法建立模型需要充足的 发动机部件特性数据,而部件特性常常难以获取[14]。 基于数据驱动的模型不需要发动机的部件特性,由 智能算法直接从发动机实际测量数据中辨识得到发 动机模型。基于数据驱动的加速过程辨识方法主要 有人工神经网络(ANN)和支持向量回归(SVR)<sup>[15]</sup>。 尉询楷等[16]采用支持向量机对发动机加速过程进行 了辨识;王海涛等[17]提出了稀疏最小二乘支持向量 机,并将其应用于发动机动态过程辨识中;潘鹏飞 等[18]采用人工神经网络和基于外源输入的非线性自 回归(NARX)模型对涡扇发动机的飞行参数进行了 辨识;Zheng等<sup>[19]</sup>采用最小批量梯度下降(MGD)神经 网络建立发动机动态模型;然而,传统的神经网络采 用梯度下降的学习方法,存在一些无法避免的问题, 比如训练时间偏长、易陷入局部极值和参数选择无 依据等问题<sup>[20]</sup>。SVR方法为多输入单输出结构,针 对每一个输出参数都需要设计一个子 SVR 模型<sup>[21]</sup>。 随着输出参数和训练参数的增多,结构会变得更加 复杂,这会导致训练时间和测试时间的增加。

极限学习机(ELM)是 Huang等提出的单隐层前 馈神经网络<sup>[22]</sup>,其输入权重和隐藏层偏差都是随机 生成,求解隐藏层输出矩阵的 Moore-Penrose 广义逆 得到输出权重,完成网络训练,整个过程没有迭代计 算。与传统神经网络相比,ELM 具有计算速度快、泛 化能力强等优点<sup>[23]</sup>。然而,输入权重和隐藏层偏差 的随机分配导致了 ELM 性能不稳定。核极限学习机 (KELM)是由 ELM 和核函数相结合而形成的,它不仅 具有 ELM 的诸多优点,而且具有较强的非线性映射 能力<sup>[24]</sup>。相关研究表明,其非线性映射能力优于 SVR 和 ELM<sup>[25]</sup>,因此,KELM 适用于航空发动机等复 杂非线性系统的模型辨识。然而,由于引入了核函 数,KELM 对核函数的参数设置较为敏感。

本文提出了基于粒子群优化核极限学习机 (PSO-KELM)的航空发动机加速过程模型辨识方法, 构建涡扇发动机加速过程模型,利用PSO寻优得到适 用于加速过程模型辨识的KELM特征参数,采用 KELM方法结合加速过程试车数据对该加速模型进 行辨识,将其与BP神经网络和PSO-SVR辨识方法进 行了比较。结果表明,该方法能较好地反映和预测 加速过程的动态特性,精度和实时性均优于BP神经 网络和SVR方法,可用于涡扇发动机状态监控和优 化控制。

# 2 基于 PSO-KELM 的涡扇发动机加速模型 辨识

#### 2.1 核极限学习机模型

极限学习机是一个多输入多输出的单隐层神经 网络,具有极快的学习能力<sup>[26]</sup>。KELM在网络中引入 核函数,具有更强大的泛化能力,同时具有极限学习 机的实时性。

假设有 Q 组训练样本  $(X_i, t_i)(i = 1, 2, \dots, Q)$ , 输入向量  $X_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n$ , 输出向量  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbb{R}^m$ , 对于一个有 L 个隐层节点的单隐层神经网络可以表示为

$$\sum_{i=1}^{L} \boldsymbol{\beta}_{i} g \left( \boldsymbol{W}_{i} \cdot \boldsymbol{X}_{j} + \boldsymbol{b}_{i} \right) = \boldsymbol{o}_{j} \quad (j = 1, \cdots, Q)$$
(1)

式中 $\boldsymbol{\beta}_i = [\beta_{i1}, \beta_{i2}, ..., \beta_{im}]^T$ 为输出层节点和隐层 节点之间的权重向量,g(x)为激活函数,可以是任意 有界的非恒量连续函数<sup>[27]</sup>,  $\boldsymbol{W}_i = [\boldsymbol{\omega}_{i,1}, \boldsymbol{\omega}_{i,2}, ..., \boldsymbol{\omega}_{i,n}]^T$ 为隐层节点和输入节点之间的权重向量, $\boldsymbol{W}_i \cdot \boldsymbol{X}_j \rightarrow \boldsymbol{W}_i$ 和 $\boldsymbol{X}_j$ 的内积, $\boldsymbol{b}_i$ 为第i个隐层单元的偏置, $\boldsymbol{o}_j$ 为网络 输出。

单隐层神经网络学习的目标是使得输出的误差

最小,可以表示为

$$\sum_{j=1}^{Q} \left\| \boldsymbol{o}_{j} - \boldsymbol{t}_{j} \right\| = 0 \tag{2}$$

即存在 $\beta_i$ ,  $W_i$ 和 $b_i$ , 使得

$$\sum_{i=1}^{L} \boldsymbol{\beta}_{i} g \left( \boldsymbol{W}_{i} \cdot \boldsymbol{X}_{j} + \boldsymbol{b}_{i} \right) = \boldsymbol{t}_{j} \quad (j = 1, \cdots, Q)$$
(3)

其矩阵表示为

$$H\beta = T \tag{4}$$

$$H(\mathbf{W}_{1},\cdots,\mathbf{W}_{L},\mathbf{b}_{1},\cdots,\mathbf{b}_{L},\mathbf{X}_{1},\cdots,\mathbf{X}_{Q}) = \begin{bmatrix}g(\mathbf{W}_{1}\cdot\mathbf{X}_{1}+\mathbf{b}_{1}) & \cdots & g(\mathbf{W}_{L}\cdot\mathbf{X}_{1}+\mathbf{b}_{L})\\ \cdots & \cdots & \cdots\\ g(\mathbf{W}_{1}\cdot\mathbf{X}_{Q}+\mathbf{b}_{1}) & \cdots & g(\mathbf{W}_{L}\cdot\mathbf{X}_{Q}+\mathbf{b}_{L})\end{bmatrix}_{Q\times L}$$
(5)
$$\begin{bmatrix}\mathbf{\beta}_{1}^{\mathrm{T}}\end{bmatrix} \qquad \begin{bmatrix}\mathbf{T}_{1}^{\mathrm{T}}\end{bmatrix}$$

$$\boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1 \\ \vdots \\ \boldsymbol{\beta}_L^{\mathsf{T}} \end{bmatrix}_{L \times m}, \boldsymbol{T} = \begin{bmatrix} \boldsymbol{I}_1 \\ \vdots \\ \boldsymbol{T}_Q^{\mathsf{T}} \end{bmatrix}_{Q \times m}$$
(6)

式中**T**为期望输出,**β**为输出权重,**H**是隐层节点的输出,**W**<sub>i</sub>和**b**<sub>i</sub>均为随机给定。求出输出权值**β**的最小二乘解,训练便可完成。因此,其学习效率和运算 速度比传统的 NN 法更高<sup>[28]</sup>。

$$\hat{\boldsymbol{\beta}} = \boldsymbol{H}^{\mathrm{T}}\boldsymbol{T} = \left(\boldsymbol{H}^{\mathrm{T}}\boldsymbol{H}\right)^{-1}\boldsymbol{H}^{\mathrm{T}}\boldsymbol{T}$$
(7)

式中
$$H^+$$
为 $H$ 的 Moore-Penrose 广义逆。  
令 $h(x_i) = [g(W_1 \cdot X_1 + b_1) \cdots g(W_L \cdot X_1 + b_L)]$ ,即有

$$\boldsymbol{H}^{\mathrm{T}}\boldsymbol{H} = \begin{bmatrix} \boldsymbol{h}(x_{1}) \\ \vdots \\ \boldsymbol{h}(x_{0}) \end{bmatrix}_{Q \times L}^{\mathrm{T}} \begin{bmatrix} \boldsymbol{h}(x_{1}) \\ \vdots \\ \boldsymbol{h}(x_{0}) \end{bmatrix}_{Q \times L}^{\mathrm{T}} = \begin{bmatrix} \boldsymbol{h}(x_{1}) \cdot \boldsymbol{h}(x_{1}) & \cdots & \boldsymbol{h}(x_{1}) \cdot \boldsymbol{h}(x_{L}) \\ \vdots \\ \boldsymbol{h}(x_{1}) \cdot \boldsymbol{h}(x_{1}) & \cdots & \boldsymbol{h}(x_{1}) \cdot \boldsymbol{h}(x_{L}) \end{bmatrix}$$
(8)  
$$\begin{bmatrix} \boldsymbol{h}(x_{1}) \cdot \boldsymbol{h}(x_{1}) & \cdots & \boldsymbol{h}(x_{1}) \cdot \boldsymbol{h}(x_{L}) \\ \vdots \\ \boldsymbol{h}(x_{L}) \cdot \boldsymbol{h}(x_{1}) & \cdots & \boldsymbol{h}(x_{L}) \cdot \boldsymbol{h}(x_{L}) \end{bmatrix}$$

式中 $h(x_{\iota}) \cdot h(x_{\iota}) \neq h(x)$ 的内积形式。可构造核函数来代替 $H^{T}H$ ,即

$$\boldsymbol{\Omega}_{\text{ELM}}(i,j) = \boldsymbol{h}(x_i) \cdot \boldsymbol{h}(x_j) = \boldsymbol{K}(x_i, x_j)$$
(9)

$$\boldsymbol{H}\boldsymbol{H}^{\mathrm{T}} = \boldsymbol{\Omega}_{\mathrm{ELM}} = \begin{bmatrix} \boldsymbol{K}(x_{1}, x_{1}) & \cdots & \boldsymbol{K}(x_{1}, x_{Q}) \\ \cdots & \cdots & \cdots \\ \boldsymbol{K}(x_{Q}, x_{1}) & \cdots & \boldsymbol{K}(x_{Q}, x_{Q}) \end{bmatrix}$$
(10)  
$$\boldsymbol{h}(x) \boldsymbol{H}^{\mathrm{T}} = \begin{bmatrix} \boldsymbol{K}(x, x_{1}) \\ \vdots \\ \boldsymbol{K}(x, x_{N}) \end{bmatrix}$$
(11)

将惩罚系数 C 加入式(7)中,使 KELM 具有更好的稳定性和泛化性,计算得到权值向量。

$$\boldsymbol{\beta}^* = \boldsymbol{H}^{\mathrm{T}} \left( \boldsymbol{H}^{\mathrm{T}} \boldsymbol{H} + \frac{\boldsymbol{I}}{\boldsymbol{C}} \right)^{-1} \boldsymbol{T}$$
 (12)

根据
$$f(x) = h(x)H^{\mathsf{T}}\left(HH^{\mathsf{T}} + \frac{I}{C}\right)^{-1}T$$
,核极限学习

机的解写为

$$f(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^{-1} \left( \Omega_{\text{ELM}} + \frac{I}{C} \right)^{-1} T \qquad (13)$$

KELM的模型结构如图1所示,*K*(*u*, *v*)代表了核函数。核参数σ和惩罚系数C对KELM算法性能会 有影响,σ影响核函数的作用范围,C影响模型的稳 定性<sup>[29]</sup>。



Fig. 1 KELM structure diagram

# 2.2 粒子群核极限学习机

粒子群算法(PSO)是一种常用的群智仿生优化 算法,具有收敛速度快、全局寻优能力强和参数设置 少等优点<sup>[30]</sup>。本文通过PSO算法对KELM的σ和C 进行寻优。

$$v_{i}(t+1) = w \cdot v_{i}(t) + c_{1}R_{1}[P_{\text{best},i} - p_{i}(t)] + c_{2}R_{2}[G_{\text{best}} - p_{i}(t)]$$
(14)

$$p_i(t+1) = p_i(t) + v_i(t+1)$$
(15)

式中 $p_i(t)$ 和 $v_i(t)$ 分别为粒子i第t次迭代的位置 和速度, $P_{\text{best},i}$ 为粒子i的单个历史最优解, $G_{\text{best}}$ 为种群 历史最优解,w为惯性权重, $c_1$ 和 $c_2$ 为加速因子, $R_1$ 和  $R_2$ 为0~1之间的随机数,t为迭代次数。

搜索空间的维数与KELM的参数相对应,粒子的 位置表示参数值,并将测试精度作为粒子群算法的 适应度函数。粒子群核极限学习机(PSO-KELM)的 具体步骤如下:

第1步:初始化。迭代次数和总体大小设置为50 和50,随机生成粒子种群。种群当中的每一个粒子  $P_i$ 由一组 $\sigma$ 和C组成,即 $P_i = (\sigma_i, C_i)$ 。

第2步:粒子适应度函数值的计算。适应度函数

М

值为辨识模型输出值与实际输出值的均方根误差, PSO的目标函数即为最小化适应度函数。

inimize: 
$$f_{\text{fitness}}(L_i) = E_{\text{RMSE}}(y, y_d) =$$

$$\sqrt{\frac{1}{N} \sum_{j=1}^{N} \left[ y(j) - y_d(j) \right]^2}$$
(16)

式中y(j)为辨识模型的输出值, $y_{d}(j)$ 为实际输出信。

第3步:更新种群历史最好位置*G*<sub>best</sub>和粒子历史 最好位置*P*<sub>best,i</sub>,再根据式(14)和式(15)更新每一个 粒子的速度和位置。

第4步:检查终止条件。如果达到所需的适应值 或最大迭代次数,请转到第5步,否则返回第2步。

第5步:得到适应值最小的KELM最优参数。

这样即可得到适用于发动机加速过程的 KELM 模型的  $\sigma$  和 C,再利用优化后的 KELM 对加速过程进行回归辨识。

### 2.3 涡扇发动机加速过程模型的建立

本文对混合排气双轴涡扇发动机的加速过程进 行辨识,该型发动机包含进气道、风扇、压气机、燃烧 室、低压涡轮、高压涡轮、外涵道、加力燃烧室和尾喷 口9大部件,如图2所示,发动机截面如表1所示。

台架测量的涡扇发动机输入参数、主要截面参数和性能参数可以简化为一个函数关系表达式,即

 $\left[T_{5}, N_{1}, N_{h}, F\right]^{\mathrm{T}} = f_{\mathrm{en}}\left(H, Ma, W_{\mathrm{fb}}, A_{8}, \alpha_{\mathrm{e}}, \alpha_{\mathrm{f}}\right) \quad (17)$ 

式中 $f_{en}$ 代表了真实涡扇发动机输入输出的函数 关系, $T_5$ 为低压涡轮出口燃气总温, $N_1$ 为低压转子转 速, $N_h$ 为高压转子转速,F为发动机推力,H为高度, Ma为马赫数, $W_h$ 为主燃烧室燃油消耗量, $\alpha_r$ 为风扇 进口导流叶片角, $\alpha_e$ 为压气机进口导流叶片角和 $A_8$ 为喷口临界截面积。

发动机加速过程是指发动机迅速从低工作状态 过渡到高工作状态的过程,通过迅速控制 $W_{0}, \alpha_{r}, \alpha_{r}$ 

Table 1	Engine reference stations		
Station	Location		
1	Inlet entry		
2	Fan entry		
22	Fan exit		
13	Bypass entry		
25	Compressor entry		
3	Burner entry		
4	High-pressure turbine entry		
42	High-pressure turbine exit		
5	Low-pressure turbine exit		
6	Mixer entry		
65	Mixer exit		
7	Afterburner exit		
8	Exhaust nozzle throat		
9	Exhaust nozzle exit		

和A<sub>s</sub>使发动机截面参数和性能参数快速变化。其主要工作状态参数为N<sub>1</sub>,N<sub>h</sub>和T<sub>5</sub>,输入参数以及发动机前一时刻的工作状态都会影响发动机当前时刻的工作状态<sup>[31]</sup>。

因此,发动机加速过程模型的输入参数包括当前的和过去的W<sub>h</sub>,A<sub>s</sub>,α<sub>r</sub>和α<sub>c</sub>以及N<sub>1</sub>,N<sub>h</sub>和T<sub>5</sub>的过去 值;输出参数包括N<sub>1</sub>,N<sub>h</sub>和T<sub>5</sub>的当前值。不同环境下 的发动机加速性能有所不同,在训练数据集中加入 不同温度和马赫数的加速过程数据,便可对发动机 工作环境进行泛化,获得不同环境下的加速性能。 同时,在长时间使用过程中发动机性能会逐渐退化, 从而导致辨识模型输出与发动机实际输出误差逐渐 加大。从发动机长时间使用数据中选取具有代表性 时间节点的加速数据并将其加入训练数据集,便可 获得加速过程自适应辨识模型。由于本次台架试车 环境温度和马赫数变化不充分,不将其作为模型的 输入参数。发动机加速过程模型如下



Fig. 2 Cross-section schematic of turbofan engine

$$\boldsymbol{y} = f_{ac}(\boldsymbol{x}) \begin{cases} \boldsymbol{x} = [W_{fb}(k), W_{fb}(k-1), \cdots, W_{fb}(k-l_{1}); \\ A_{8}(k), A_{8}(k-1), \cdots, A_{8}(k-l_{2}); \\ \alpha_{f}(k), \alpha_{f}(k-1), \cdots, \alpha_{f}(k-l_{3}); \\ \alpha_{c}(k), \alpha_{c}(k-1), \cdots, \alpha_{c}(k-l_{4}); \\ N_{1}(k-1), \cdots, N_{1}(k-l_{5}); \\ N_{h}(k-1), \cdots, N_{h}(k-l_{6}); \\ T_{5}(k-1), \cdots, T_{5}(k-l_{7})] \\ \boldsymbol{y} = [N_{1}(k), N_{h}(k), T_{5}(k)]^{\mathrm{T}} \end{cases}$$
(18)

式中 $f_{ac}$ 为KELM需要辨识的发动机加速过程模型; $l_1$ , $l_2$ , $l_3$ 和 $l_4$ 为输入参数的延迟; $l_5$ , $l_6$ 和 $l_7$ 为输出参数的延迟,根据发动机的动态惯性因素将其均设置为 $2^{[32]}$ 。

#### 2.4 基于 PSO-KELM 的加速模型辨识方法

基于 KELM 辨识加速模型的思想为:针对非线性 加速模型  $y = f_{ac}(x)$  和 N 个训练样本 $(x_i, y_i)$ ,求得函数  $f_{KELM}$ ,它使得由实测值组成的目标向量 y 和 KELM 输 出量  $\tilde{y} = f_{KELM}(x)$ 的均方根误差最小。由于 KELM 为 多输入多输出结构,因此对于多输出结构的辨识对 象仅需建立一个模型。

采用 KELM 进行模型辨识时,首先利用 PSO 算法 对σ和 C进行寻优,寻优的目标即为最小化适应度函数。优化完成后,KELM 中建立的模型就能以较高精 度逼近 N 个训练样本,其具体流程如图 3 所示。

第1步:根据加速过程原理,建立涡扇发动机非 线性加速模型,模型主要包含输入量、输出量和它们 之间的函数关系。

第2步:选取涡扇发动机加速过程试车数据,将 其划分为模型辨识的训练和测试数据集,并对数据 集进行归一化处理。

第3步:设置 PSO 算法的基本参数,包括最大迭 代次数和种群粒子数量,采用 PSO 算法对 KELM 的 σ 和 C进行寻优。

第4步:基于训练数据集,采用经PSO优化后的



Fig. 3 Flow chart of acceleration model based on PSO-KELM

KELM 对已建立的涡扇发动机加速模型进行回归辨识。

第5步:采用测试数据集对基于 PSO-KELM 方法 建立的加速过程辨识模型进行验证。

## 3 辨识结果分析

为了验证该方法的有效性,建立了基于 PSO-KELM 方法的涡扇发动机加速过程辨识模型,并通过 台架试验数据进行了验证。采用留一交叉验证 (LOO-CV)方法对该方法的性能进行评价,以减少数 据人为分组带来的误差。最后,将该方法与 BP 神经 网络辨识方法和 PSO-SVR辨识方法进行了比较。

#### 3.1 模型辨识数据的选取与处理

本文采用的数据来自涡扇发动机完整地面台架 试车,试车数据采样周期为50ms。从中选取*N*<sub>h</sub>从设 计点的32%加速到94%的四次类似加速过程。

四组测量时间序列数据分别为 MD1, MD2, MD3 和 MD4, 如表 2 所示。从中可以看出, PLA 的起始点 和终止点位置存在微小差别, 这是由于人工操作导 致的, PLA 的位置不一样导致发动机四控制量的起始 点位置和终点位置也有所不同。

加速过程中四控制量变化趋势相似,但是其具

Data set Nun	N I CI.	PLA/(°) –	Operational range of the inputs				
	Number of data		$W_{\rm fb}/({ m kg/h})$	$\alpha_{\rm f}/(\circ)$	$\alpha_{\rm c}/(\circ)$	$A_8/(\circ)$	
MD1	160	[12.82,68.21]	[379.10,5180.12]	[4.81,97.80]	[4.90,106.32]	[56.60,110.91]	
MD2	160	[15.30,67.53]	[443.73,5092.64]	[4.88,97.63]	[4.93, 106.49]	[56.25,110.73]	
MD3	160	[14.10,67.35]	[379.10,5180.12]	[4.81,97.80]	[4.90,106.32]	[56.60,110.91]	
MD4	160	[13.85,67.23]	[441.52,5092.64]	[4.93,97.59]	[4.93, 106.50]	[56.28,110.73]	

 Table 2
 Experimental time series data sets

体数值存在差别,如图4所示。这是由于在相同的环 境条件和PLA控制下,发动机各控制变量将按照既 定控制规律变化,达到稳态点。而在实际加速控制 过程中,发动机控制量的大小和增加率存在微小差 别。由于不同变量变化范围差异较大,将试车数据 进行了归一化处理,用于模型训练和验证。

## 3.2 模型辨识结果

设置 PSO 算法的最大迭代次数为 50,种群粒子数量为 50。KELM 采用 RBF 核函数,利用 PSO 对 KELM 的 $\sigma$ 和 *C*进行寻优,  $l_1$ ,  $l_2$ , …,  $l_7$ 设为 2。利用训练样本建立涡扇发动机的加速过程辨识模型,如表 3 所示。

Table 3 Optimization results

Model	Training sample	Testing sample	σ	С
M 1	MD2, MD3, MD4	MD1	731.61	0.34
M2	MD1, MD3, MD4	MD2	801.78	0.51
M3	MD1, MD2, MD4	MD3	621.30	1.94
M4	MD1, MD2, MD3	MD4	775.45	0.29

将测试样本输入模型,计算出相应的输出,并将 模型输出与实测数据进行比较,验证 KELM 加速模型 的有效性。以模型 M1 为例,选取 MD2, MD3 和 MD4 作为训练样本集,建立基于 PSO-KELM 算法的涡扇 发动机加速过程辨识模型。将 MD1 作为验证样本输 入到 KELM 模型中得到对应的输出,通过模型输出值 和试车数据的对比来验证加速过程模型的效果。从 第 3 帧开始进行预测仿真,一共预估 158 帧。KELM 模型输出参数 N<sub>1</sub>, N<sub>h</sub>和 T<sub>5</sub> 与实际测量值对比如图 5 所 示。从中可看出,输出参数的辨识结果都良好地逼 近了实测数据。N<sub>1</sub>, N<sub>h</sub>和 T<sub>5</sub> 最大相对误差分别为 0.39%, 0.15% 和 1.30%, 说明本文提出 PSO-KELM 发 动机加速模型建立方法是可行的。

采用四组试验数据进行留一交叉验证,可得各 模型输出参数与实测数据的最大相对误差如图6所 示。由图可得,不同训练样本的模型输出参数与实测 数据的最大相对误差均未超过1.84%。N<sub>1</sub>,N<sub>h</sub>和T<sub>5</sub>的 最大相对误差均值分别为1.013%,0.355%和1.055%, 表明本文建立的涡扇发动机加速模型精度满足实际 应用的精度要求。

#### 3.3 不同方法辨识效果对比

为了更好地说明基于 PSO-KELM 的涡扇发动机 加速过程辨识方法的优越性,利用相同的训练与验 证样本集,对比 PSO-KELM、BP 神经网络和 PSO-SVR三种方法的辨识效果。

BP神经网络使用 MATLAB R2014a 中的工具包, 采用三层 BP 网络和常用的 Levenberg-Marquardt 算法,隐含层结点数设置为 10。SVR 的核函数选取



Fig. 4 Four control variables of MD1 and MD2







RBF核函数,采用PSO算法对其核函数参数σ和正则 化参数γ进行优化。采用三种方法对某型涡扇发动 机加速过程进行辨识,模型输出参数与实测数据的 相对误差对比如表4所示,图7对比了三种算法最大 相对误差的均值。从表4和图7可看出,PSO-SVR的 平均相对误差低于BP神经网络,PSO-KELM的平均 相对误差低于PSO-SVR。主要原因是KELM和SVR 都采用核映射,提高了非线性拟合能力,有效地避免 了BP神经网络在训练时容易陷入局部极值的问题。

表5为三种不同算法的平均训练时间和平均测 试时间对比。从中可看出,BP神经网络的平均训练 速度最快,这是由于其它两种算法采用PSO进行优化 的原因;SVR的训练时间最长,这是由于SVR需要针 对每一个输出参数训练一个子SVR,3个输出参数需 要设计3个子SVR。KELM的平均测试时间快于BP 神经网络和SVR算法,这是由于KELM具有ELM网

			-			
Method	Outputs	Maximum relative error/%			A 101	
		MD1	MD2	MD3	MD4	Average/%
BP	$N_1$	2.36	3.11	1.98	3.63	2.770
	$N_{\rm h}$	0.51	0.84	0.63	0.86	0.710
	$T_5$	2.55	1.37	1.58	2.92	2.105
PSO-SVR	$N_1$	1.74	1.60	1.94	3.90	2.295
	$N_{\rm h}$	0.61	0.58	0.60	0.71	0.625
	$T_5$	2.22	0.85	1.44	1.47	1.495
PSO-KELM	$N_1$	0.39	0.74	1.08	1.84	1.013
	$N_{\rm h}$	0.15	0.35	0.42	0.50	0.355
	$T_5$	1.30	0.50	1.07	1.43	1.055

Table 4 Precision comparison of different methods



Fig. 7 Average values of maximum relative errors

络结构简单和复杂度低的特点。三种方法的仿真环 境相同,都采用:Windows 7操作系统,CPU采用 Intel (R) Core(TM)i5-2410,其主频为2.30GHz,4G内存。

Table 5	Comparison	of time	consumption

Method	Average training time/s	Average testing time/ms
BP	2.35	0.30
PSO-SVR	225.76	0.41
PSO-KELM	140.87	0.04

与 BP 神经网络和 SVR 相比,本文提出的方法不 仅有更高的辨识精度,而且计算时间较短,满足发动 机状态监控和性能优化控制的要求。加速过程辨识 模型可用于控制规律优化设计中,在满足加速过程 诸多限制条件下,基于辨识模型对燃油流量、喷口面 积、风扇和压气机导叶角度进行寻优控制,使发动机 获得更优的加速性能。

# 4 结 论

通过本文研究,得到结论如下:

(1)辨识模型输出参数低压转子转速、高压转子转速和低压涡轮出口燃气总温都较好地贴近了试车数据,说明本文提出基于 PSO-KELM 的涡扇发动机

加速过程模型辨识方法可行。

(2)不同验证样本求得的低压转子转速、高压转 子转速和低压涡轮出口燃气总温的最大相对误差均 值分别为1.013%,0.355%和1.055%,表明基于PSO-KELM方法辨识得到的涡扇发动机加速过程模型精 度满足实际应用需求。

(3)与 BP 神经网络和 PSO-SVR 相比,本文采用 PSO-KELM 方法辨识得到的涡扇发动机加速模型精 度更高。该方法平均计算时间为 0.04ms,满足发动机 状态监控和性能优化控制的实时性要求。

**致** 谢:感谢国家自然科学基金、山东省自然科学基金、 泰山学者建设工程专项经费的资助。

# 参考文献

- [1] Liu Y, Litt J S, Guo T H. Design and Demonstration of Emergency Control Modes for Enhanced Engine Performance [C]. San Jose: AIAA/ASME/SAE/ASEE Joint Propulsion Conference, 2013.
- [2] 陈玉春,刘振德,袁 宁,等.一种涡轮发动机加速 控制规律设计的新方法[J].航空学报,2008,29(2).
- [3] Litt J S, Frederick D K, Guo T H. The Case for Intelligent Propulsion Control for Fast Engine Response [R]. NASA/TM 2009-215668.
- [4] Zheng Q, Zhang H. A Global Optimization Control for Turbo-Fan Engine Acceleration Schedule Design [J].
   Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2018, 232 (2): 308-316.
- [5] Garg S. Propulsion Controls and Diagnostics Research in Support of NASA Aeronautics Research Mission Programs
   [C]. Nashville: AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit, 2011.
- [6] Csank J, Litt J S, Guo T H. Control Design for a Generic Commercial Aircraft Engine [C]. Nashville: AIAA/ASME/ SAE/ASEE Joint Propulsion Conference & Exhibit, 2010.
- [7] Garg S. Propulsion Controls and Health Management Research at NASA Glenn Research Center [R]. NASA/TM 2002-211590.
- [8] Zheng Q, Miao L, Zhang H, et al. On-Board Real-Time Optimization Control for Turbofan Engine Thrust under Flight Emergency Condition [J]. Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, 2017, 231(11): 554-566.
- [9] Mcglynn G E, Litt J S, Lemon K A, et al. A Risk Management Architecture for Emergency Integrated Aircraft Control[R]. NASA/TM, 2011-217143.
- [10] Sun F, Miao L, Zhang H. A Study on the Installed Per-

formance Seeking Control for Aero-Propulsion under Supersonic State[J]. International Journal of Turbo & Jet-Engines, 2016, 33(4): 341-351.

- [11] Hussain S, Mokhtar M, Howe J M. Sensor Failure Detection, Identification, and Accommodation using Fully Connected Cascade Neural Network [J]. *IEEE Transactions* on Industrial Electronics, 2015, 62(3): 1683-1692.
- [12] Vloponi A, Simon D L. Enhanced Self Tuning On-Board Realtime Model (Estorm) for Aircraft Engine Performance Health Tracking[R]. NASA/CR 2008-215272.
- [13] Asgari H, Venturini M, Chen X Q, et al. Modeling and Simulation of the Transient Behavior of an Industrial Power Plant Gas Turbine[J]. Journal of Engineering for Gas Turbines and Power, 2014, 136(6).
- [14] Asgari H, Jegarkandi M F, Chen X Q, et al. Design of Conventional and Neural Network Based Controllers for a Single-Shaft Gas Turbine [J]. Aircraft Engineering and Aerospace Technology, 2015, 89(1): 52-65.
- [15] Asgari H, Chen X Q, Menhaj M B, et al. Artificial Neural Network-Based System Identification for a Single-Shaft Gas Turbine [J]. Journal of Engineering for Gas Turbines and Power, 2013, 135(9).
- [16] 尉询楷,李应红,王剑影,等.基于支持向量机的航 空发动机辨识模型[J].航空动力学报,2004,19(5): 684-688.
- [17] 王海涛,谢寿生,武 卫,等.基于稀疏最小二乘支 持向量机的航空发动机动态过程辨识[J].航空动力 学报,2010,25(9).
- [18] 潘鹏飞,马明明,许艳芝.飞行试验数据驱动的涡扇 发动机模型辨识[J]. 燃气涡轮试验与研究,2016,29 (6):21-25.
- [19] Zheng Q, Zhang H, Li Y, et al. Aero-Engine On-Board Dynamic Adaptive MGD Neural Network Model Within a Large Flight Envelope[J]. IEEE Access, 2018, 6: 45755 -45761.
- [20] 赵姝帆,李本威,宋汉强,等.基于K-均值聚类与粒子群核极限学习机的推力估计器设计[J].推进技术,2019,40(2):259-266. (ZHAO Shu-fan, LI Ben-wei,SONG Han-qiang, et al. Thrust Estimator Design Based on K-Means Clustering and Particle Swarm Optimization Kernel Extreme Learning Machine[J]. Journal of Propulsion Technology, 2019, 40(2):259-266.)

- [21] Gu B, Sheng V S, Wang Z, et al. Incremental Learning for v-Support Vector Regression [J]. Neural Networks, 2015, 67: 140-150.
- [22] Huang G B, Zhu Q Y, Siew C K. Extreme Learning Machine: Theory and Applications [J]. Neurocomputing, 2006, 70(3): 489-501.
- [23] Deng C W, Huang G B, Xu J, et al. Extreme Learning Machines: New Trends and Applications [J]. Science China Information Sciences, 2015, 58(2): 1-16.
- [24] Pei F, Chen X Z, Zhu Y L, et al. Transformer Fault Diagnosis Based on Particle Swarm Optimization and Kernel-Based Extreme Learning Machine[J]. Computer Engineering and Design, 2015, 36(5): 1327-1331.
- [25] Huang G B, Bai Z, Kasun L L C, et al. Local Receptive Fields Based Extreme Learning Machine [J]. IEEE Computational Intelligence Magazine, 2015, 10(2): 18-29.
- [26] Huang G B, Wang D H, Lan Y. Extreme Learning Machines: A Survey [J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2): 107-122.
- [27] Li K, Lei S, Wu J J, et al. A Rolling Bearing Fault Diagnosis Method Based on Variational Mode Decomposition and an Improved Kernel Extreme Learning Machine [J]. *Applied Science*, 2017, 7(10).
- [28] Chao P, Jia Y, Shukai D, et al. Enhancing Electronic Nose Performance Based on a Novel QPSO-KELM Model
   [J]. Sensors, 2016, 16(4): 520-535.
- [29] Sun H, Yang J, Wang L. Resistance Spot Welding Quality Identification with Particle Swarm Optimization and a Kernel Extreme Learning Machine Model [J]. International Journal of Advanced Manufacturing Technology, 2016, 91(5): 1-9.
- [30] Lu H, Du B, Liu J, et al. A Kernel Extreme Learning Machine Algorithm Based on Improved Particle Swam Optimization[J]. Memetic Computing, 2016, 9(2): 1-8.
- [31] Zangmolk B R, Khaledi H. Development of an Interactive Code for Design and Off-Design Performance Evaluation of Gas Turbines [C]. Orlando: ASME Turbo Expo 2009: Power for Land, Sea, and Air, 2009.
- [32] Asgari H, Chen X Q, Morini M, et al. NARX Models for Simulation of the Start-Up Operation of a Single-Shaft Gas Turbine [J]. Applied Thermal Engineering, 2015, 93: 368-376.

(编辑:张 贺)