

# 基于改进 QPSO-SVR 的航空发动机排气温度预测<sup>\*</sup>

皮 骏, 黄江博, 黄 磊, 高树伟, 刘光才

(中国民航大学通用航空学院 天津, 300300)

**摘要** 为了减少航空发动机排气温度的随机性对飞机安全飞行的影响,提出了改进量子粒子群优化支持向量回归机(improved quantum behaved particle swarm optimization support vector regression,简称 IQPSO-SVR)的航空发动机排气温度预测模型,以 A319 飞机的 V2500 发动机为例,选取状态监控所监测的性能参数数据作为训练样本和测试样本,其中航空发动机的高压转子转速、低压转子转速、燃油流量、高压压气机出口温度以及时间  $t$  作为模型的输入,以航空发动机排气温度作为模型的输出,在不同组训练样本的条件下,对改进量子粒子群优化过的支持向量回归基模型进行测试,并与量子粒子群优化支持向量回归机(quantum behaved particle swarm optimization support vector regression,简称 QPSO-SVR)、支持向量回归机(support vector regression,简称 SVR)进行对比。研究结果表明,改进量子粒子群优化支持向量回归机在航空发动机排气温度预测中相较其他两方法准确性更高,同时,在添加噪声的情况下,IQPSO-SVR 也具有较好的预测能力。

**关键词** 航空发动机;改进量子粒子群;支持向量回归机;排气温度;预测

**中图分类号** TH17; V231.1

## 引 言

当航空发动机的排气温度超过一定的值时,将严重影响航空发动机的正常工作和飞机的安全飞行,因此对其进行准确的预测,有助于判别发动机的性能状态,同时为预防和排除故障提供了充分的决策时间<sup>[1-4]</sup>。

由于航空发动机是一个复杂的非线性系统,排气温度又受各种因素影响,所以航空发动机的排气温度具有多变性<sup>[5]</sup>,并且各种预测算法的本身参数多,初始值设定不确定,使之预测难度加大。国内外许多学者对其进行了研究,Ilbas 等<sup>[6]</sup>利用人工神经网络对涡轮废气进行了估算。Flores 等<sup>[7]</sup>把神经网络用于时间序列预测<sup>[7]</sup>。Yilmaz<sup>[8]</sup>利用排气温度与其他发动机性能参数之间的关系对排气温度进行了评估。宋云雪等<sup>[9]</sup>通过多元线性回归对航空发动机排气温度进行预测。由于航空发动机的复杂性,许多参数难以与排气温度成严格意义上的线性相关。史永胜等<sup>[10]</sup>在多元线性的基础上又引入偏最小二

乘方法对排气温度进行预测。王强等<sup>[11]</sup>利用灰色理论对航空发动机状态监控的实时数据进行预测分析。丁刚等<sup>[12]</sup>把 BP 神经网络、过程神经网络以及自适应神经网络引入排气温度预测。于广滨等<sup>[13]</sup>把支持过程向量机引入航空发动机排气温度预测。但是在支持向量预测过程中,其结果的好坏直接由核函数的参数与惩罚系数的选取而决定,如果初始参数选取不当,则预测结果将不会很理想。

针对支持向量机初始参数值选取问题,Zhou 等<sup>[14]</sup>提出运用量子粒子群(quantum behaved particle swarm optimization,简称 QPSO)算法对支持向量机参数进行寻优,以量子粒子群的最优解作为支持向量机的初始参数,用以提高支持向量机的预测精度,但是由于量子粒子群算法与标准 PSO 算法一样,都存在陷入局部最优、以及训练后期的早熟问题,寻优效果并不明显。因此,结合黄璇等<sup>[15]</sup>提出的改进粒子群算法的思想,将对量子粒子群算法进行改进,用以搜索最优支持向量回归机的核函数参数及惩罚因子,并将优化过的支持向量回归机用于航空发动机排气温度预测。

<sup>\*</sup> 国家自然科学基金委员会与中国民用航空局联合资助项目(U1633101);中央高效基本科研业务费中国民航大学专项资助项目(3122013H001)

收稿日期:2017-04-01;修回日期:2017-05-31

## 1 支持向量回归基

设训练样本为  $\{(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)\} \subseteq R^n \times R$  通过某一非线性函数  $K(x)$  映射到大于  $n$  维的高维空间中,  $\omega^T$  为各个空间对输出影响的权值, 则回归函数可以构建为

$$f(x) = \omega^T K(x_i) + b \quad (1)$$

假设所有的训练样本可在精度为  $\epsilon$  条件下考虑到误差进行拟合, 误差以引入松弛变量  $\xi_i$  与  $\xi_i^*$  表示

$$\begin{cases} y_i - \omega K(x_i) - b \leq \epsilon + \xi_i \\ \omega K(x_i) - y_i + b \geq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \quad (i=1, \dots, k) \end{cases} \quad (2)$$

则回归估计问题可转化为在约束条件(2)下的最小误差问题

$$\min \frac{1}{2} \omega^2 + C \sum_{i=1}^k (\xi_i + \xi_i^*) \quad (3)$$

其中:  $C$  为惩罚因子。

引入 Lagrange 函数, 即

$$\begin{aligned} \varphi(\omega, \xi, \xi^*; \alpha, \alpha^*, \gamma, \gamma^*) = & \frac{1}{2} |\omega|^2 + C \left( \sum_{i=1}^k \xi_i + \sum_{i=1}^k \xi_i^* \right) - \sum_{i=1}^k \alpha_i [(\omega x_i) + b - y_i + \epsilon + \xi_i] - \sum_{i=1}^k (\gamma_i \xi_i + \gamma_i^* \xi_i^*) - \sum_{i=1}^k \alpha_i^* [y_i - (\omega \cdot x_i) - b + \epsilon + \xi_i^*] \end{aligned}$$

根据 Wolfe 对偶定理, 对其再进行二次优化, 转化为对偶问题, 即

$$\begin{aligned} \min \left[ \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) K(x_i, x_j) \right] + \\ \epsilon \sum_{i=1}^k (\alpha_i^* + \alpha_i) - \sum_{i=1}^n y_i (\alpha_i^* - \alpha_i) \end{aligned} \quad (4)$$

约束条件为

$$\text{s. t. } \begin{cases} \sum_{i=1}^k \alpha_i = \sum_{i=1}^k \alpha_i^* \\ 0 \leq \alpha_i, \alpha_i^* \leq C \quad (i=1, 2, \dots, k) \end{cases}$$

其中:  $K(x_i, y_i)$  为核函数。

求解上述最优模型, 可得回归函数为

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (5)$$

核函数一般有 4 大类:

- 多项式函数  $k(x, x_i) = (x \cdot x_i + 1)^d$ ;
- 径向基函数  $K(x, x_i) = \exp\left(-\frac{x - x_i}{\sigma^2}\right)$ ;
- 多层感知器函数  $K(x, x_i) = \tanh[\kappa(x \cdot x_i) + \nu]$ ;
- B 样条函数  $K(x, x_i) = B_{2p+1}(x - x_i)$ 。

其中径向基(radial basis function, 简称 RBF)核函数局部性较强, 对于特定范围内的数据具有较强的插值能力。航空发动机排气温度预测是建立在部分历史数据的基础上, 这些数据在特定的范围内波动, 并且航空发动机排气温度预测需要描述数据的变化趋势以及接下来短时间内的预测值, 因此径向基核函数相较其他核函数更适合于航空发动机排气温度的预测。

利用 SVR 对航空发动机排气温度进行预测时, 则需对式(3)中的  $C$  以及 RBF 核函数的参数  $\sigma$  两个参数利用改进量子粒子群优化算法进行寻优, 使预测结果更理想。

## 2 改进量子群优化算法

### 2.1 量子粒子群优化算法

标准的粒子群优化算法无法百分之百保证搜索到全局最优解, 全局搜索能力不完美, 在此基础上, Sun 等<sup>[16]</sup>提出了量子粒子群优化算法(QPSO), 在量子力学原理中, 速度则毫无意义, 粒子的位置只根据波函数来确定。因此与常规的粒子群相比, QPSO 可控制的参数少, 具有算法简单, 搜索速度快, 寻优能力强等特点。

假设在  $D$  维搜索空间中, 粒子群规模为  $N$ , 粒子  $i$  经过  $t$  次更新后, 其位置在第  $j$  维空间势能最小的位置为  $x_{ij}(k)$ 。

$$x_{ij}(t) = \varphi_{ij}(t) P_{ij}(t) + [1 - \varphi_{ij}(t)] P_{kj}(t) \quad (6)$$

其中:  $i \in [1, N], j \in [1, D]$ ;  $\varphi_{ij}(t)$  为均匀分布在  $[0, 1]$  的随机数;  $P_i$  为个体最优;  $P_g$  为全局最优。

利用蒙特卡洛的方法, 对其进行计算粒子  $i$  在迭代  $k+1$  次后在  $j$  维空间所处的位置为

$$x_{ij}(t+1) = x_{ij}(t) \pm \beta | P_{mbest} - x_{ij}(t) | \ln[1/\varphi_{ij}(t)] \quad (7)$$

其中:  $\beta$  为压缩-扩展系数,  $P_{mbest}$  为平均最优位置。

$P_{mbest}$  的表达式为

$$P_{mbest} = \frac{1}{N} \sum_{i=1}^N P_i = \left( \frac{1}{N} \sum_{i=1}^N P_{i1}, \frac{1}{N} \sum_{i=1}^N P_{i2}, \dots, \frac{1}{N} \sum_{i=1}^N P_{iD} \right) \quad (8)$$

则更新的方程式如下

$$\begin{cases} P_i(t+1) = \begin{cases} x_i(t+1) & (f(x_i(t+1)) < f(P_i(t))) \\ P_i(t) & (f(x_i(t+1)) \geq f(P_i(t))) \end{cases} \\ P_g(t+1) = \arg \{ \min_{1 \leq i \leq N} [f(P_i(t))] \} \end{cases} \quad (9)$$

其中:  $f(·)$  为适应度函数。

## 2.2 改进量子粒子群

量子粒子群与常规的 PSO 算法一样,也存在过早的收敛问题,并且在迭代次数达到一定值后,其多样性也会减少,使得局部寻优能力变差,因此在量子粒子群的基础上对其进行粒子聚集程度判定、动态参数以及动态压缩-扩展系数操作。

### 2.2.1 算法改进判断准则

针对粒子过早收敛问题,引入概率统计中方差的含义,对粒子过早收敛进行判定,由于粒子迭代次数到达后期后,其适应度值都趋于全局最优值,因此对粒子适应度方差进行计算,判定粒子是否达到过早收敛

$$s^2 = \frac{1}{N} \sum_{i=1}^N (f_i - f_{\text{avg}})^2 \quad (10)$$

其中:  $f_i$  为粒子  $i$  的适应度值;  $f_{\text{avg}}$  为粒子的平均适应度值;  $N$  为种群规模。

### 2.2.2 进化因子

随着迭代次数的增加,粒子的适应度值越来越接近,则粒子适应度值方差也会越来越小,当粒子的适应度值小于某一特定的值时,则认为迭代进入后期的过早收敛阶段。为了避免这一阶段,在此条件下,对粒子平均最优位置引入进化因子,表达式为

$$\eta_t = 1 + c_1 [C_t(0, 1) + c_2 N_t(0, 1)] \quad (11)$$

其中:  $\eta_t$  为粒子最优平均值的进化因子;  $C_t(0, 1)$  为以柯西分布在  $[0, 1]$  产生的随机数;  $N_t(0, 1)$  为以高斯分布在  $[0, 1]$  产生的随机数;  $c_1, c_2$  为扰动因子。

进行动态操作如下

$$\begin{cases} c_1 = c_{1\min} + (c_{1\max} - c_{1\min})t/t_{\max} \\ c_2 = c_{2\max} - (c_{2\max} - c_{2\min})t/t_{\max} \end{cases} \quad (12)$$

其中:  $c_{1\max}, c_{1\min}$  分别为  $c_1$  的最大值与最小值;  $c_{2\max}, c_{2\min}$  分别为  $c_2$  的最大值与最小值;  $t_{\max}$  为更新次数的最大值。

在添加进化因子后,粒子的平均最优位置  $P'_{\text{mbest}}$  为

$$P'_{\text{mbest}} = P_{\text{mbest}} \eta_t \quad (13)$$

### 2.2.3 动态压缩-扩展系数

压缩-扩展系数与标准粒子群中的惯性权值有着共同的作用,对于粒子的计算有着重要的作用,在此借鉴动态权值的思想,也对压缩-扩压系数进行动态调节,操作如下

$$\beta = \beta_{\min} + (\beta_{\max} - \beta_{\min}) \tan\left(\frac{t}{t_{\max}} \times \frac{\pi}{4}\right) \quad (14)$$

其中:  $\beta_{\max}$  与  $\beta_{\min}$  分别为  $\beta$  的最大值与最小值。

在迭代次数较少时,  $\beta$  与  $\beta_{\max}$  大小相近,确保了算法的全局搜索能力;随着迭代次数增大,  $\beta$  以非线性递减,确保了局部的搜索能力,因此灵活调整了局部搜索与全局搜索能力的动态平衡。

## 3 IQPSO-SVR 的航空发动机排气温度预测

现以 A319 飞机的一个飞行循环数据为例,其中飞行循环时长为 2 h,以 1 min 的时间间隔选取 80 组数据,由于数据较多则展示部分原始数据,如表 1 所示。同时以 IQPSO-SVR 建立航空发动机排气温度预测模型,首先需要进行相关性分析来确定入选模型的相关参数,然后建立参数与航空发动机排气温度关系模型,并根据参选模型中性能参数的作用大小对当前个体的状态进行分析和预测。利用 SPSS 软件,计算各个参数的 overall 等检验量的  $P$  值,选取小于 0.05 检验标准的性能参数分别为:低压压气机转速  $N_1$ 、高压压气机转速  $N_2$ 、发动机排气温度  $C_{\text{EGT}}$ 、燃油流量  $F_f$ 、高压压气机出口温度  $T_3$  以及时间  $t$ ,则建立预测模型为

$$C_{\text{EGT}} = f(t, N_1, N_2, F_f, T_3) \quad (15)$$

其中:  $f(·)$  为式(5)的回归函数。

表 1 原始数据

Tab. 1 Actual data

$t/\text{min}$	$C_{\text{EGT}}/\text{k}$	$F_f/10^3(\text{kg} \cdot \text{h}^{-1})$	$N_1/\%$	$N_2/\%$	$T_3/^\circ\text{C}$
1	630.1	1 369	83.4	94.8	452.3
2	629.4	1 448	81.8	94.8	451.9
⋮	⋮	⋮	⋮	⋮	⋮
79	639.3	1 200	83.87	94.2	445.8
80	709.1	2 212	78.9	96.5	496.9

### 3.1 归一化

航空发动机排气温度以及相关的性能参数在飞机飞行过程中波动幅度较大,同时为满足计算上的物理意义,则需在模型进行训练与预测之前对其进行如下归一化处理

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (16)$$

其中:  $x_{\max}, x_{\min}$  分别为输入样本  $x_i$  的最大值、最小值;  $x$  为归一化处理后得到的数值。

### 3.2 适应度函数

在对 SVR 的参数进行寻优时,在此以预测误差作为粒子群算法的寻优目标,则适应度函数为

$$F = \frac{1}{M} \sum_{i=1}^M |y_i - d_i| \quad (17)$$

其中:  $M$  为预测数量;  $y_i$  为 SVR 预测值;  $d_i$  为实际值。

### 3.3 预测模型评价标准

文中选取平均相对误差作为预测结果的评价标准,即

$$E_{\text{MAPE}} = \frac{1}{M} \sum_{i=1}^M \left| \frac{y_i - d_i}{d_i} \right|$$

其中:  $M$  为预测数量;  $y_i$  为 SVR 预测值;  $d_i$  为实际值; MAPE 为绝对百分比误差。

### 3.4 IQPSO-SVR 的预测流程图

利用改进的 QPSO 对 SVR 进行优化,并对航空发动机的排气温度进行预测,其预测流程如图 1 所示。

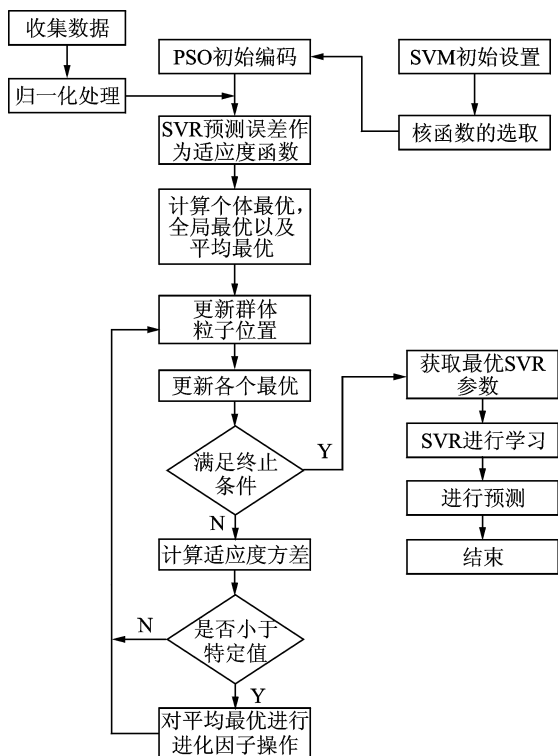


图 1 IQPSO-SVR 预测流程图

Fig. 1 IQPSO-SVR prediction flow chart

### 3.5 改进 QPSO-SVR 算法步骤

QAPSO-SVR 算法实现步骤如下:

1) 确定支持向量回归机的核函数、各个参数初始化;

2) 对于改进量子粒子群的初始值进行设置,包括:最大迭代次数、种群规模、空间维数以及参数初始化;

3) 构建 SVR 结构,以粒子代表  $c$  与  $g$ ,进行搜索;

4) 对群体中每个个体进行适应度评价,适应度值定义为:将预测的误差作为改进 QPSO 的适应度;

5) 根据适应度函数,计算适应度值,再根据适应度值更新个体最优位置和群体最优位置;

6) 在式(14)的基础上,对惯性权值进行动态调整,根据量子粒子群中的位置更新方式对其进行更新;

7) 以粒子适应度为标准,判断是否满足收敛条件或者是否达到最大进化次数,是则进入步骤 8,否则返回步骤 4;

8) 计算适应度方差,并与设定值比较,是则进入下一步,否则返回步骤 4;

9) 根据式(11)计算进化因子,并带入式(12)计算  $P_{\text{mbest}}$ ,并返回步骤 6;

10) 待 PSO 寻找最优解后,应用最优解作为支持向量回归机的初始值并对航空发动机的排气温度进行预测。

## 4 IQPSO-SVR 验证

### 4.1 参数设置

笔者运用 Matlab R2012a,编程实现 IQPSO-SVR 的航空发动机排气温度预测模型。模型训练中共选取 80 组数据,前 60 组作为训练样本,后 20 组作为验证集。原始数据需在归一化处理后注入 IQPSO-SVR 中。设置种群规模为 20 个,算法迭代进化次数为 200,  $c_1 = 2.05$ ,  $c_2 = 2.05$ ,  $V_{\text{max}} = 1$ ,  $V_{\text{min}} = -1$ ,  $\omega_{\text{max}} = 0.9$ ,  $\omega_{\text{min}} = 0.4$ 。在 SVR 学习过程中,都采用默认值,在 PSO-SVR 以及 IQPSO-SVR 学习过程中,  $c, \sigma$  作为粒子群寻优后最优解以外,其余值也为默认值。为验证 IQPSO-SVR 在航空发动机排气温度预测的有效性,同时另采用 PSO-SVR 与 SVR 来进行预测,与其对比。

### 4.2 仿真结果

经过全部训练集数据训练后的 3 种方法对全部测试数据集进行测试,图 2 为 3 种方法在训练 60 组时,EGT 的预测值与真实值对比,从图中可以看出 3 种模型对排气温度预测的变化趋势与真实值大致相同。图 3 为各个模型对  $C_{\text{EGT}}$  预测的绝对误差,图 2 与图 3 中横坐标为预测样本序列(无量纲)。从图中可以看出,3 种算法都能可以对  $C_{\text{EGT}}$  进行较好的预测,平均相对误差大致都在 10% 以内。3 种算

法对航空发动机排气温度预测的平均相对误差都小于 7.66%，其中 IQPSO-SVR 的预测误差要小于另外两种算法，QPSO-SVR 预测误差明显比 SVR 偏差小。但是由于粒子群的随机性，难免在预测中出现像图 3 中样本 4 那种预测误差大于未优化的 SVR，因此，在实际工程应用优化的 SVR 预测时，预测结果以 SVR 的预测结果为标准，误差大于标准值则选 SVR 的结果为优化结果。

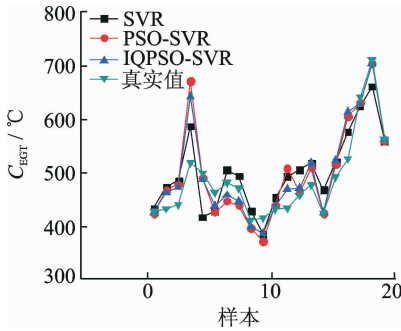


图 2 C<sub>EGT</sub> 预测值

Fig. 2 The C<sub>EGT</sub> predictive value




图 3 预测误差

Fig. 3 The errors predictive value

在实际航空发动机排气温度预测中，数据噪声往往不可避免，噪声强度的变化对航空发动机排气温度预测影响较大，为了研究 IQPSO-SVR 的抗噪声能力，在以上的基础上分别又在 3%，5% 的噪声强度下，运用 3 种模型分别对其进行排气温度预测，预测结果的平均绝对误差如表 2。

表 2 预测结果比较

Tab. 2 Comparison of forecast results %

噪声强度	E <sub>MAPE</sub>		
	SVR	PSO-SVR	IQPSO-SVR
0	7.66	6.74	5.69
3	11.02	9.82	9.46
5	15.36	11.16	10.13

从表 2 中可以看出，随着噪声强度的增加，IQPSO-SVR 和 SVR, QPSO-SVR 一样，绝对误差平均值随着噪声强度的增加而增加。噪声强度分别

在 0%，3%，5% 时，IQPSO-SVR 的航空发动机排气温度预测绝对误差平均值最小。因此可认为 IQPSO-SVR 相较 SVR 与 QPSO-SVR，预测准确度更高，抗噪能力更强。

### 5 结 论

1) SVR, QPSO-SVR, IQPSO-SVR 三种方法都可以对航空发动机的排气温度进行准确的预测，在不添加噪声的情况下，三者相对平均误差都小于 7.66%，其中 IQPSO-SVR 预测偏差最小。

2) 在各个噪声强度中，IQPSO-SVR 的预测偏差最小，因此其抗噪能力相较 SVR 与 QPSO-SVR 更强，SVR 的抗噪能力最差。

3) 为使 IQPSO-SVR 在航空发动机排气温度预测的误差更小，文中只对核函数参数以及惩罚因子进行了优化，并未对 SVR 的其他参数进行优化，因此 SVR 的预测准确度还有提升的空间。

### 参 考 文 献

[1] 付云骁, 贾利民, 秦勇, 等. 基于 LMD-CM-PCA 的滚动轴承故障诊断方法[J]. 振动、测试与诊断, 2017, 37(2): 249-255.  
Fu Yunxiao, Jia Limin, Qin Yong, et al. Roller bearing fault diagnosis method based on LMD-CM-PCA [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(2):249-255. (in Chinese)

[2] Samanta B, Al-Balushi K R, Al-Araimi S A. Bearing fault detection using artificial neural networks and support vector machines with genetic algorithm[J]. Soft Comput, 2006, 10: 264-271.

[3] 崔建国, 华娇娇, 董世良, 等. 基于 SK 与 LSSVM 的空气制冷机寿命趋势分析[J]. 振动、测试与诊断, 2016, 36(3):471-478.  
Cui Jianguo, Hua Jiaojiao, Dong Shiliang, et al. Life trend analysis of aircraft air refrigerator based on SK and LSSVM[J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(3):471-478. (in Chinese)

[4] Bengtsson M. Condition based maintenance system technology where is development heading? [C]// Proceedings of the 17th European Maintenance Congress. Barcelona Spain:[s. n.], 2004.

[5] 吕永乐, 郎荣玲, 路辉, 等. 航空发动机性能参数联合 RBFNN 和 FAR 预测[J]. 北京航空航天大学学报, 2010, 36(2):131-134.  
Lü Yongle, Lang Rongling, Lu Hui, et al. Prediction

- of aeroengines performance parameter combining RBF-PN and FAR [J]. Journal of Beijing University of Aeronautics and Astronautics, 2010, 36(2):131-134. (in Chinese)
- [6] Ilbas M, Turkmen M. Estimation of exhaust gas temperature using artificial neural network in turbofan engines[J]. Journal of Thermal Science and Technology, 2012, 32(2):11-18.
- [7] Flores J J, Graff M, Rodriguez H. Evaluative design of ARMA and ANN models for time series forecasting [J]. Renewable Energy, 2012, 44:225-230.
- [8] Yilmaz I. Evaluation of the relationship between exhaust gas temperature and operational parameters in CFM56-7Bengines[J]. Proceedings of the Institution of Mechanical Engineers, 2009, 223(4):433-440.
- [9] 宋云雪, 张科兴, 史永胜. 基于多元线性回归的航空发动机性能参数预测[J]. 航空动力学报, 2009, 24(2): 427-431.  
Song Yunxue, Zhang Kexing, Shi Yongsheng. Research on aeroengine performance parameters forecast based on multiple linear regression forecasting method [J]. Journal of Aerospace Power, 2009, 24(2):427-431. (in Chinese)
- [10] 史永胜, 李元正, 宋云雪. 小样本下基于偏最小二乘回归的航空发动机性能参数预测[J]. 飞机设计, 2012, 32(6): 47-51.  
Sui Yongsheng, Li Yuanzheng, Song Yunxue. Aeroengine performance parameter forecast based on partial least-squares regression method under condition of small samples[J]. Aircraft Design, 2012, 32(6):47-51. (in Chinese)
- [11] 王强, 戴晟晖. 灰色理论与时序模型的发动机状态监测分析[J]. 计算机工程与应用, 2009, 45(8):246-248.  
Wang Qiang, Dai Shenghui. Engine condition monitoring based on grey auto-regressive combination model [J]. Computer Engineering and Applications, 2009, 45(8): 246-248. (in Chinese)
- [12] 丁刚, 徐敏强, 侯立国. 基于过程神经网络的航空发动机排气温度预测[J]. 航空动力学报, 2009, 24(5): 1035-1039.  
Ding Gang, Xu Minqiang, Hou Ligu. prediction of aeroengine exhaust gas temperature using[J]. Journal of Aerospace power, 2009, 24(5):1035-1039. (in Chinese)
- [13] 于广滨, 丁刚, 姚威, 等. 基于支持过程向量机的航空发动机排气温度预测[J]. 电机与控制学报, 2013, 17(8): 30-36.  
Yu Guangbin, Ding Gang, Yao Wei, et al. Aeroengine exhaust gas temperature prediction using support process vector machine [J]. Electric Machines and Control, 2013, 17(8):30-36. (in Chinese)
- [14] Zhou Lincheng, Yang Huizhong, Liu Chunbo. QPSO-based hyper-parameters selection for LS-SVM regression[C]// Proceedings of Fourth International Conference on Natural Computation. Jinan, China: IEEE, 2008: 130-133.
- [15] 黄璇, 郭立红, 李姜, 等. 改进粒子群优化 BP 神经网络的目标威胁估计[J]. 吉林大学学报:工学版, 2017, 47(3):996-1002.  
Huang Xuan, Guo Lihong, Li Jiang, et al. Target threat assessment based on BP neural network optimized by modified PSO[J]. Journal of Jilin University: Engineering and Technology Edition, 2017, 47(3): 996-1002. (in Chinese)
- [16] Sun Jun, Feng Bin, Xu Wenbo. Particle swarm optimization with particles having quantum behavior[C]// Proceedings of Congress on Evolutionary Computation. Portland: IEEE, 2004: 325-331.



**第一作者简介:**皮骏,男,1973年7月生,博士、副教授。主要研究方向为航空发动机振动分析、故障诊断。曾发表《机械振动故障诊断系统的设计与应用》(《噪声与振动控制》2015年第35卷第1期)等论文。

E-mail: pijun8@163.com