

航空发动机传感器信号重构的 K-ELM 方法

尤成新^{1,3}, 鲁 峰^{1,2,3}, 黄金泉^{1,2}

- (1. 南京航空航天大学 能源与动力学院 江苏省航空动力系统重点实验室, 南京 210016;
2. 先进航空发动机协同创新中心, 北京 100191;
3. 中国航空发动机集团有限公司 航空动力控制系统研究所, 江苏 无锡 214063)

摘 要: 针对航空发动机传感器信号重构, 提出了评价核极限学习机(K-ELM)模型性能的一种快速留一交叉验证方法. 结果表明: 该方法可以避免原始的留一验证方法 N 次模型的显式训练, 将计算复杂度降低为原来的 $1/N$ (N 为样本数目). 该算法可以快速准确评价核极限学习机的性能, 为核极限学习机确定最优的核参数.

关 键 词: 航空发动机; 传感器信号重构; 核极限学习机; 留一交叉验证方法; 核参数

中图分类号: V233.7

文献标志码: A

K-ELM method for sensor signal reconfiguration of aero-engine

YOU Cheng-xin^{1,3}, LU Feng^{1,2,3}, HUANG Jin-quan^{1,2}

- (1. Jiangsu Province Key Laboratory of Aerospace Power System, College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
2. Collaborative Innovation Center for Advanced Aero-Engine, Beijing 100191, China;
3. Aero-Engine Control System Institute, Aero Engine (Group) Corporation of China, Wuxi Jiangsu 214063, China)

Abstract: A fast leave-one-out cross validation method was presented to provide a criterion for kernel-based extreme learning machine (K-ELM) used for sensor signal reconfiguration of aero-engine. The procedure can avoid N times explicit training (N is the number of training samples) so that the computation cost was reduced $1/N$ when compared with normal leave-one-out procedure. Simulation results show that this method can provide a fast and accurate criterion, allowing to select best kernel parameters for K-ELM.

Key words: aero-engine; sensor signal reconfiguration; kernel-based extreme learning machine (K-ELM); leave-one-out cross validation method; kernel parameters

收稿日期: 2015-05-14

基金项目: 国家自然科学基金(51276087); 中央高校基本科研业务费专项资金(NP2012504); 南京航空航天大学研究生创新基地(实验室)开放基金(kfj20150205)

作者简介: 尤成新(1990—), 男, 硕士生, 主要从事航空发动机故障诊断研究.

通讯作者: 黄金泉(1963—), 男, 教授, 博士, 主要从事航空发动机控制及故障诊断研究. E-mail: jhuang@nuaa.edu.cn

引用格式: 尤成新, 鲁峰, 黄金泉. 航空发动机传感器信号重构的 K-ELM 方法[J]. 航空动力学报, 2017, 32(1): 221-226. YOU Chengxin, LU Feng, HUANG Jinquan. K-ELM method for sensor signal reconfiguration of aero-engine[J]. Journal of Aerospace Power, 2017, 32(1): 221-226.

航空发动机闭环控制系统离不开传感器测量信号.然而,由于航空发动机工作在高温、高压、大应力的苛刻条件下,而且还经常变换工作状态,导致传感器属于故障多发元件.解析余度技术是提高控制系统可靠性的有效途径之一.解析余度技术是根据被控对象的数学模型估计对象的某些变量,当该变量的传感器发生故障时,用其估计值作为余度信息,代替传感器的测量值,使系统仍能正常工作^[1-4].在解析余度技术中以神经网络为代表的航空发动机传感器故障诊断算法得到了深入的研究并取得了一定的成果^[5-9].但神经网络有自身的缺陷,如需要多次迭代,训练时间长,容易陷入局部最优解等.极限学习机(extreme learning machine, ELM)算法具有训练速度快、泛化能力强的特点,用于航空发动机传感器故障诊断中是一种有前途的方法^[10-13].

极限学习机在近年来的机器学习领域引起极大的关注, Huang 等将核函数引入到极限学习机中得到核极限学习机^[14](kernel-based ELM, K-ELM),揭示了 ELM 与支持向量机(SVM)等其他核方法之间的关系.与其他类型的核方法一样, K-ELM 面临模型选择和评价的问题,通常交叉验证的方法可以用来评价 ELM 模型的泛化性能,寻找最优的 ELM 模型.交叉验证方法有 Hold-Out 法、 k 重交叉验证方法和留一交叉验证(LOO-CV)方法等.相对于其他交叉验证方法,留一交叉验证法能够对模型的泛化误差给出更好的估计,估计是几乎无偏.但其计算成本太高,限制了它的实际应用,特别是处理一些大规模数据集问题^[15].

在降低留一交叉验证算法的计算成本方面已取得了一些研究成果^[8,16-17].对于显式的特征映射的极限学习机,文献[8]提出了进行快速留一交叉验证算法误差的快速计算方法,但该方法是在建立在 ELM 的特征映射是已知的基础上.在核极限学习机(K-ELM)中,特征映射不是显式给出的,而是以核函数的形式存在,所以原有的方法就无法直接用于核极限学习机.本文在 K-ELM 理论框架下给出了评价模型的快速留一交叉验证方法,并从理论和数值仿真两方面验证其有效性.

1 核极限学习机

给定 N 个样本 $\{(x_i, y_i) | i=1, 2, \dots, N\}$, 这里 $x_i = [x_{i1} \ x_{i2} \ \dots \ x_{in}]^T \in \mathbf{R}^n$, 学习问题表述为寻找预测函数 $f: x \rightarrow y$, 使得 $f(x) \approx y$. 在具有

L 个隐层神经元的 ELM 中, 这个预测函数的形式为

$$f(x) = \sum_{j=1}^L g(a_j^T x + b_j) \beta_j = \mathbf{h}^T(x) \boldsymbol{\beta} \quad (1)$$

式中 $a_j = [a_{1j} \ a_{2j} \ \dots \ a_{nj}]^T$, 为连接第 j 个隐含节点的输入权值向量; b_j 为第 j 个隐含节点偏置; $\boldsymbol{\beta} = [\beta_1 \ \beta_2 \ \dots \ \beta_L]^T$ 为输出权值向量, $\mathbf{h}(x) = [g(a_1^T x + b_1) \ \dots \ g(a_L^T x + b_L)]^T$ 为特征映射, $g(x)$ 为隐层神经元激活函数. 在 ELM 中, 输入权值和隐含节点偏置都是事先设定好的, 激活函数也是选定的, 所以 ELM 的训练问题归结为求解输出权值 $\boldsymbol{\beta}$, 建立如下的最优化问题^[12]:

$$\min_{\boldsymbol{\beta}} \frac{1}{2} \|\boldsymbol{\beta}\|_2^2 + \frac{C}{2} \sum_{i=1}^N \epsilon_i^2 \quad (2)$$

s. t. $\mathbf{h}^T(x_i) \boldsymbol{\beta} = y_i - \epsilon_i, i = 1, 2, \dots, N$

式中 C 为正则化参数, 可以人为设定. ϵ_i 是松弛变量, 衡量预测值与实际值之间的误差. 求解式(2)得到

$$\boldsymbol{\beta} = \mathbf{H}^T \left(\frac{1}{C} \mathbf{I}_N + \mathbf{H} \mathbf{H}^T \right)^{-1} \mathbf{Y} \quad (3)$$

式中 $\mathbf{H} = [\mathbf{h}(x_1) \ \dots \ \mathbf{h}(x_N)]^T$ 是隐含层输出矩阵, $\mathbf{Y} = [y_1 \ \dots \ y_N]^T$ 是输出向量, $\mathbf{I}_N$ 是一个 $N \times N$ 维的单位矩阵.

类似于 SVM 等核方法, 取代显示特征映射 $\mathbf{h}(x)$, 定义核函数: $k(x, y) = \langle \mathbf{h}(x), \mathbf{h}(y) \rangle$, 这里 $\langle \cdot, \cdot \rangle$ 表示特征映射的内积, 于是可以定义核矩阵 $\boldsymbol{\Omega}$

$$\boldsymbol{\Omega} = \mathbf{H} \mathbf{H}^T; \Omega_{i,j} = \mathbf{h}(x_i) \cdot \mathbf{h}(x_j) = k(x_i, x_j) \quad (4)$$

将核函数代入式(1)和式(3)得到 K-ELM 的预测函数

$$f(x) = \mathbf{h}^T(x) \boldsymbol{\beta} = \mathbf{h}^T(x) \mathbf{H}^T \left(\frac{1}{C} \mathbf{I}_N + \mathbf{H} \mathbf{H}^T \right)^{-1} \mathbf{Y} = \begin{bmatrix} k(x, x_1) \\ \vdots \\ k(x, x_N) \end{bmatrix}^T \left(\frac{1}{C} \mathbf{I}_N + \boldsymbol{\Omega} \right)^{-1} \mathbf{Y} = \mathbf{k}(x) \boldsymbol{\alpha} \quad (5)$$

式中 $\boldsymbol{\alpha}$ 是 K-ELM 的输出权值

$$\boldsymbol{\alpha} = \left(\frac{1}{C} \mathbf{I}_N + \boldsymbol{\Omega} \right)^{-1} \mathbf{Y} \quad (6)$$

2 核极限学习机的快速留一交叉验证法

留一交叉验证(LOO-CV)方法, 主要的思想是每次从 N 个样本挑选一个作为测试样本, 利用

剩余的 $(N-1)$ 个样本训练得到的模型对其进行估计, 这样保证每个模型与被测试的模型非常相似(仅相差一个训练样本点), 能够对被估计 ELM 模型的泛化性能给出很好的估计, LOO-CV 方法的泛化误差估计是几乎无偏^[15]. 但是 LOO-CV 方法也有明显的缺点, 要进行 N 次模型计算, 计算成本太高, 这在很大程度上限制了它的实际应用, 特别是对于一些大规模数据集问题. 针对该问题本文主要利用矩阵分块求逆的方法, 由包含所有样本的逆矩阵直接得到挑出单个样本的逆矩阵, 从而避免了 N 次模型训练带来的求逆过程, 大大降低了计算成本.

定义 $\mathbf{A} = \left(\frac{1}{C} \mathbf{I}_N + \mathbf{\Omega} \right)$, 代入式(6)得到

$$\boldsymbol{\alpha} = \mathbf{A}^{-1} \mathbf{Y} \quad (7)$$

首先消除第 p 个样本对模型训练的影响, 利用剩余的 $(N-1)$ 个样本训练 ELM 模型, 得到如下等式:

$$\boldsymbol{\alpha}_p = \mathbf{A}_p^{-1} \mathbf{Y} \quad (8)$$

式中 $\mathbf{A}_p$ 是通过将原来的 $\mathbf{A}$ 矩阵第 p 列所有的元素置零得到的(除了 $\mathbf{A}(p, p)$ 不变). 那么第 p 个样本对 ELM 模型建立的贡献可以忽略, 该 ELM 模型是基于剩余的 $(N-1)$ 个样本建立.

$$\mathbf{A} = \begin{bmatrix} a_{11} & \cdots & a_{1p} & \cdots & a_{1N} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ a_{p1} & \cdots & a_{pp} & \cdots & a_{pN} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ a_{N1} & \cdots & a_{Np} & \cdots & a_{NN} \end{bmatrix} \quad (9)$$

$$\mathbf{A}_p = \begin{bmatrix} a_{11} & \cdots & 0 & \cdots & a_{1N} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ a_{p1} & \cdots & a_{pp} & \cdots & a_{pN} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ a_{N1} & \cdots & 0 & \cdots & a_{NN} \end{bmatrix}$$

现在主要解决的问题是如何由原始矩阵 $\mathbf{A}$ 的逆 $\mathbf{A}^{-1}$ 直接得到 $\mathbf{A}_p$ 矩阵的逆 $\mathbf{A}_p^{-1}$, 以期减少矩阵求逆过程带来的计算量. 为此首先引入 Sherman-Morrison-Woodbury 公式

$$(\mathbf{A} + \mathbf{u}\mathbf{v}^T)^{-1} = \mathbf{A}^{-1} - \frac{\mathbf{A}^{-1}\mathbf{u}\mathbf{v}^T\mathbf{A}^{-1}}{1 + \mathbf{v}^T\mathbf{A}^{-1}\mathbf{u}} \quad (10)$$

定义 $\mathbf{u} = [a_{1p} \quad a_{2p} \quad \cdots \quad a_{(p-1)p} \quad 0 \quad a_{(p+1)p} \quad \cdots \quad a_{Np}]^T$, 以及 $\mathbf{v} = [0 \quad 0 \quad \cdots \quad 0 \quad -1 \quad 0 \quad \cdots \quad 0]^T$, 除了 $\mathbf{v}(p) = -1$ 其他元素为 0. 可以得到 $\mathbf{A}_p = \mathbf{A} + \mathbf{u}\mathbf{v}^T$, 那么去除第 p 个样本得到的输出权值为

$$\boldsymbol{\alpha}_p = \left(\mathbf{A}^{-1} - \frac{\mathbf{A}^{-1}\mathbf{u}\mathbf{v}^T\mathbf{A}^{-1}}{1 + \mathbf{v}^T\mathbf{A}^{-1}\mathbf{u}} \right) \mathbf{Y} = \boldsymbol{\alpha} - \frac{\mathbf{A}^{-1}\mathbf{u}\mathbf{v}^T\mathbf{A}^{-1}\mathbf{Y}}{1 + \mathbf{v}^T\mathbf{A}^{-1}\mathbf{u}} \quad (11)$$

经过一系列的推导和简化以后得到

$$1 + \mathbf{v}^T\mathbf{A}^{-1}\mathbf{u} = \bar{a}_{pp}a_{pp} \quad (12)$$

$$\mathbf{A}^{-1}\mathbf{u}\mathbf{v}^T\mathbf{A}^{-1}\mathbf{Y} = \mathbf{L}a_{pp}\boldsymbol{\alpha}(p) \quad (13)$$

式中 $\mathbf{L} = [\bar{a}_{1p} \quad \bar{a}_{2p} \quad \cdots \quad (\bar{a}_{pp}a_{pp} - 1)/a_{pp} \quad \cdots \quad \bar{a}_{Np}]^T$, $\boldsymbol{\alpha}(p)$ 是 $\boldsymbol{\alpha}$ 的第 p 个元素, $\bar{a}_{ip}$ ($i=1, 2, \dots, N$) 是 $\mathbf{A}^{-1}$ 中对应下标的元素, 于是得到

$$\boldsymbol{\alpha}_p = \boldsymbol{\alpha} - \frac{\mathbf{L}\boldsymbol{\alpha}(p)}{\bar{a}_{pp}} \quad (14)$$

$\boldsymbol{\alpha}_p$ 中每个分量代表相应样本对建立模型的贡献, 由于建立 $\mathbf{A}_p$ 时消除了第 p 个样本的影响, 所以 $\boldsymbol{\alpha}_p$ 的第 p 个分量可以忽略, 等价于用剩下 $N-1$ 个样本训练模型, 得到最终的模型输出权值为

$$\hat{\boldsymbol{\alpha}}_p = \hat{\boldsymbol{\alpha}} - \frac{\hat{\mathbf{L}}\hat{\boldsymbol{\alpha}}(p)}{\hat{a}_{pp}} \quad (15)$$

式中 $\hat{\boldsymbol{\alpha}}$ 和 $\hat{\mathbf{L}}$ 分别是 $\boldsymbol{\alpha}$ 和 $\mathbf{L}$ 剔除第 p 个分量(降为 $N-1$ 维)得到. 通过式(15)求解 $\hat{\boldsymbol{\alpha}}_p$ 建立剔除第 p 个样本的模型就避免了每次求逆, 大大减少了计算量.

综上所述, 对于包含 N 个样本的数据集 $\{(\mathbf{x}_i, y_i) | i=1, 2, \dots, N\}$, 核极限学习机的快速留一交叉验证算法的计算步骤如下:

- 1) 选取核函数, 计算包含所有样本的矩阵 $\mathbf{A}$ 及其逆, 设 $p=1$;
- 2) 根据式(15)计算剔除第 p 个样本后建立模型输出权值 $\hat{\boldsymbol{\alpha}}_p$;
- 3) 根据式(5)计算模型对第 p 个样本的估计值 $\tilde{y}_p$;
- 4) 如果 $p < N$, $p=p+1$ 转第 2 步;
- 5) 计算模型的泛化性能指标即方均根误差 (RMSE, 量符号记为 E_{rms})

$$E_{\text{rms}} = \sqrt{\frac{\sum_{p=1}^N (y_p - \tilde{y}_p)^2}{N}} \quad (16)$$

3 数值仿真验证

为了验证所提出的算法的有效性, 本文对快速留一交叉 (FLOO) 验证算法, 原始留一交叉 (LOO) 验证算法和 10-重交叉 (10F) 验证算法进行了比较, 使用人工数据集 sinc 以及实际数据集 Boston Housing 和 Abalone. 最后将该算法应用于航空发动机传感器信号重构模型选取, 建立了转速信号重构模型.

3.1 人工数据集 sinc

sinc 函数的表达式

$$f(x) = \begin{cases} \sin x / x & x \neq 0 \\ 1 & x = 0 \end{cases}$$

sinc 数据集是一个经常被用来测试学习机器性能的人工数据实例,在区间 $(-10,10)$ 内分别随机(均匀分布)产生 M 个训练样本,样本规模分别为 500,1000,1500,2000,2500,3000.表 1 中给出了样本数量从 500 增加到 3000 时 3 种算法的计算时间(单位:s).从表中可以看出,FLOO 算法具有明显的优势,且计算时间随样本数量呈线性增加.而 10F 算法计算时间相对来说也比较短,但随样本数目的增加计算时间增加的速度要比 FLOO 算法快,在处理更大规模的数据时不如 FLOO 算法.而 LOO 算法计算耗时最为漫长,基本上随样本数目呈平方趋势增加.

3.2 实际问题数据集

选取两个来自实际问题的数据集 Boston

housing 和 Abalone,两个数据集都来自 UCI(University of California)机器学习公共数据库,样本数目分别为 455 和 1000,所有的数据都归一化到 $[-1,1]$ 区间上.核函数分别选择径向基核函数(RBF)以及解析核函数^[18], γ 是核函数的可选参数将 γ 设置在 $[10^{-2}, 10^2]$ 区间.用式(16)中的均方根误差评价模型的泛化能力,其中 G_{loo} , G_{floo} 和 G_{10f} 分别是 LOO 算法、FLOO 算法和 10F 算法在训练样本上计算得到的方均根误差.

由于 LOO 算法每次从 N 个样本挑选一个作为测试,利用剩余的 $(N-1)$ 个样本对其进行估计,这样保证每个模型与被测试的模型非常相似(仅相差一个训练样本点),所以其方均根误差 G_{loo} 基本可以衡量其真实泛化能力.从表 2 和表 3

表 1 sinc 数据集估计耗时(单位:s)
Table 1 Estimate time for sinc dataset (unit:s)

算法	样本数量					
	500	1000	1500	2000	2500	3000
LOO	0.7491	7.7227	33.8026	74.1476	151.0138	277.2857
10F	0.1641	0.7006	3.1656	2.9968	5.1389	8.0324
FLOO	0.0851	0.2268	1.2960	1.4037	2.5874	3.8879

表 2 Boston housing 数据集估计精度
Table 2 Estimate accuracy for Boston housing dataset

γ	RBF			解析核函数		
	G_{loo}	G_{floo}	G_{10f}	G_{loo}	G_{floo}	G_{10f}
10^{-2}	0.41620	0.45100	0.43200	0.20877	0.22111	0.19978
10^{-1}	0.26079	0.27346	0.37001	0.10276	0.11406	0.11424
10^0	0.09068	0.09078	0.16412	0.08604	0.07717	0.10308
10^1	0.07475	0.07676	0.10137	0.07375	0.07170	0.10302
10^2	0.10673	0.10885	0.11301	0.06916	0.07259	0.10328

表 3 Abalone 数据集估计精度
Table 3 Estimate accuracy for Abalone dataset

γ	RBF			解析核函数		
	G_{loo}	G_{floo}	G_{10f}	G_{loo}	G_{floo}	G_{10f}
10^{-2}	0.26021	0.26066	0.26153	0.17534	0.18874	0.18383
10^{-1}	0.12178	0.11851	0.12364	0.09174	0.09623	0.09939
10^0	0.09149	0.09316	0.09912	0.08744	0.09188	0.09720
10^1	0.08934	0.09218	0.09720	0.08961	0.09215	0.09930
10^2	0.09441	0.09493	0.09888	0.09367	0.09308	0.09941

可以看出,与 G_{100} 比较, G_{floo} 总是比 G_{10f} 更接近 G_{100} ,说明 FLOO 算法相对 10F 算法更准确地衡量模型的泛化能力. 在参数选择方面,在 Boston housing 数据集中,对于 RBF 核在 $\gamma=10$ 三者都达到最小值,而解析核, G_{real} 在 $\gamma=10^2$ 达到最小, G_{floo} 和 G_{10f} 在 $\gamma=10$ 最小,说明两者对模型的实际泛化能力的估计还存在一定误差,所以最优的核参数还需在 $10\sim10^2$ 进一步寻找. 在 Abalone 数据集中,RBF 核参数在 $\gamma=10$ 达到最优,同样解析核参数也是在 $\gamma=10$ 模型的估计误差最小.

3.3 航空发动机传感器信号重构

现将 ELM 算法用于传感器信号重构,并结合本文提出的 FLOO 算法选择模型参数. 这里重构燃气涡轮转速信号 N_g ,选择与转速相关性大的 ω_f, T_3, p_3 信号作为 K-ELM 的输入变量, N_g 作为 K-ELM 的输出,所有测量值都归一化到 $[0,1]$ 区间上. 在地面条件下,选取一组发动机数据作为训练样本(样本数目为 2500)训练 K-ELM 模型. 再选取另一组数据作为测试样本,测试得到的 K-ELM 模型的精度,所有的训练和测试样本都附加噪声信号,噪声服从均值为 0、方差为 0.05 的高斯分布. 所选择 RBF 作为 K-ELM 的核函数,将核参数 γ 在 $[2^{-6}, 2^{10}]$ 范围内变化,得到模型的精度随核参数变化如图 1 所示,3 种算法都在 $\gamma=2$ 附近达到最优值,设置 γ 为 2,训练 K-ELM 模型,训练和预测结果如图 2 所示.

图 2 中实线是真实的样本值,虚线是 K-ELM 模型的预测值,预测值不完全等于真实信号的均值,训练和测试的方均根误差分别为 0.36% 和 0.37%,预测误差较小,属于可接受范围内. 可以看出无论是动态过程还是稳态过程,K-ELM 模型都能够很好地完成转速信号的重构,并且有抑




图 1 K-ELM 模型精度随核参数变化图
Fig. 1 Accuracy of K-ELM varying with kernel parameter





图 2 利用 K-ELM 重构 N_g 信号的训练和预测结果
Fig. 2 Training and prediction results of N_g signal reconfiguration using K-ELM

制噪声的能力.

4 结 论

本文提出了核极限学习机的快速留一交叉验证算法,在准确计算模型的留一交叉验证误差同时又降低了计算复杂度. 在人工数据集和 UCI 库中的实际问题数据集上的仿真结果表明,算法计算效率高,同时又能准确估计模型的泛化能力. 最后将该算法用于航空发动机传感器重构的 K-ELM 模型的参数选取,建立了转速信号的重构模型,在测量信号有噪声的情况下,K-ELM 仍然能够重构转速信号,并且有较高的预测精度.

参考文献:

[1] 赵永平. 支持向量回归机及其在智能航空发动机参数估计中的应用[D]. 南京:南京航空航天大学,2009.
ZHAO Yongping. Support vector regressions and their applications to parameter estimation for intelligent aero-engines[D]. Nanjing: Nanjing University of Aeronautics and Astronautics,2009. (in Chinese)
[2] 鲁峰,黄金泉,陈煜,等. 基于 SPSO-SVR 的融合航空发动机传感器故障诊断[J]. 航空动力学报,2009,24(8):1856-

1865.
LU Feng, HUANG Jinquan, CHEN Yu, et al. Research on sensor fault diagnosis of aero-engine based on data fusion of SPSO-SVR[J]. Journal of Aerospace Power, 2009, 24(8):1856-1865. (in Chinese)
- [3] XUE Wei, GUO Yingqing. Aircraft engine sensor fault diagnostics based on estimation of engine's health degradation[J]. Chinese Journal of Aeronautics, 2009, 22(1): 18-21.
- [4] FENG Zhigang, Shida K, WANG Qi. Sensor fault detection and data recovery based on LS-SVM predictor[J]. Chinese Journal of Scientific Instrument, 2007, 28(2):193-197.
- [5] ZHAO Yongping, SUN Jianguo. Fast online approximation for hard support vector regression and its application to analytical redundancy for aeroengine[J]. Chinese Journal of Aeronautics, 2010, 23(2):145-152.
- [6] 徐启华, 师军, 耿帅. 应用快速多分类 SVM 的航空发动机故障诊断方法[J]. 推进技术, 2012, 33(6):961-967.
XU Qihua, SHI Jun, GENG Shuai. Aeroengine fault diagnosis by a new fast multi-class support vector algorithm[J]. Journal of Propulsion Technology, 2012, 33(6):961-967. (in Chinese)
- [7] 吴斌, 尉询楷, 冯悦, 等. 航空发动机混沌支持向量预测模型应用[J]. 火力与指挥控制, 2011, 36(5):29-33.
WU Bin, WEI Xunkai, FENG Yue, et al. Applications of chaotic support vector forecasting model for aeroengine[J]. Fire Control and Command Control, 2011, 36(5):29-33. (in Chinese)
- [8] 徐启华, 耿帅, 师军. 基于大规模训练集 SVM 的发动机故障诊断[J]. 航空动力学报, 2011, 26(12):2841-2848.
XU Qihua, GENG Shuai, SHI Jun. Fault diagnosis method for aero-engine based on SVM with large-scale training set[J]. Journal of Aerospace Power, 2011, 26(12):2841-2848. (in Chinese)
- [9] 陈毅, 黄金泉, 张鹏. 航空发动机控制系统传感器 FDIA 系统仿真[J]. 航空动力学报, 2008, 23(2):396-400.
CHEN Yi, HUANG Jinquan, ZHANG Peng. FDIA simulation of aero-engine control system sensor FDIA system[J]. Journal of Aerospace Power, 2008, 23(2):396-400. (in Chinese)
- [10] Huang G B, Zhu Q Y, Chee K S. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1/2/3):489-501.
- [11] Hua W, Mao C Q, Zhang L J. A brief review of machine learning and its application[C]// Proceedings of International Conference on Information Engineering and Computer Science. Wuhan: IEEE, 2009:1-4.
- [12] 孙毅刚, 刘静雅, 赵珍. 基于极限学习机的航空发动机传感器故障诊断[J]. 传感器与微系统, 2014(8):23-26.
SUN Yigang, LIU Jingya, ZHAO Zhen. Aircraft engine sensor fault diagnosis based on extreme learning machine[J]. Transducer and Microsystem Technologies, 2014(8):23-26. (in Chinese)
- [13] 李业波, 李秋红, 黄向华, 等. 航空发动机传感器故障与部件故障诊断技术[J]. 北京航空航天大学学报, 2013, 39(9):1174-1180.
LI Yebo, LI QiuHong, HUANG Xianghua et al. Fault diagnosis for sensors and components of aeroengine[J]. Journal of Beijing University of Aeronautics and Astronautics, 2013, 39(9):1174-1180. (in Chinese)
- [14] Huang G B, Zhao H G, Ding X J, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics: Part B Cybernetics, 2012, 42(2):513-529.
- [15] 刘学艺. 极限学习机算法及其在高炉冶炼过程建模中的应用研究[D]. 杭州: 浙江大学, 2013.
LIU Xueyi. Research on extreme learning machine and its application to blast furnace ironmaking process[D]. Hangzhou: Zhejiang University, 2013. (in Chinese)
- [16] Cawley G C, Talbot N. Fast exact leave-one-out cross-validation of sparse least-squares support vector machines[J]. Neural Networks, 2004, 17(10):1467-1475.
- [17] Ying Z, Keong K C. Fast leave-one-out evaluation and improvement on inference for LS-SVMs[R]. Cambridge, UK: The 17th International Conference on Pattern Recognition, 2004.
- [18] Frénay B, Verleysen M. Parameter-insensitive kernel in extreme learning for non-linear support vector regression[J]. Neurocomputing, 2011, 74(16):2526-2531.

(编辑:王碧琚)