

基于贯序正则极端学习机的时间序列预测及其应用

张弦, 王宏力*

第二炮兵工程学院 自动控制工程系, 陕西 西安 710025

摘要: 为实现对液压泵特征参数的在线预测, 提出一种贯序正则极端学习机(SRELM), 并研究了基于SRELM的预测方法。SRELM根据结构风险最小化原理实现网络训练, 其网络权值可随新样本的逐次加入而递推求解, 具有泛化能力强与训练速度快的优点, 因此适于特征参数的在线预测。基于SRELM的预测方法利用特征参数训练SRELM模型, 以逐次增加新数据的方式对SRELM模型进行在线训练, 并利用训练后的SRELM模型对未来时刻的特征参数进行外推预测。液压泵特征参数预测实例表明, 基于SRELM的特征参数预测方法具有预测精度高与计算效率高的优点, 其综合性能优于基于传统迭代式神经网络的预测方法与基于支持向量机的预测方法。

关键词: 神经网络; 正则极端学习机; 特征参数预测; 时间序列分析; 视情维修

中图分类号: V557 文献标识码: A

特征参数预测技术, 利用可表征设备健康状况的状态特征参数建立预测模型, 以预测设备健康状况的未来发展趋势, 从而为其故障诊断与视情维修提供前瞻性依据^[1-2], 已在机械工程^[3-6]与航空航天^[7-8]领域获得了成功应用。以往方法大多利用当前时刻所获得的所有状态特征参数建立预测模型, 然后对以当前时刻为起点的设备状态进行短期预测, 属于典型的离线预测模式。然而实际工程实践中设备的状态并非一成不变, 而是在逐渐变化, 特别是在其性能发生退化时。只有利用最新获得的状态特征参数不断在线更新预测模型, 才可使更新后的预测模型更加真实地反映出设备当前时刻的真实状态。

作为导弹发射装置的重要组成部分, 液压系统的主要作用是对导弹发射装置的位置调节, 因此发挥着至关重要的作用。液压泵是液压系统的

动力源, 其状态直接影响整个液压系统。预测液压泵状态的发展趋势, 有利于掌控其健康状况, 以便在其状态恶化时对未来可能出现的故障做出早期预测。

极端学习机(Extreme Learning Machine, ELM)^[9]是一种新颖的单隐层前馈神经网络。它将传统的神经网络参数训练问题转化为求解线性方程组, 根据广义逆矩阵理论, 解析求得具有最小范数的最小二乘解作为网络权值, 其训练过程可一次完成而无需迭代。与传统神经网络训练算法中的网络权值迭代调整策略相比, ELM的训练速度显著提升。这一优势使ELM已在模式识别与回归估计等问题中获得了成功应用^[10-15]。为改善ELM的泛化能力, 文献^[15]借鉴统计学习理论中的结构风险最小化原理, 提出了正则极端学习机(Regularized Extreme Learning Machine,

收稿日期: 2010-10-08; 退修日期: 2010-12-23; 录用日期: 2011-01-18; 网络出版时间: 2011-03-04 16:34:38

网络出版地址: www.cnki.net/kcms/detail/11.1929.V.20110304.1634.000.html

DOI: CNKI:11-1929/V.20110304.1634.000

* 通讯作者. Tel.: 029-84743239 E-mail: wanghl@163.com

引用格式: 张弦, 王宏力. 基于贯序正则极端学习机的时间序列预测及其应用[J]. 航空学报, 2011, 32(7): 1302-1308. Zhang Xian, Wang Hongli. Time series prediction based on sequential regularized extreme learning machine and its application [J]. Acta Aeronautica et Astronautica Sinica, 2011, 32(7): 1302-1308.

RELM)。RELM通过引入参数 γ 以权衡经验风险与结构风险,使训练后RELM的网络权值具有更小的范数,从而提高了ELM的泛化能力。

针对应用于液压泵特征参数预测的RELM,借鉴文献[10]中在线贯序极端学习机(Online Sequential Extreme Learning Machine, OSELM)的思想,提出一种可实现在线训练的贯序正则极端学习机(Sequential Regularized Extreme Learning Machine, SRELM),其有效性将通过液压泵特征参数预测实例加以验证。

1 RELM

设时间序列训练样本集为 $S_k = \{(\mathbf{x}_p, t_p)\}_{p=1}^k$,其中 $\mathbf{x}_p = [x_p \ x_{p+1} \ \cdots \ x_{p+n-1}]^T$, $t_p = x_{p+n}$, x_p 为时间序列数据, k 为训练样本的数量, n 为嵌入维数。对于该时间序列训练样本集用于回归问题的RELM可表示为以下约束优化:

$$\begin{aligned} & \min \left(\frac{1}{2} \boldsymbol{\beta}_k^T \boldsymbol{\beta}_k + \frac{\gamma}{2} \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon} \right) \\ \text{s. t. } & t_p = \sum_{i=1}^L \beta_i f(\boldsymbol{\alpha}_i \mathbf{x}_p + b_i) - \varepsilon_p \quad (p = 1, 2, \dots, k) \end{aligned} \quad (1)$$

式中: γ 为调节经验风险与结构风险的参数; $f(\cdot)$ 为隐层神经元函数; L 为隐层神经元的数量; $\boldsymbol{\alpha}_i = [\alpha_{i1} \ \alpha_{i2} \ \cdots \ \alpha_{in}]$ 为连接第 i 个隐层神经元的输入权值,可在 $[-1, 1]$ 区间内随机生成; $\boldsymbol{\beta}_k = [\beta_1 \ \beta_2 \ \cdots \ \beta_L]^T$, β_i 为连接第 i 个隐层神经元的输出权值; b_i 为第 i 个隐层神经元的偏差,可在 $[-1, 1]$ 区间内随机生成; $\boldsymbol{\varepsilon} = [\varepsilon_1 \ \varepsilon_2 \ \cdots \ \varepsilon_k]^T$, ε_p 为回归误差。为求解上述优化问题,建立相应的拉格朗日函数为

$$\begin{aligned} L(\mathbf{w}, \boldsymbol{\varepsilon}, \boldsymbol{\beta}_k) &= \frac{1}{2} \boldsymbol{\beta}_k^T \boldsymbol{\beta}_k + \frac{\gamma}{2} \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon} - \\ & \mathbf{w}(\mathbf{H}_k \boldsymbol{\beta}_k - \mathbf{T}_k - \boldsymbol{\varepsilon}) \end{aligned} \quad (2)$$

式中: $\mathbf{w} = [\omega_1 \ \omega_2 \ \cdots \ \omega_k]$ 为拉格朗日权值; $\mathbf{H}_k = [\mathbf{h}_1^T \ \mathbf{h}_2^T \ \cdots \ \mathbf{h}_k^T]^T$ 为神经元矩阵, $\mathbf{h}_p = [f(\boldsymbol{\alpha}_1 \mathbf{x}_p + b_1) \ f(\boldsymbol{\alpha}_2 \mathbf{x}_p + b_2) \ \cdots \ f(\boldsymbol{\alpha}_L \mathbf{x}_p + b_L)]$ ($p = 1, 2, \dots, k$); $\mathbf{T}_k = [t_1 \ t_2 \ \cdots \ t_k]^T$ 为输出向量。

对拉格朗日函数各变量求偏导并令偏导数为

零,可得

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

式中: \mathbf{I} 为单位矩阵。最终可得训练后的RELM时间序列预测模型为

$$t = \sum_{i=1}^L \beta_i f(\boldsymbol{\alpha}_i \mathbf{x} + b_i) \quad (4)$$

式中: \mathbf{x} 为模型输入; t 为模型输出。

2 SRELM

从RELM的回归原理可见,由式(1)~式(4)所示的RELM训练过程建立在包含 k 个训练样本的固定训练样本集 S_k 上,实质为求解与 S_k 对应的输出权值 $\boldsymbol{\beta}_k$ 。当有独立于 S_k 之外的新训练样本 $(\mathbf{x}_{k+1}, t_{k+1})$ 加入 S_k 时, S_k 扩张为 $S_{k+1} = \{(\mathbf{x}_p, t_p)\}_{p=1}^{k+1}$,需利用 S_{k+1} 按照式(3)求解与之对应的 $\boldsymbol{\beta}_{k+1}$ 。然而,输出权值的求解过程涉及计算较大的矩阵逆运算,如果每加入一个新训练样本,都进行一次矩阵逆运算的话,会大为降低RELM在线训练的计算效率。为有效解决上述问题,本文提出一种可实现输出权值递推求解的RELM。

假设当前已利用 S_k 计算获得了式(3)所示的 $\boldsymbol{\beta}_k$ 。当有新训练样本 $(\mathbf{x}_{k+1}, t_{k+1})$ 加入时,对应的神经元矩阵 \mathbf{H}_k 变化为 $\mathbf{H}_{k+1} = \begin{bmatrix} \mathbf{H}_k \\ \mathbf{h}_{k+1} \end{bmatrix}$, $\mathbf{h}_{k+1} = [f(\boldsymbol{\alpha}_1 \mathbf{x}_{k+1} + b_1) \ f(\boldsymbol{\alpha}_2 \mathbf{x}_{k+1} + b_2) \ \cdots \ f(\boldsymbol{\alpha}_L \mathbf{x}_{k+1} + b_L)]$ 为与 $(\mathbf{x}_{k+1}, t_{k+1})$ 对应的新输入向量,输出向量 \mathbf{T}_k 变化为 $\mathbf{T}_{k+1} = \begin{bmatrix} \mathbf{T}_k \\ t_{k+1} \end{bmatrix}$ 。因此根据式(3),此时的RELM输出权值为

$$\begin{aligned} \boldsymbol{\beta}_{k+1} &= \left(\mathbf{H}_{k+1}^T \mathbf{H}_{k+1} + \frac{\mathbf{I}}{\gamma} \right)^{-1} \mathbf{H}_{k+1}^T \mathbf{T}_{k+1} = \\ & \left(\mathbf{H}_k^T \mathbf{H}_k + \mathbf{h}_{k+1}^T \mathbf{h}_{k+1} + \frac{\mathbf{I}}{\gamma} \right)^{-1} (\mathbf{H}_k^T \mathbf{T}_k + \mathbf{h}_{k+1}^T t_{k+1}) \end{aligned} \quad (5)$$

令 $\mathbf{P}_{k+1} = \left(\mathbf{H}_k^T \mathbf{H}_k + \mathbf{h}_{k+1}^T \mathbf{h}_{k+1} + \frac{\mathbf{I}}{\gamma} \right)^{-1}$, $\mathbf{P}_k = \left(\mathbf{H}_k^T \mathbf{H}_k + \frac{\mathbf{I}}{\gamma} \right)^{-1}$,可得

$$\mathbf{P}_{k+1} = (\mathbf{P}_k^{-1} + \mathbf{h}_{k+1}^T \mathbf{h}_{k+1})^{-1} \quad (6)$$

将 Sherman-Morrison 矩阵求逆引理^[16]应用于式(6),可得 \mathbf{P}_k 的递推表达式为

$$\mathbf{P}_{k+1} = \mathbf{P}_k - \frac{\mathbf{P}_k \mathbf{h}_{k+1}^T \mathbf{h}_{k+1} \mathbf{P}_k}{1 + \mathbf{h}_{k+1}^T \mathbf{P}_k \mathbf{h}_{k+1}} \quad (7)$$

对式(6)两端同时求逆后代入式(5),可得 β_k 的递推表达式为

$$\begin{aligned} \beta_{k+1} &= \mathbf{P}_{k+1} (\mathbf{H}_{k+1}^T \mathbf{T}_k + \mathbf{h}_{k+1}^T t_{k+1}) = \\ &= \mathbf{P}_{k+1} (\mathbf{P}_k^{-1} \beta_k + \mathbf{h}_{k+1}^T t_{k+1}) = \\ &= \mathbf{P}_{k+1} [(\mathbf{P}_k^{-1} - \mathbf{h}_{k+1}^T \mathbf{P}_k \mathbf{h}_{k+1}) \beta_k + \mathbf{h}_{k+1}^T t_{k+1}] = \\ &= \beta_k + \mathbf{P}_{k+1} \mathbf{h}_{k+1}^T (t_{k+1} - \mathbf{h}_{k+1} \beta_k) \end{aligned} \quad (8)$$

因此, β_{k+1} 可在 β_k 的基础上递推而得,避免了根据式(3)重新计算。

3 基于 SRELM 的时间序列预测

将 SRELM 应用于特征参数预测的过程包含如下 5 个步骤:

步骤 1 选择合适的嵌入维数 n , 将原始的 m 个特征参数 $\{x_p\}_{p=1}^m$ 转化为训练样本集 S_k , $k = m - n$ 。

步骤 2 选择合适的参数 γ 、隐层神经元数量 L 与隐层神经元函数 $f(\cdot)$, 并在 $[-1, 1]$ 区间内随机生成 $f(\cdot)$ 的输入权值与偏差, 然后在此基础上利用 S_k 计算初始输出权值:

$$\beta_k = \mathbf{P}_k \mathbf{H}^T \mathbf{T}_k \quad (9)$$

步骤 3 以 $\mathbf{x}_{k+1} = [x_{m-n+1} \quad x_{m-n+2} \quad \dots \quad x_m]^T$ 为输入, 计算获得未来时刻特征参数 x_{m+1} 的预测值为

$$\tilde{x}_{m+1} = \sum_{i=1}^L \beta_i f(\mathbf{a}_i \mathbf{x}_{k+1} + b_i) \quad (10)$$

步骤 4 在获得 x_{m+1} 的真实值之后, 根据式(11)对 \mathbf{P}_k 与 β_k 进行递推更新。

$$\begin{cases} \mathbf{P}_{k+1} = \mathbf{P}_k - \frac{\mathbf{P}_k \mathbf{h}_{k+1}^T \mathbf{h}_{k+1} \mathbf{P}_k}{1 + \mathbf{h}_{k+1}^T \mathbf{P}_k \mathbf{h}_{k+1}} \\ \beta_{k+1} = \beta_k + \mathbf{P}_{k+1} \mathbf{h}_{k+1}^T (t_{k+1} - \mathbf{h}_{k+1} \beta_k) \end{cases} \quad (11)$$

式中: $t_{k+1} = x_{m+1}$ 。

步骤 5 令 $k = k + 1$, $m = m + 1$, 转至步骤 3。

4 特征参数时间序列预测实例

以某型导弹发射装置中的轴向柱塞式液压泵为研究对象, 采用压电式振动加速度传感器在采

样频率为 2 560 Hz 的条件下分别采集其端盖振动信号与壳体振动信号, 选取其中的 100 个端盖振动峰峰值时间序列 $\{x_p\}_{p=1}^{100}$ 与 100 个壳体振动峰峰值时间序列 $\{y_p\}_{p=1}^{100}$, 作为该液压泵的特征参数, 如图 1 所示。

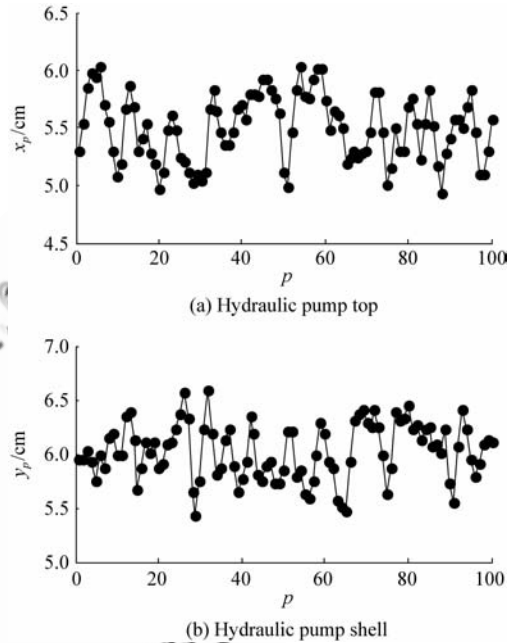


图 1 液压泵振动峰峰值

Fig. 1 Vibration peak-to-peak values of hydraulic pump

4.1 SRELM 与传统神经网络的比较

分别采用 SRELM、基于 Levenberg-Marquardt 训练算法的神经网络 (LM-NN)、基于共轭梯度训练算法的神经网络 (CG-NN) 与基于拟牛顿训练算法的神经网络 (BFGS-NN) 建立预测模型。

选择嵌入维数 $n = 6$, 将 $\{x_p\}_{p=1}^{100}$ 与 $\{y_p\}_{p=1}^{100}$ 转化为训练与测试样本集 $\{(\mathbf{x}_p, t_p)\}_{p=1}^{94}$ 与 $\{(\mathbf{y}_p, v_p)\}_{p=1}^{94}$, 其中, $\mathbf{x}_p = [x_p \quad x_{p+1} \quad \dots \quad x_{p+n-1}]^T$ 、 $\mathbf{y}_p = [y_p \quad y_{p+1} \quad \dots \quad y_{p+n-1}]^T$ 为预测模型输入, $t_p = x_{p+n}$ 、 $v_p = y_{p+n}$ 为预测模型输出。利用前 84 个样本 $\{(\mathbf{x}_p, t_p)\}_{p=1}^{84}$ 、 $\{(\mathbf{y}_p, v_p)\}_{p=1}^{84}$ 分别训练预测模型, 然后利用训练后的预测模型对后 10 个样本 $\{(\mathbf{x}_p, t_p)\}_{p=85}^{94}$ 、 $\{(\mathbf{y}_p, v_p)\}_{p=85}^{94}$ 分别进行离线与在线预测。利用预测平均相对误差 $E = \frac{1}{N} \cdot$

$\sum_{f=1}^N \left| \frac{\tilde{x}_f - x_f}{x_f} \right| \times 100$ 衡量预测精度, 其中, x_f 为

时间序列真实值, \hat{x}_f 为 x_f 的预测值, N 为预测数据的长度; 利用预测模型训练时间 T 衡量计算效率。

当利用上述 4 种神经网络进行时间序列预测时, 除隐层神经元数量 L 是需人为选择的一个共同因素之外, 由于 SRELM 中引入了参数 γ , 因此还需考虑 γ 对 SRELM 预测精度的影响。图 2 与图 3 分别为 $L=10, 20, 30, 40, 50$ 时, γ 对基于 SRELM 预测模型的离线与在线预测结果的影响。从图 2 与图 3 可见, E 随 γ 在 $10^1 \sim 10^{11}$ 范围内变化表现出显著的差异且变化规律也不尽相同, 但基本都在 $\gamma \in [10^4, 10^5]$ 时取得最小值。




图 3 γ 对壳体预测结果的影响

Fig. 3 Effect of γ on hydraulic pump shell prediction

表 1~表 4 展示了在 $\gamma=10^4$ 条件下, 具有不同隐层神经元的 SRELM 与 LM-NN、CG-NN、BFGS-NN 预测模型对测试样本的离线与在线预测结果。离线预测模式仅利用训练样本对预测模型进行一次训练, 之后不再利用新样本更新预测模型。由于液压泵的状态在不断发生变化, 而离线预测所建立的预测模型始终停留在前 84 个样本的影响下, 并未随液压泵的状态变化而同时调整, 因此其预测值会逐渐偏离真实值。在线预测模式不断将新样本加入训练样本集, 虽需多次训练预测模型, 但保证了始终利用最新状态特征参数更新预测模型, 使得更新后的预测模型始终反映液压泵的最新状态, 且其预测值均是以一步外推预测方式获得的, 可始终保持对于状态特征参数的准确预测。因此, 4 种预测模型的在线预测训练时间虽多于离线训练时间, 但在线预测平均相对误差却远小于离线预测平均相对误差。

相比于 LM-NN、CG-NN 与 BFGS-NN, SRELM 沿袭了 ELM 以求解线性方程组的方式完成模型训练的优势, 对于网络权值的求解无需迭代而是一次完成。表 1~表 4 中的训练时间表明, SRELM 所需训练时间仅为其余 3 种传统神经网络的 1/100 左右。因此, SRELM 在训练速度方面表现出了极为明显的优势, 且 SRELM 避免了新样本贯序加入时的预测模型重新训练问题, 更适于在线训练。RELM 通过引入参数 γ 权衡 ELM 的结构风险与经验风险, 其泛化能力较传统神经网络有显著提高^[15]。作为一种可实现贯序训练的 RELM 改进模式, SRELM 同样具备了这一优势。从表 1~表 4 可见, SRELM 的平均相对误差均明显小于 LM-NN、CG-NN 与 BFGS-NN, 因此预测精度更高。

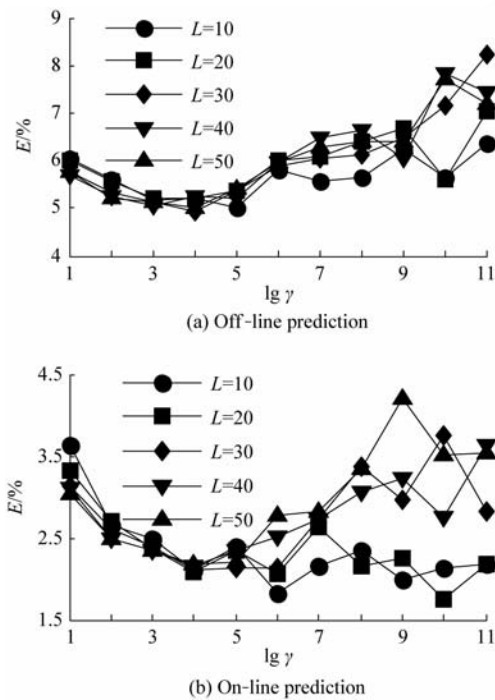


图 2 γ 对端盖预测结果的影响

Fig. 2 Effect of γ on hydraulic pump top prediction

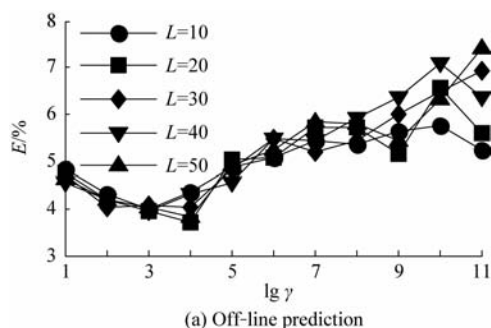


表 1 端盖振动峰峰值的离线预测结果

Table 1 Off-line prediction results of hydraulic pump top vibration peak-to-peak value

Hidden-layer neuron amount	SRELM		LM-NN		CG-NN		BFGS-NN	
	E/%	T/s	E/%	T/s	E/%	T/s	E/%	T/s
10	5.217 0	0.003 1	7.375 9	3.403 2	9.258 3	10.830 2	8.226 4	7.869 1
20	4.708 8	0.005 8	6.580 1	0.547 5	7.536 8	5.795 3	7.842 0	5.832 3
50	5.017 4	0.015 9	7.153 8	1.684 8	7.863 7	5.236 5	8.572 3	21.736 5

表 2 端盖振动峰峰值的在线预测结果

Table 2 On-line prediction results of hydraulic pump top vibration peak-to-peak value

Hidden-layer neuron amount	SRELM		LM-NN		CG-NN		BFGS-NN	
	E/%	T/s	E/%	T/s	E/%	T/s	E/%	T/s
10	2.096 5	0.004 1	5.497 2	36.251 6	5.302 3	59.828 4	5.424 0	73.654 5
20	2.084 5	0.008 6	5.004 5	1.176 6	4.179 3	9.258 9	5.075 1	23.654 2
50	2.184 2	0.028 9	4.056 9	3.621 1	5.300 7	13.335 4	5.584 0	41.571 3

表 3 壳体振动峰峰值的离线预测结果

Table 3 Off-line prediction results of hydraulic pump shell vibration peak-to-peak value

Hidden-layer neuron amount	SRELM		LM-NN		CG-NN		BFGS-NN	
	E/%	T/s	E/%	T/s	E/%	T/s	E/%	T/s
10	4.370 9	0.002 5	9.851 9	0.507 2	8.856 1	7.809 1	9.186 9	9.828 7
20	3.721 6	0.006 7	7.391 3	0.574 5	7.369 2	5.516 1	8.423 7	11.254 2
50	3.823 3	0.016 9	7.612 8	2.267 9	8.010 3	3.385 1	9.253 0	19.662 4

表 4 壳体振动峰峰值的在线预测结果

Table 4 On-line prediction results of hydraulic pump shell vibration peak-to-peak value

Hidden-layer neuron amount	SRELM		LM-NN		CG-NN		BFGS-NN	
	E/%	T/s	E/%	T/s	E/%	T/s	E/%	T/s
10	1.795 4	0.004 6	3.928 7	50.676 6	3.435 0	55.795 7	3.922 0	96.770 2
20	1.623 5	0.008 1	4.257 4	0.978 0	5.249 4	10.564 0	4.474 2	19.021 5
50	1.672 9	0.029 3	4.453 1	3.731 9	3.988 0	15.856 7	5.338 0	42.990 3

4.2 SRELM 与支持向量机(SVM)的比较

SVM 是一种被众多学者应用于特征参数预测^[5,7-8]的机器学习方法,因此选择 SVM 与 SRELM 进行比较。鉴于在线预测相比于离线预测在预测精度上的优势,仅进行在线预测比较,以高斯函数作为 SVM 的核函数。

正则化参数 c 与高斯核参数 r 是影响 SVM 预测精度的两个重要参数,图 4 与图 5 是在 $c \in [1, 1\ 000]$ 与 $r \in [1, 1\ 000]$ 范围内, SVM 对后 10

个数据的在线预测结果。从图中可见, c 与 r 对于 SVM 的预测精度具有显著影响,需谨慎选择才能获得最小的预测平均相对误差,其对于后 10 个数据的最小预测平均相对误差分别为 2.013 8% 与 1.810 9%,这与 SRELM 的预测精度相当。然而 SVM 的训练过程相当于求解计算代价较大的二次规划,完成在线预测所需训练时间分别为 37.581 2 s 与 45.297 1 s,几乎是 SRELM 训练时间的 1 000 倍。因此, SRELM 在训练速度方面的优势极为明显。




图4 基于SVM的端盖振动峰峰值的预测结果

Fig. 4 SVM prediction results of hydraulic pump top vibration peak-to-peak value




图5 基于SVM的壳体振动峰峰值的预测结果

Fig. 5 SVM prediction results of hydraulic pump shell vibration peak-to-peak value

5 结论

(1) 基于特征参数预测的状态监测技术通过预测反映设备健康状况的重要特征参数,以预知设备状态的恶化趋势,是一种增强设备故障早期发现能力的重要手段。

(2) 液压泵特征参数预测实例表明,在线预测模式预测精度显著高于离线预测模型,更适于液压泵的状态监测,而SRELM正是为解决时间序列在线预测问题而提出的一种RELM在线训练模式,具有预测精度高且计算代价小的优点,因此可准确且快速地在线预测出液压泵的未来时刻状态,更适于基于特征参数预测的状态监测。

参 考 文 献

[1] 曾声奎, Michael G. Pecht, 吴际. 故障预测与健康管

(PHM)技术的现状与发展[J]. 航空学报, 2005, 26(5): 626-632.

Zeng Shengkui, Michael G. Pecht, Wu Ji. Status and perspectives of prognostics and health management technologies[J]. Acta Aeronautica et Astronautica Sinica, 2005, 26(5): 626-632. (in Chinese)

[2] 孙博, 康锐, 张叔农. 基于特征参数趋势进化的故障诊断和预测方法[J]. 航空学报, 2008, 29(2): 393-398.

Sun Bo, Kang Rui, Zhang Shunong. An approach to diagnostics and prognostics based on evolutionary feature parameters [J]. Acta Aeronautica et Astronautica Sinica, 2008, 29(2): 393-398. (in Chinese)

[3] Caesarendra W, Niu G, Yang B S. Machine condition prognosis based on sequential Monte Carlo method[J]. Expert Systems with Applications, 2010, 37(3): 2412-2420.

[4] Tran V T, Yang B S, Tan A C C. Multi-step ahead direct prediction for the machine condition prognosis using regression trees and neuro-fuzzy systems[J]. Expert Systems with Applications, 2009, 36(5): 9378-9387.

[5] Feng F Z, Zhu D D, Jiang P C, et al. GA-EMD-SVR condition prediction for a certain diesel engine[C]// Proceedings of Prognostics and Health Management Conference, 2010: 1-8.

[6] Zhao F G, Chen J, Guo L, et al. Neuro-fuzzy based condition prediction of bearing health[J]. Journal of Vibration and Control, 2009, 15(7): 1079-1091.

[7] 李本威, 张贇, 孙涛. 基于免疫粒子群算法的滑油屑末支持向量机预测模型设计[J]. 航空动力学报, 2009, 24(7): 1639-1643.

Li Benwei, Zhang Yun, Sun Tao. Design of forecasting model for aero-engine lubrication debris support vector machines based on immune-particle swarm optimization algorithm[J]. Journal of Aerospace Power, 2009, 24(7): 1639-1643. (in Chinese)

[8] 胡金海, 谢寿生, 骆广琦, 等. 基于支持向量机方法的发动机性能趋势预测[J]. 推进技术, 2005, 26(3): 260-264.

Hu Jinhai, Xie Shousheng, Luo Guangqi, et al. Study of support vector machines for aeroengine performance trend forecasting[J]. Journal of Propulsion Technology, 2005, 26(3): 260-264. (in Chinese)

[9] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1-3): 489-501.

[10] Liang N Y, Huang G B, Saratchandran N, et al. A fast and accurate on-line sequential learning algorithm for feed-forward networks[J]. IEEE Transactions on Neural Networks, 2006, 17(6): 1411-1423.

[11] Miche Y, Soriamaa A, Bas P, et al. OP-ELM: optimally

- pruned extreme learning machine[J]. IEEE Transactions on Neural Networks, 2010, 21(1): 158-162.
- [12] Liu N, Wang H. Ensemble based extreme learning machine[J]. IEEE Signal Processing Letters, 2010, 17(8): 754-757.
- [13] Lan Y, Soh C Y, Huang G B. Constructive hidden nodes selection of extreme learning machine for regression[J]. Neurocomputing, 2010, 73(16-18): 3191-3199.
- [14] Malathi V, Marimuthu N S, Baskar S. Intelligent approaches using support vector machine and extreme learning machine for transmission line protection [J]. Neurocomputing, 2010, 73(10-12): 2160-2167.
- [15] 邓万宇, 郑庆华, 陈琳, 等. 神经网络极速学习方法研究[J]. 计算机学报, 2010, 33(2): 279-287.
Deng Wanyu, Zheng Qinghua, Chen Lin, et al. Research on extreme learning of neural networks[J]. Chinese Journal of Computers, 2010, 33(2): 279-287. (in Chinese)
- [16] 张贤达. 矩阵分析与应用[M]. 北京: 清华大学出版社, 2005.
Zhang Xianda. Matrix analysis and applications[M]. Beijing: Tsinghua University Press, 2005. (in Chinese)

作者简介:

张弦(1982—) 男, 博士研究生。主要研究方向: 工业过程的故障监控。

Tel: 029-84743239

E-mail: sltecas@163.com

王宏力(1965—) 男, 博士, 教授。主要研究方向: 控制系统的故障检测与诊断。

Tel: 029-84743239

E-mail: wanghl@163.com

Time Series Prediction Based on Sequential Regularized Extreme Learning Machine and Its Application

ZHANG Xian, WANG Hongli*

Department of Automatic Control Engineering, The Second Artillery Engineering College, Xi'an 710025, China

Abstract: In order to accurately predict the feature parameters of a hydraulic pump, a new algorithm called sequential regularized extreme learning machine (SRELM) is proposed and a prediction method based on SRELM is studied. On the basis of structural risk minimization theory, SRELM balances the empirical risk and structural risk to enhance the generalization performance of conventional extreme learning machine (ELM). In comparison with the regularized extreme learning machine (RELM), SRELM can complete the training procedure recursively without retraining when there are sequential training samples. Thus, SRELM is suitable for on-line feature parameter prediction. In the SRELM-based prediction method, feature parameters of the hydraulic pump are used to train an SRELM model. The latest feature parameter is adopted iteratively to update the prediction model and then the trained prediction model is used to predict future feature parameters. Experiments on the hydraulic pump feature parameter prediction indicate that the SRELM-based prediction method has better performance in prediction accuracy and computational cost in comparison with conventional neural-network-based prediction and support-vector-machine-based prediction.

Key words: neural networks; regularized extreme learning machine; feature parameter prediction; time series analysis; condition-based maintenance

Received: 2010-10-08; Revised: 2010-12-23; Accepted: 2011-01-18; Published online: 2011-03-04 16:34:38

URL: www.cnki.net/kcms/detail/11.1929.V.20110304.1634.000.html DOI: CNKI:11-1929/V.20110304.1634.000

* Corresponding author. Tel.: 029-84743239 E-mail: wanghl@163.com