DOI: 10.19650/j.cnki.cjsi.J1905491

基于在线相关熵极限学习机的器件退化趋势实时流预测方法*

梅文娟[1],高 媛[2],杜 立[1],刘 震[1],王厚军[1]
(1. 电子科技大学自动化工程学院 成都 611731; 2. 军委装备发展部某中心 北京 100000)

摘 要:针对器件退化趋势预测,现有方法难以有效进行模型在线更新且趋势预测易受噪声和奇异值影响产生畸变的问题,构建了一种在线受限相关熵极限学习机,并在该模型基础上,提出了预测模型动态更新方法,完成了高可靠器件退化趋势建模及参数线动态更新。通过建立训练数据误差编码本,利用 M-估计动态检测训练数据中的奇异值并进行相应的模型修正,进一步提高模型的鲁棒性。仿真实验及光电耦合器 CTR 实验均表明该方法相比于典型的预测方法,能够在避免实时噪声和奇异值干扰的情况下对预测模型作出有效的更新且能快速给出单步及多步的预测结果,有效地提升了实时预测的准确性。

关键词: 极限学习机; 实时预测方法; 相关熵; 实时流数据
中图分类号: TH701 **文献标识码**: A **国家标准学科分类代码**: 520.20

Online sequential regularized correntropy criterion extreme learning machine on spark streaming signal prediction for electronic device degradation

Mei Wenjuan[1], Gao Yuan[2], Du Li[1], Liu Zhen[1], Wang Houjun[1]
(*1.School of Automation Engineering, University of Electronic and Technology of China, Chengdu 611731, China*;
2.CMC Equipment Development Department, Beijing 100000, China)

Abstract: For real-time prediction on device degradation, the existing algorithms are difficult to update the trained model and the prediction results are easy to be distorted due to the outlier and noise. To solve these problems, a novel method named as online sequential regularized correntropy criterion extreme learning machine (OSRCC-ELM) is proposed to generate high robust prediction model and provide dynamic updating ability. Firstly, based on the regularized correntropy criterion ELM, the updating method for the model is realized. Secondly, the outlier and noise are detected with the dynamic M-estimator that is integrated with the error codebook. Finally, the corresponding influence of the outlier and noise are removed from the current model. Experiments using simulated data and CTR of optical couples show that OSRCC-ELM can achieve higher prediction accuracy without the effect of outliers and noises than other methods while provide accurate prediction with high speed.

Keywords: extreme learning machine; online prediction method; correntropy; spark streaming data

0 引 言

伴随电子器件相关技术的飞速发展,针对电子器件可靠性设计的要求日益增加。其中,器件退化趋势的预测可以准确及时地为用户提供相关的状态信息,不仅能够有效地预防设备故障的发生,还为其他可靠性服务提供可靠信息,提高维护和备存的效率[1-3]。目前,趋势预测已经应用于航空航天[4]、舰船维护[5]、车辆管理[6]等场合中,成为保障设备安全性、完好性的重要手段[7]。因此,电子器件退化趋势的预测技术成为现今研究的热点之一。

该领域的相关研究主要分为物理机理法和数据驱动方法两类。物理机理法通过对待预测对象的退化机制进

收稿日期:2019-08-18 Received Date:2019-08-18
*基金项目:国家自然科学基金(U1830133)项目资助

行详细分析,推导器件的退化规律,以此为依据进行预测[8-10]。Mohammad 等[11]通过对偶准则设计了针对 DC/DC 转换器的预测模型,该模型可以有效预测转换器的剩余寿命。同时,Daeil 等[12]提出基于阻抗分析的模型预测方法,用于预测由于接触失效造成的射频器件故障。实验证明,射频器件阻抗可以有效地反映器件的健康状况。尽管物理机理法可以提供精准的预测信息,然而该类方法仅适用于特定器件的退化预测。同时,由于多数机理方法假定器件处于理想情况下,因此该类方法在实际应用中效果并不理想。

近年来,机器学习方法,例如支持向量机(support vector machine, SVM)[13],相关向量机(relevance vector machine, RVM)[14]、粒子滤波器(particle filter, PF)[15]因为高效的数据特征提取能力和自适应模型生成能力作为数据驱动预测方法中脱颖而出。由于机器学习方法可以自适应地提取数据的变化规律,因此相较于机理法更能适应当下对器件预测模型在生成时间上的要求,同时可以达到更高的预测精度[16-18]。然而,随着大数据、云计算和工业互联网的发展和融合,电子设备的退化趋势预测存在了新的挑战。

1)电子设备反映退化趋势的数据日益增加,虽然数据的增加可以在一定程度提升模型的预测精度,然而也影响了模型训练时间。传统的机器学习方法由于需要通过迭代不断修正网络中各个节点的权重,在海量数据的情况下时间复杂度过高,导致模型的预测效率降低[19-20]。2006 年,Huang 等[21]提出一种可以快速训练的 3 层网络,称为极限学习机(extreme learning machine, ELM)。ELM 随机产生隐藏层权值,同时可以通过最小均方准则直接计算输出层权重,因此 ELM 克服了传统机器学习方法需要反复迭代调整权值的不足,能够快速产生预测模型,被广泛用于趋势预测领域[22-23]。

2)工业互联网对预测的实时性要求更高,设备故障趋势多是通过数据逐条输入的实时流数据进入预测模型。相较于批数据处理,流数据情况下的预测在时延上要求更加严格。并且由于传统的流数据预测方法采用“离线训练,在线预测”的方式[24-26]。在早期器件退化趋势不明显的情况下,这种预测方法会导致预测模型无法准确反映器件的总体退化信息,造成较高的预测误差。胡友涛等[27]提出的基于 WSVR 和 FCM 聚类的实时寿命预测方法,利用同类产品的性能退化数据对特定个体的寿命进行实时预测。该方法通过聚类,能够找到于特定个体相了类似的历史信息,做到有效的预测。然而,该方法不适用于数量小的设备寿命预测中。相比而言,在 ELM 的基础上发展的在线极限学习机(online sequential extreme learning machine, OSELM),可以在原有快速生成的离线预测模型基础上,动态更新网络中的节点权重[28]。基于 OSELM 的趋势预测方法不仅继承了 ELM 的快速性,同时克服了离线训练下预测模型受到离线训练数据特征局限的缺点,能够及时对模型进行有效更新[29-31]。

3)对于实际应用中的器件如光电耦合器、IGBT 等,其退化趋势早期并不明显,并且数据中存在噪声或奇异值,绝大多数的机器学习方法构建的趋势预测模型易受到干扰[32]。尽管在离线预测情况下已经有通过替换最小均方准则的机器学习算法,如相关熵极限学习机(regularized correntropy criterion extreme learning machine, RCC-ELM)[33]、幸存误差信息极限学习机(enabled survival error potential extreme learning machine, ESEP-ELM)[34]等模型可以在一定程度上降低噪声和奇异值带来的影响。然而,对于在线预测的情况,相关的研究较少。Guo 等[35]采用 M 估计对极限学习机进行改进,提出在线 M-估计极限学习机(M-estimator online sequential extreme learning machine, MOS-ELM)。该方法通过 M-估计检测出异常数据中,避免了含奇异值的数据参与到预测模型的更新过程中。其仿真结果表明该方法在混沌数据下相比其他方法具有更高的预测精度。然而,对于电子器件的退化时间序列,由于 M-估计的阈值仅以离线的训练数据作为依据,因此在退化趋势变化较大的情况下,与早期退化趋势偏差较大的器件的实时数据可能会被错误判断为奇异值,导致预测受到局限。在相关熵极限学习机上,Wang 等[36]提出了基于生成最大相关熵准则的在线极限学习机(generalized maximum correntropy criterion, OS-ELM-GMCC),克服了 RCC-ELM 的预测效果受离线数据的统计规律影响的弊端。然而对于 OS-ELM-GMCC 算法,生成最大相关熵的谱轮廓参量较难确定,这在一定程度上限制了方法的应用。

为克服由于传统的离线预测模型及现有在线模型对于实时数据奇异值和噪声估计发生偏差,预测趋势发生畸变的问题,本文提出了一种在线受限相关熵极限学习机(online sequential restricted correntropy criterion based extreme learning machine, OSRCC-ELM)。在 RCC-ELM 的基础上,提出了针对实时流数据的预测模型动态更新方法,提升预测模型在动态数据下的鲁棒性。同时,建立模型训练数据的误差编码本,通过 M-估计动态检测训练数据中存在的奇异值,并给出了针对训练数据中奇异值的预测模型动态修正法,降低奇异值对模型的影响。为验证本文方法的效果,分别在数据集仿真的实际应用中与现有的在线预测方法进行比较。从实验结果中可以看出,本文方法相较于其他方法,能够更好地克服动态数据中噪声和奇异点带来的影响,达到更高的预测精度。同时算法的动态更新时间能很好地满足实时流预测的应用要求。

1 算法总体架构

ELM 属于一种单层前馈神经网络[37],其结构如图 1 所示。该结构具体由以下 3 部分组成。

1)输入层:包含带预测对象的实时数据信息 $\boldsymbol{x}=\{x_1,x_2,\cdots x_i,\cdots,x_n\}$,其中 x_i 为第 i 维数据输入。

2)隐藏层:由神经网络中的隐藏层节点组成 $(\boldsymbol{W},\boldsymbol{b})=\{(\boldsymbol{W}_j,b_j)\}$,其中 $\boldsymbol{W}_j$ 为第 j 个节点的权值,b_j 为第 j 个节点的偏置系数。在 *ELM* 的生成过程中,隐藏层的各参数可直接随机生成,且在后续的训练中无需进行调整。根据输入层的数据,可以采用 Sigmoid 激活函数得到隐藏层各个节点的输出 h_j。

$$h_j=\frac{1}{1+\mathrm{e}^{(1-Wx-b)}} \tag{1}$$

3)输出层:根据不同的输出准则,可直接计算出输出层的权重。对于单输出的神经网络,输出层权重可以表示为 $\beta=\{\beta_1,\beta_2,\cdots,\beta_k,\cdots,\beta_L\}$,其中 β_k 为第 k 个隐藏层输出对应的输出层权重。通过输出层,得到的模型预测值如下:

$$y=\sum_{k=1}^{L}\beta_k h_k \tag{2}$$

预测值的误差 e 计算如下:

$$e=t-y \tag{3}$$

其中 t 为当前数据的真实输出。

由 ELM 的结构可以看出,对于 ELM 的训练着重于输出层的产生。大多数 ELM 算法通过最小均方准则建立输出层训练的代价函数 J_{MSE}。

$$J_{\mathrm{MSE}}=\min_{\beta}\left[\sum_{i=1}^{N}(y_i-t_i)^2+\lambda\|\beta\|\right] \tag{4}$$

式中:y_i 为第 i 个历史数据的预测值;t_i 为第 i 个样本的真实值;λ 为正则化参数。

通过对 J_{MSE} 求导得出隐藏层的计算方法。

$$\boldsymbol{\beta}=(\boldsymbol{H}^{\mathrm{T}}\boldsymbol{H}+\boldsymbol{\lambda I})^{-1}\boldsymbol{H}^{\mathrm{T}}\boldsymbol{T} \tag{5}$$

式中:$\boldsymbol{T}=\{t_1,t_2,\cdots,t_N\}$;$\boldsymbol{H}$ 为各个样本隐藏层输出组成的矩阵。

$$\boldsymbol{H}=\begin{bmatrix}\dfrac{1}{1+\exp[1-(\boldsymbol{W}_1\boldsymbol{x}_1+b_1)]} & \dfrac{1}{1+\exp[1-(\boldsymbol{W}_M\boldsymbol{x}_1+b_M)]}\\ \dfrac{1}{1+\exp[1-(\boldsymbol{W}_1\boldsymbol{x}_N+b_N)]} & \dfrac{1}{1+\exp[1-(\boldsymbol{W}_M\boldsymbol{x}_N+b_M)]}\end{bmatrix} \tag{6}$$

尽管通过最小均方(minimum mean square error, MMSE)训练的模型具有较好的预测效果,然而该准则假设误差满足高斯分布,因此算法容易受到数据中非高斯噪声的影响。同时,最小均方准则属于一种全局的评估方式,预测误差不同的样本给模型训练带来的影响相同,这进一步导致了噪声和奇异点对于模型的不良影响。

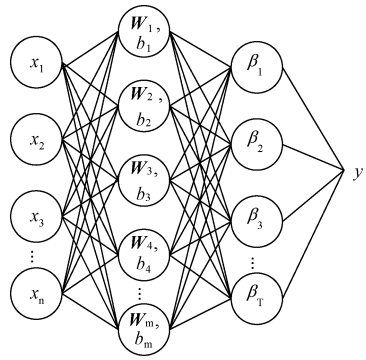

图 1 ELM 结构

Fig.1 The structure of ELM

$$J_{\mathrm{RCC}}=\min_{\beta}\left[\sum_{i=1}^{N}k(y_i-t_i)+\lambda\|\beta\|\right] \tag{7}$$

其中 $k(t_i-y_i)$ 为相关熵关于第 i 个样本的核函数,在这里采用高斯核函数表示。

$$k(y_i,t_i)=e^{\left(-\frac{(t_i-y_i)^2}{2\sigma^2}\right)} \tag{8}$$

该相关熵核函数对于不同误差样本的评估效果如图 2 所示。可以看出,在同参数条件下,$k(t_i-y_i)$ 对于不同误差取值 e 下的样本产生的核函数数值不同。同时,误差大的样本产生的相关熵函数取值越小,代表该类样本在代价函数中对预测模型产生的影响相较于误差较小的样本低。通过这样的方式,相关熵评估避免了误差和奇异值对于代价函数的影响,进而提升了算法的鲁棒性,达到局部评估的目的。

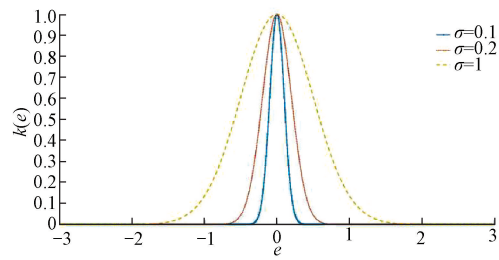

图 2 相关熵核函数影响

Fig.2 The effect of correntropy kernels

由半二次优化,存在一个共轭凸函数 φ,使得:

$$k(y_i,t_i)=\sup_{\alpha\in R^-}\left(\alpha\frac{(y_i-t_i)^2}{2\sigma^2}-\varphi(\alpha)\right) \tag{9}$$

其中 $\alpha=-k(y_i,t_i)$。

将式(9)代入式(7),得到新的代价函数。

$$\tilde{J}_{\mathrm{RCC}}=\min_{\beta}\left[\sum_{i=1}^{N}\left(\alpha_i\frac{(t_i-y_i)^2}{2\sigma^2}-\varphi(\alpha_i)\right)-\lambda\|\beta\|\right] \tag{10}$$

对(9)进行求导后得到输出层的计算公式:

$$\boldsymbol{\beta} = (\boldsymbol{H}^{\mathrm{T}}\boldsymbol{\Lambda}\boldsymbol{H} - \lambda\boldsymbol{I})^{-1}\boldsymbol{H}^{\mathrm{T}}\boldsymbol{\Lambda}\boldsymbol{T} \tag{11}$$

式中:$\boldsymbol{\Lambda}$ 为对角矩阵,其对角元素为 $\Lambda_{ii} = -k(y_i, t_i)$。

为实现实时流下根据动态数据反映的电子器件退化趋势对预测模型进行动态更新,本文在 RCC-ELM 的基础上,提出了 DSRCC-ELM。在式(11)的基础上,构建出基于相关熵准则的动态更新方法,提升预测模型对实时退化趋势的适应性。同时,进一步降低流数据中奇异值对模型的不良影响,设计了误差编码本,结合 M-估计动态识别流数据中存在的奇异值,并且提出了消除奇异值数据影响的模型修正方法。

本文方法的总体架构如图 3 所示。对于被测件产生的实时流数据,通过 OSRCC-ELM 得到预测的结果。并根据预测信息和后续测试结果的不同对预测模型的权重进行更新。根据新数据的更新结果,修改编码本中的信息,并借助 M-估计更新的阈值动态识别流数据中存在的奇异值。最后,消除奇异值对预测模型的影响,产生新的预测模型用于之后的实时流预测中。

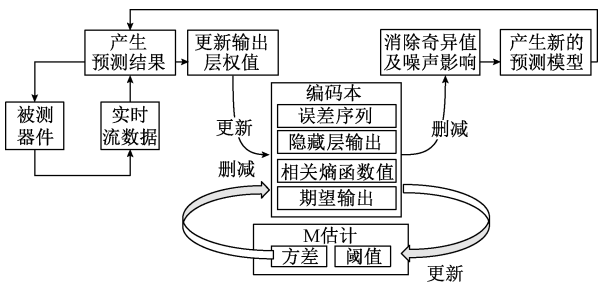

图 3　OSRCC-ELM 架构

Fig.3　The framework of OSRCC-ELM algorithm

综上,算法总体分为离线预测模型建立和实时预测模型的更新两个部分进行。

1)利用历史数据建立基于相关熵的离线预测极限学习机模型,并根据其离线训练结果产生初始编码本。

2)进入实时数据的预测和更新阶段,当实时数据点产生时,通过当前的模型产生未来时刻的预测值。根据算法对于该时刻的预测值,判断该时刻数据是否为有效表征趋势的数据,同时对编码本中存储的数据信息进行评估。利用有效的数据对预测模型进行模型的更新,同时,淘汰编码本与当前趋势不吻合的数据信息并去除该信息对预测模型的影响,产生新的预测模型。

2　实时流下 OSRCC-ELM 输出层的动态更新

对于电子器件的实时诊断,输入数据多为逐条输入的流数据,且要求预测模型能够进行迅速准确的更新。本文结合 RCC-ELM 的特点,提出在不改变隐藏层构造的情况下动态更新预测模型输出层参数的方法,从而适应器件退化趋势的动态变化。

设 p 时刻对应的预测模型输出层为 $\boldsymbol{\beta}_p$,由式(11)可得:

$$\boldsymbol{\beta}_{(p)} = [\boldsymbol{H}_{(p)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p)}\boldsymbol{H}_{(p)}]^{-1}\boldsymbol{H}_{(p)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p)}\boldsymbol{T}_{(p)} = \boldsymbol{K}_{(p)}{}^{-1}\boldsymbol{H}_{(p)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p)}\boldsymbol{T}_{(p)} \tag{12}$$

式中:$\boldsymbol{H}_p$ 为 p 时刻器件退化数据的隐藏层输出。

$$\boldsymbol{H}_{(0)} = \begin{bmatrix} G(a_1,b_1,x_1)\cdots G(a_2,b_2,x_1) & \cdots & G(a_{\tilde{n}},b_{\tilde{n}},x_1) \\ \vdots & \ddots & \vdots \\ G(a_1,b_1,x_N)\cdots G(a_2,b_2,x_N) & \cdots & G(a_{\tilde{n}},b_{\tilde{n}},x_N) \end{bmatrix} \tag{13}$$

$\boldsymbol{\Lambda}_{(p)}$ 为器件退化数据对应的对角矩阵。

$$\boldsymbol{\Lambda}_{(p)} = \begin{bmatrix} \varphi(e_1) & & \\ & \ddots & \\ & & \varphi(e_n) \end{bmatrix} \tag{14}$$

$\boldsymbol{T}_{(p)}$ 为器件退化数据的实际输出。

$$\boldsymbol{T}_{(p)} = \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_N \end{bmatrix} \tag{15}$$

$\boldsymbol{K}_{(p)}$ 为 $\boldsymbol{H}_p$ 的伪逆矩阵,表达为:

$$\boldsymbol{K}_{(p)} = [\boldsymbol{H}_{(p)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p)}\boldsymbol{H}_{(p)} - \lambda\boldsymbol{I}]^{-1} \tag{16}$$

对于 $p+1$ 时刻产生的流数据 (x_{p+1}, t_{p+1}),有:

$$\boldsymbol{\beta}_{(p+1)} = K_{(p+1)}^{-1}\begin{bmatrix}\boldsymbol{H}_{(p)}\\ \boldsymbol{H}_{(p+1)}\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\boldsymbol{\Lambda}_{(p)} & 0\\ 0 & \boldsymbol{\Lambda}_{(p+1)}\end{bmatrix}\begin{bmatrix}\boldsymbol{T}_{(p)}\\ \boldsymbol{T}_{(p+1)}\end{bmatrix} \tag{17}$$

对 $\boldsymbol{K}_{(p+1)}$ 有:

$$\boldsymbol{K}_{(p+1)} = \begin{bmatrix}\boldsymbol{H}_{(p)}\\ \boldsymbol{H}_{(p+1)}\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\boldsymbol{\Lambda}_{(p)} & 0\\ 0 & \boldsymbol{\Lambda}_{(p+1)}\end{bmatrix}\begin{bmatrix}\boldsymbol{H}_{(p)}\\ \boldsymbol{H}_{(p+1)}\end{bmatrix} - \lambda\boldsymbol{I} = \boldsymbol{H}_{(p)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p)}\boldsymbol{H}_{(p)} + \boldsymbol{H}_{(p+1)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{H}_{(p+1)} - \lambda\boldsymbol{I} = (\boldsymbol{H}_{(p)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p)}\boldsymbol{H}_{(p)} - \lambda\boldsymbol{I}) + \boldsymbol{H}_{(p+1)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{H}_{(p+1)} = \boldsymbol{K}_{(p)} + \boldsymbol{H}_{(p+1)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{H}_{(p+1)} \tag{18}$$

同时,对于 $\begin{bmatrix}\boldsymbol{H}_{(p)}\\ \boldsymbol{H}_{(p+1)}\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\boldsymbol{\Lambda}_{(p)} & 0\\ 0 & \boldsymbol{\Lambda}_{(\mathrm{p}+1)}\end{bmatrix}\begin{bmatrix}\boldsymbol{T}_{(p)}\\ \boldsymbol{T}_{(p+1)}\end{bmatrix}$ 有:

$$\begin{bmatrix}\boldsymbol{H}_{(p)}\\ \boldsymbol{H}_{(p+1)}\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\boldsymbol{\Lambda}_{(p)} & 0\\ 0 & \boldsymbol{\Lambda}_{(p+1)}\end{bmatrix}\begin{bmatrix}\boldsymbol{T}_{(p)}\\ \boldsymbol{T}_{(p+1)}\end{bmatrix} = \boldsymbol{H}_{(p)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p)}\boldsymbol{T}_{(p)} + \boldsymbol{H}_{(p+1)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{T}_{(p+1)} = \boldsymbol{K}_{(p)}\boldsymbol{K}_{(p)}{}^{-1}\boldsymbol{H}_{(p)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p)}\boldsymbol{T}_{(p)} + \boldsymbol{H}_{(p+1)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{T}_{(p+1)} = \boldsymbol{K}_{(p)}\boldsymbol{\beta}_{(p)} + \boldsymbol{H}_{(p+1)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{T}_{(p+1)} = \boldsymbol{K}_{(p+1)} - \boldsymbol{H}_{(p+1)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{H}_{(p+1)}\boldsymbol{\beta}_{(p)} + \boldsymbol{H}_{(p+1)}{}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{T}_{(p+1)} \tag{19}$$

将式(18)和(19)代入式(17)可得 OSRCC-ELM 的输出层更新公式:

$$\boldsymbol{\beta}_{(p+1)} = \boldsymbol{K}_{(p)}^{-1}[\boldsymbol{K}_{(p+1)}\boldsymbol{\beta}_{(p)} - \boldsymbol{H}_{(p+1)}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{H}_{(p+1)}\boldsymbol{\beta}_{(p)} + \boldsymbol{H}_{(p+1)}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)}\boldsymbol{T}_{(p+1)}] = \boldsymbol{\beta}_{(p)} + \boldsymbol{K}_{(p+1)}^{-1}\boldsymbol{H}_{(p+1)}^{\mathrm{T}}\boldsymbol{\Lambda}_{(p+1)} \cdot (\boldsymbol{T}_{(p+1)} - \boldsymbol{H}_{(p+1)}\boldsymbol{\beta}_{(p+1)}) \tag{20}$$

3 实时流下 OSRCC-ELM 输出层的奇异值影响消除

对于实际应用中的流数据存在的奇异点,提出了结合误差编码本以及 M-估计的动态奇异值识别方法以及预测模型奇异值影响消除法。该方法通过误差编码本(error codebook, ECB)记录对当前预测模型有效的历史数据的相关信息,通过实时的编码本更新和 M-估计,求得用于识别奇异值的 M 估计阈值。根据 M 估计的阈值,提出误差编码本中存在的奇异值,最后将预测模型受到奇异值的影响剔除。

根据预测模型更新以及 M-估计的相关需求,设计的 ECB 中包括以下 4 个部分。

1)误差序列:包含当前有效样本的误差平方值 $\boldsymbol{We}_{\mathrm{ECB}} = \{e_1^2, e_2^2, \cdots, e_{Lw}^2\}$,其中 $e_i^2 = (y_i - t_i)^2$。

2)隐藏层输出:ECB 中有效样本的隐藏层输出 $\boldsymbol{H}_{\mathrm{ECB}} = \{\boldsymbol{h}_1, \boldsymbol{h}_2, \cdots, \boldsymbol{h}_{Lw}\}$。

3)相关熵函数值:ECB 中各个样本对应的相关熵核评估 $\boldsymbol{K}_{\mathrm{ECB}} = \{k(e_1), K(e_2), \cdots, K(e_{Lw})\}$。

4)期望输出:ECB 中各个样本对应的实际输出 $\boldsymbol{T}_{\mathrm{ECB}} = \{t_1, t_2, \cdots, t_{Lw}\}$

根据 ECB 中的误差序列[30],对预测模型的误差方差做如下估计:

$$\sigma_M = 1.483\,(1 + 5/(Lw - 1))\,\sqrt{med(W_{\mathrm{ECB}})} \tag{21}$$

按照置信度 $\phi(e) = 99\%$,设定 M-估计的阈值 α_M 为:

$$\alpha_M = 2.576\,\sigma_M \tag{22}$$

由 M-估计中的阈值,将 ECB 中存在的奇异值找出并剔除。

$$\boldsymbol{W}^* = \{e_j^2 \mid e_j^2 > \alpha_M^2\} \tag{23}$$

$$\boldsymbol{H}^* = \{h_j \mid e_j^2 > \alpha_M^2\} \tag{24}$$

$$\boldsymbol{K}^* = \{k(e_j) \mid e_j^2 > \alpha_M^2\} \tag{25}$$

$$\boldsymbol{T}^* = \{t_j \mid e_j^2 > \alpha_M^2\} \tag{26}$$

接着,根据剔除的数据,ECB 中包含的隐藏层输出可以表示为 $\begin{bmatrix}\boldsymbol{H}\backslash\boldsymbol{H}^* \\ \boldsymbol{H}^*\end{bmatrix}$,对应的相关熵对角矩阵为 $\begin{bmatrix}\boldsymbol{\Lambda}\backslash\boldsymbol{\Lambda}^* & \mathrm{O} \\ \mathrm{O} & \boldsymbol{\Lambda}^*\end{bmatrix}$ 消除奇异值对输出层权值的影响,根据式(10),当前输出层的权值可表示为:

$$\boldsymbol{\beta} = \boldsymbol{K}^{-1}\begin{bmatrix}\boldsymbol{H}\backslash\boldsymbol{H}^* \\ \boldsymbol{H}^*\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\boldsymbol{\Lambda}\backslash\boldsymbol{\Lambda}^* & 0 \\ 0 & \boldsymbol{\Lambda}^*\end{bmatrix}\begin{bmatrix}\boldsymbol{T}\backslash\boldsymbol{T}^* \\ \boldsymbol{T}^*\end{bmatrix} \tag{27}$$

其中 $\boldsymbol{K} = \begin{bmatrix}\boldsymbol{H} \\ \boldsymbol{H}^*\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\boldsymbol{\Lambda} & \\ & \boldsymbol{\Lambda}^*\end{bmatrix}\begin{bmatrix}\boldsymbol{H} \\ \boldsymbol{H}^*\end{bmatrix} - \lambda\boldsymbol{I}$。

修正后的输出层权值不包含 $\boldsymbol{H}^*$ 的影响,因此可以表示为:

$$\hat{\boldsymbol{\beta}} = \hat{\boldsymbol{K}}^{-1}(\boldsymbol{H}\backslash\boldsymbol{H}^*)^{\mathrm{T}}(\boldsymbol{\Lambda}\backslash\boldsymbol{\Lambda}^*)^{\mathrm{T}} \tag{28}$$

因此对于 $\boldsymbol{K}$ 有:

$$\begin{bmatrix}\boldsymbol{H} \\ \boldsymbol{H}^*\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\boldsymbol{\Lambda}\backslash\boldsymbol{\Lambda}^* & \\ & \boldsymbol{\Lambda}^*\end{bmatrix}\begin{bmatrix}\boldsymbol{H} \\ \boldsymbol{H}^*\end{bmatrix} - \lambda\boldsymbol{I} =$$

$$\boldsymbol{H}^{\mathrm{T}}\boldsymbol{\Lambda}\boldsymbol{H} + \boldsymbol{H}^*\boldsymbol{\Lambda}^*\boldsymbol{H}^* - \lambda\boldsymbol{I} =$$

$$\hat{\boldsymbol{K}} + \boldsymbol{H}^{*\mathrm{T}}\boldsymbol{\Lambda}^*\boldsymbol{H}^*\begin{bmatrix}\boldsymbol{H} \\ \boldsymbol{H}^*\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\boldsymbol{\Lambda}\backslash\boldsymbol{\Lambda}^* & \\ & \boldsymbol{\Lambda}^*\end{bmatrix}\begin{bmatrix}\boldsymbol{T} \\ \boldsymbol{T}^*\end{bmatrix} =$$

$$\boldsymbol{H}^{\mathrm{T}}(\boldsymbol{\Lambda}\backslash\boldsymbol{\Lambda}^*)^{\mathrm{T}} + \boldsymbol{H}^{*\mathrm{T}}\boldsymbol{\Lambda}^*\boldsymbol{T}^* =$$

$$\hat{\boldsymbol{K}}\hat{\boldsymbol{K}}^{-1}\boldsymbol{H}^{\mathrm{T}}(\boldsymbol{\Lambda}\backslash\boldsymbol{\Lambda}^*)^{\mathrm{T}} + \boldsymbol{H}^{*\mathrm{T}}\boldsymbol{\Lambda}^*\boldsymbol{T}^* =$$

$$\hat{\boldsymbol{K}}\hat{\boldsymbol{\beta}} + \boldsymbol{H}^{*\mathrm{T}}\boldsymbol{\Lambda}^*\boldsymbol{T}^* = (\boldsymbol{K} - \boldsymbol{H}^*\boldsymbol{\Lambda}^*\boldsymbol{H}^*)\hat{\boldsymbol{\beta}} + \boldsymbol{H}^{*\mathrm{T}}\boldsymbol{\Lambda}^*\boldsymbol{T}^* \tag{29}$$

将式(29)代入式(27)后可得:

$$\boldsymbol{\beta} = \boldsymbol{K}^{-1}[(\boldsymbol{K} + \boldsymbol{H}^*\boldsymbol{\Lambda}^*\boldsymbol{H}^*)\hat{\boldsymbol{\beta}} + \boldsymbol{H}^{*\mathrm{T}}\boldsymbol{\Lambda}^*\boldsymbol{T}^*] \tag{30}$$

因此,输出层权值可以被修正为:

$$\hat{\boldsymbol{\beta}} = (\boldsymbol{K} - \boldsymbol{H}^{*\mathrm{T}}\boldsymbol{\Lambda}^*\boldsymbol{H}^*)^{-1}(\boldsymbol{K}\boldsymbol{\beta} - \boldsymbol{H}^{*\mathrm{T}}\boldsymbol{\Lambda}^*\boldsymbol{T}^*) \tag{31}$$

预测模型输出层的修正过程如图 4 所示。在预测模型更新之后,按照式(2)更新 ECB 中的误差序列,求出新的 M-估计阈值,根据 M-估计的阈值,检测 ECB 样本中出现的奇异值($\boldsymbol{W}^*, \boldsymbol{H}^*.\boldsymbol{K}^*, \boldsymbol{T}^*$)。最后通过(31)修正输出层的权值。

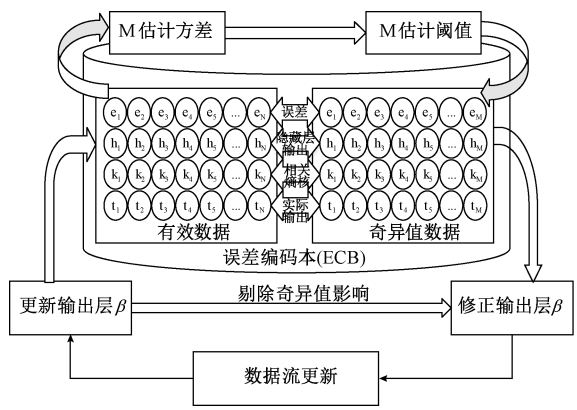

图 4 预测模型输出层的修正过程

Fig.4 The correction process of output layer for the prediction model

4　OSRCC-ELM 算法时间复杂度分析

根据 OSRCC-ELM 算法的相关步骤,对算法的时间复杂度进行分析:首先 OSRCC-ELM 算法的预测模型需要通过一部分离线数据进行训练,设训练数据的个数为 N_l,则该步骤的时间复杂度为 $O(I_H N_l(5M+2M^2))$,其中 I_H 为输出层训练的迭代次数;在数据流预测过程中,得到各个时刻的预测数据需要消耗的时间复杂度为 $O(M^3)$;更新输出层的时间复杂度为 $O(NM^2)$;对 ECB 进行更新的时间复杂度为 $O(NL_wM)$,最后修正输出层的时间复杂度为 $O(L*D^2)$,其中 L^* 为奇异值个数。因此,OSRCC-ELM 的时间复杂度为 $O(I_H N_l(5M+2M^2)+M^{3+}NM^{2+}NL_wM+L*D^2)=O(N^3)$。

表 1 所示为几种预测方法的时间复杂度估计,可以看出,OSRCC-ELM 与其他算法在时间复杂度上具有相同的量级。

表 1　算法时间复杂度比较

Table 1　Comparison on time complexity among algorithms

算法	步骤	时间复杂度
RCC-ELM	离线训练	$O(IHNl(5M+2M^2))$
	实时流数据预测	$O(N(5M+2M^2))$
	算法整体	$O(IHNl(5M+2M2)+N(5M+2M^2))$
ESEP-ELM	离线训练	$O(M^3)$
	实时流数据预测	$O(NM)$
	算法整体	$O(NM+M^3)$
OS-ELM	离线训练	$O(M^3)$
	实时流数据预测	$O(NM^2)$
	算法整体	$O(NM^2+M^3)$
MOS-ELM	离线训练	$O(M^3)$
	实时流数据预测	$O(NM^2)$
	算法整体	$O(NM^2+M^3)$
OSRCC-ELM	离线训练	$O(IHNl(5M+2M^2))$
	实时流数据预测	$O(M^3)$
	输出层更新	$O(NM^2)$
	ECB 更新	$O(NL_wM)$
	输出层修正	$O(L*D^2)$
	算法整体	$O(I_H N_l(5M+2M^2)+M^{3+}NM^{2+}NL_wM+L*D^2)=O(N^3)$

同时,OSRCC-ELM 大部分的时间消耗在离线训练阶段,其实时预测与更新的时间复杂度为 $O(M3)$ 与 $O(NM2)$。在相对于实时更新的情况下,实施训练数据量 M 相对 N 较小,因此实时更新与预测的时间复杂度相对离线训练较低。同时,在实时训练过程中多采用实时给出预测结果后立即更新模型的方式,在该方式下单次样本预测的时间复杂度为 $O(1)$,单次模型更新的时间复杂度为 $O(N)$,满足大部分工程应用的需求。

5　OSRCC-ELM 算法在典型指数退化信号中的实验验证

为验证 OSRCC-ELM 的实际效果,采用典型指数退化数据[31]进行验证。6 组数据集的模型形式如下所示。

$$Y(t)=\varphi+\theta e^{|\beta t+\varepsilon(t)-\frac{\sigma^2}{2}|} \tag{32}$$

式中:$Y(t)$ 表示作为连续随机过程的退化信号,相对于时间 t 是连续的;φ 是常数确定性参数;θ 是对数正态随机变量;其中 $\ln\theta$ 的均值为 μ_0;方差为 σ_0^2;β 为具有均值 μ_1 和方差 σ_1^2 的正态随机变量;而 $\varepsilon(t)$ 是具有均值 0 和方差 σ^2 的正态分布随机误差项。令模型参数 $\varphi=0.12$,$\mu_0=0.05$,$\sigma_0^2=2.5\times10^{-7}$,$\mu_1=0.011$,$\sigma_1^2=1\times10^{-8}$ 和 $\sigma^2=1\times10^{-6}$。

为更好地评估算法的预测效果,本文将 OSRCC-ELM 与几个典型的预测算法(RCC-ELM, ESEP-ELM, OS-ELM,MOS-ELM 以及典型单层机器学习方法 RVM)进行比较。所有算法均运行于 MATLAB 2017b 软件环境下。

各个算法在不同数据集下的训练精度和预测精度如表 2 所示。通过表 2 可以看出,由于 ELM 算法的高适应性,所有方法均可以达到很好的训练精度。然而,在实时流预测部分,RCC-ELM 在每个数据集上的预测精度均不如其他方法,这是由于离线训练时 RCC-ELM 无法对被测对象的动态趋势进行准确的估计。相比之下,OS-ELM 能够更好地进行预测。

与 OS-ELM 不同的是,在 M 估计的作用下,MOS-ELM 在这各样本中具有很高的预测精度。同时 ESEP-ELM 与 OSRCC-ELM 由于对实时训练中的不同样本进行了很好的局部评估,因此能够达到很高的预测结果。OSRCC-ELM 结合了相关熵高鲁棒性的优点,同时通过 ECB 达到动态识别奇异点的效果,因此几乎在所有数据集上都具有最高的预测精度。

图 5 所示为各算法样本 6 预测实际情况。从图 5 可以看出,5 种方法都在一定程度上对实时数据的特征进行了准确估计。OS-ELM、MOS-ELM 和 OSRCC-ELM 的预测曲线均基本符合实际数据的变化趋势。然而,在 590 个时间点之后,RCC-ELM、ESEP-ELM 和 OS-ELM 的预测曲线与实际曲线产生了较大的偏差,这可能是由于实时流中噪声的影响。相比之下,MOS-ELM 与 OSRCC-ELM 在该时间段内具有更高的预测能力,预测曲线与实际

表 2 算法预测精度对比

Table 2 Comparison on prediction accuracy among algorithms

数据		样本 1	样本 2	样本 3	样本 4	样本 5	样本 6
RVM	训练精度	1.33×10^{-3}	2.26×10^{-02}	1.25×10^{-2}	1.24×10^{-3}	1.03×10^{-2}	1.86×10^{-2}
	预测精度	4.92×10^{-2}	4.59×10^{-1}	4.95×10^{-4}	4.23×10^{-1}	5.53×10^{-1}	4.67×10^{-1}
RCC-ELM	训练精度	**1.15×10^{-3}**	**1.94×10^{-8}**	**1.86×10^{-8}**	**2.36×10^{-8}**	4.92×10^{-3}	2.28×10^{-3}
	预测精度	9.92×10^{-2}	8.14×10^{-2}	9.48×10^{-2}	8.33×10^{-2}	5.85×10^{-2}	5.17×10^{-2}
ESEP-ELM	训练精度	2.55×10^{-3}	9.92×10^{-4}	2.82×10^{-7}	1.47×10^{-3}	3.28×10^{-3}	1.52×10^{-3}
	预测精度	9.76×10^{-3}	2.11×10^{-3}	2.04×10^{-3}	1.69×10^{-2}	4.07×10^{-3}	4.25×10^{-3}
OSELM	训练精度	2.06×10^{-3}	1.33×10^{-3}	1.33×10^{-3}	2.80×10^{-3}	**2.36×10^{-3}**	2.56×10^{-3}
	预测精度	3.18×10^{-3}	2.30×10^{-3}	2.59×10^{-3}	3.82×10^{-3}	5.92×10^{-3}	**2.58×10^{-3}**
MOS-ELM	训练精度	2.45×10^{-3}	9.92×10^{-4}	2.82×10^{-7}	1.47×10^{-3}	3.28×10^{-3}	**1.52×10^{-3}**
	预测精度	2.04×10^{-3}	2.73×10^{-3}	2.01×10^{-3}	3.68×10^{-2}	2.18×10^{-3}	3.35×10^{-3}
OSRCC-ELM	训练精度	2.45×10^{-3}	9.92×10^{-4}	3.54×10^{-3}	1.47×10^{-3}	3.28×10^{-3}	**1.52×10^{-3}**
	预测精度	**2.03×10^{-3}**	**1.98×10^{-3}**	**2.01×10^{-3}**	**3.65×10^{-3}**	**2.04×10^{-3}**	2.73×10^{-3}

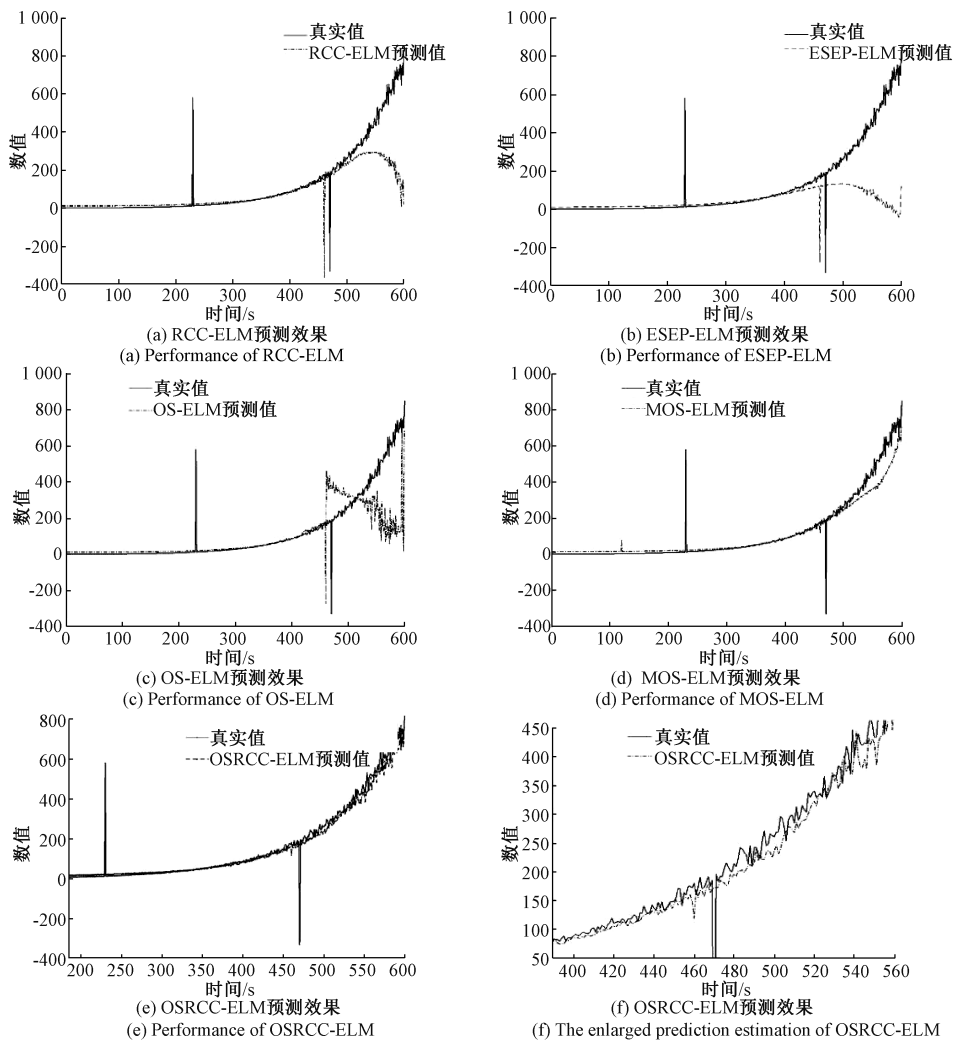

图 5 预测效果比较

Fig.5 Comparison on prediction performance

曲线的偏差较小。在 460 s 奇异值数据出现之后,OS-ELM的预测效果均受到了不同程度的影响,然而 OSRCC-ELM 的预测的精度保持稳定,因此本方法相较于现有方法对含奇异值信号仍具有很好的预测效果。图 6 所示为几种算法的训练时间与预测时间,从图 6 中可以看出几种算法的训练时间与预测时间相当。因此 OSRCC-ELM 相比之下具有更高的预测效率。

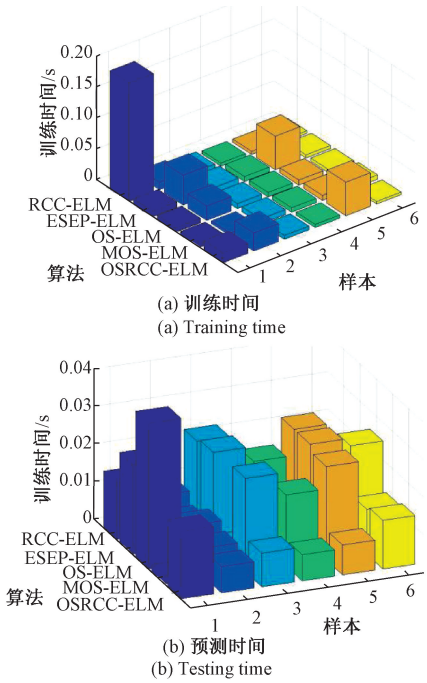

图 6　各算法离线训练时间与在线预测时间比较

Fig.6　Comparison on offline training time consumption and online predicting time consumption

6　OSRCC-ELM 算法在光电耦合器退化趋势预测上的应用

为进一步验证算法在实际应用中的效果,本节将 OSRCC-ELM 用于光电耦合器的退化趋势预测中。光电耦合器(optical coupler, OC)是一种常用电子元件,可以光为媒介的传输电信号,实现电能-光能-电能的转换,从而隔离输入和输出信号。OC 的工作电路如图 7 所示,其中工作电压下发光二极管中的电流与光敏三极管的电流的比值被定义为电流传输比(current transfer ratio, CTR),是用于衡量 OC 可靠性的重要指标。当 CTR 小于 50%时,OC 功耗增加,从而影响器件的正常输出。同时,伴随 OC 的使用时间变长,CTR 会逐渐降低产生退化。因此,对于 CTR 的实时预测在 OC 的健康管理中起到了重要的作用。

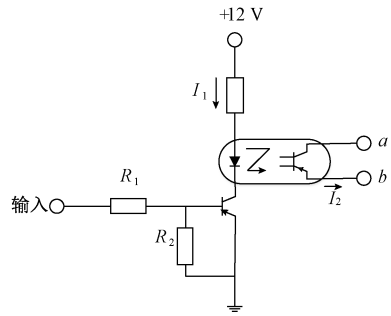

图 7　OC 工作电路

Fig.7　The operating circuit of OC

本文对贮存状态下的 GD310 系列 OC 进行了 CTR 实时预测。通过图 8 所示各模型产生的预测曲线比较可以看出,对于单步预测,ELM 模型相较于 RVM 模型在精度上有明显的优势,离线预测方法 RCC-ELM 由于仅对离线数据进行了训练,因此无法准确捕捉光电耦合器在退化时的数据规律,因此几乎无法进行可靠的预测。ESEP-ELM、OSELM、MOS-ELM 可以有效的对模型进行合理预测,然而受到数据中的噪声影响,预测结果波动较大,在部分节点上存在较大的误差。相较而言,本文方法克服了噪声的影响,但不预测可以达到 9.65×10^{-5} 的精度,预测曲线能够准确地反映故障的退化趋势,且预测曲线无较大的波动,预测效果稳定。

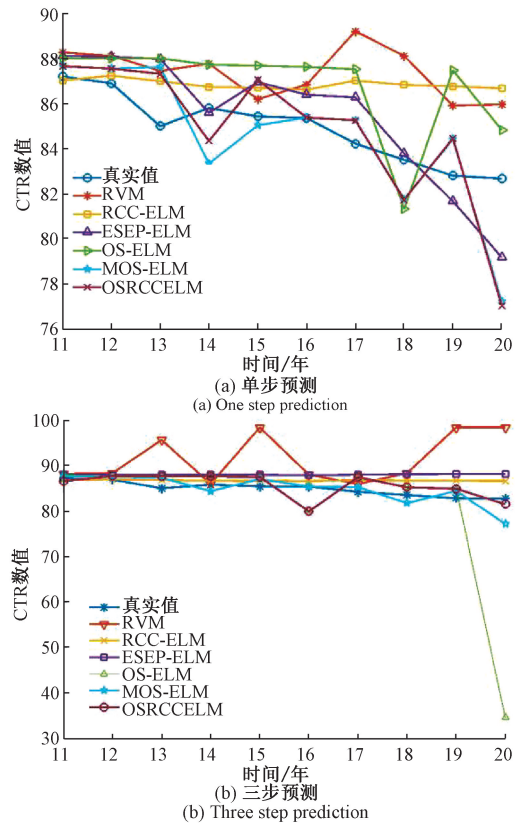

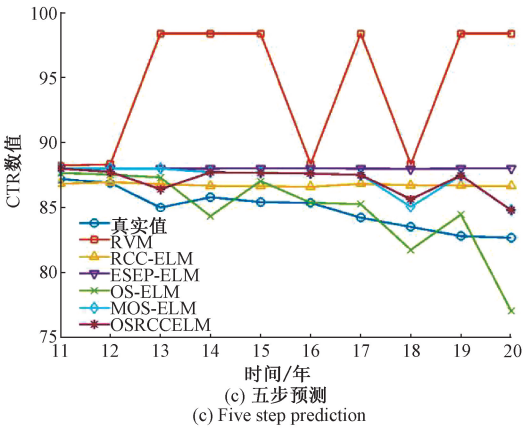

(c) 五步预测
(c) Five step prediction

图 8 预测效果比较

Fig.8 Comparison on prediction performance

同时,在三步预测和五步预测中,OSRCC-ELM 相较于其他算法,具有更加稳定的预测效果。然而,对于五步预测,受到训练样本个数和累计预测误差的影响,算法的预测精度受到一定的影响。

OSRCC-ELM 算法与相关算法的预测精度和时间消耗如表 3 所示。从精度指标上来看,ELM 模型的算法相较于 RVM 模型有较高的优势,在预测时间上几种算法的预测效果相当。尽管 RCC-ELM 在部分多步预测中具有最快的预测速度,然而其预测误差随着预测步数的增加出现了明显的上升。综合来看,OSRCC-ELM 在多数情况下能在较短的时间内达到最优的预测精度。

表 4 所示为 OSRCC-ELM 的预测值与真实值之间的对比效果。由表 4 可以看出 OSRCC-ELM 可以有效地给出 CTR 的预测值,且在五步预测的范围内能达到很高的精度。同时,对于 OSRCC-ELM 在各个时间点下的预测时间极短,可以达到在线预测的应用要求。图 9 所示为 OSRCC-ELM 在多步预测下的预测效果,可以看出,算法在一至五步预测下能达到较高的预测精度,预测结果基本反映光电耦合器 CTR 的变化趋势。图 10 比较了各个方法对各样本的预测误差,可以看出,5 种方法在前 5 个样本点上的预测误差均较低,然而在后面的样本点信息可以看出 RVM, RCC-ELM, ESEP-ELM, OSELM 和 MOS-ELM 均出现了预测精度降低的现象,而 OSRCC-ELM 的预测精度相对稳定,说明了算法具有稳定反映数据变化趋势的能力,提供可靠的预测结果。

表 3 算法精度与时间比较

Table 3 Comparison on accuracy and time consumption among algorithms

算法		RVM	RCC-ELM	ESEP-ELM	OSELM	MOSELM	OSRCCELM
离线训练精度	训练精度	4.73×10^{-3}	4.68×10^{-5}	1.88×10^{-4}	4.61×10^{-5}	4.68×10^{-5}	4.61×10^{-5}
	训练时间/s	6.986×10^{-1}	2.972×10^{-1}	5.113×10^{-2}	8.15×10^{-3}	3.764×10^{-2}	9.64×10^{-3}
单步预测精度	实时预测精度	1.12×10^{-1}	6.76×10^{-4}	2.62×10^{-4}	1.91×10^{-4}	1.88×10^{-4}	9.65×10^{-5}
	预测时间/s	3.08×10^{-1}	3.47×10^{-2}	3.462×10^{-2}	5.085×10^{-1}	$5.580\ 3\times10^{-1}$	$4.539\ 4\times10^{-1}$
二步预测精度	实时预测精度	1.17×10^{-1}	1.33×10^{-3}	7.78×10^{-2}	6.17×10^{-4}	1.40×10^{-3}	3.43×10^{-4}
	预测时间/s	2.53×10^{-1}	1.09×10^{-2}	8.67×10^{-2}	5.85×10^{-2}	4.18×10^{-2}	2.16×10^{-3}
三步预测精度	实时预测精度	1.04×10^{-1}	1.75×10^{-3}	3.38×10^{-1}	5.10×10^{-3}	4.17×10^{-2}	5.74×10^{-4}
	预测时间/s	2.683×10^{-1}	1.21×10^{-2}	2.56×10^{-2}	1.421×10^{-1}	$6.792\ 9\times10^{-2}$	2.85×10^{-3}
四步预测精度	实时预测精度	1.17×10^{-1}	2.07×10^{-3}	8.18×10^{-1}	8.00×10^{-4}	4.90×10^{-3}	9.86×10^{-4}
	预测时间/s	$2.881\ 8\times10^{-1}$	2.78×10^{-2}	3.42×10^{-2}	5.66×10^{-2}	7.32×10^{-2}	2.279×10^{-3}
五步预测精度	实时预测精度	1.41×10^{-1}	3.17×10^{-3}	1.60×10^{-2}	1.30×10^{-3}	1.99×10^{-3}	1.40×10^{-3}
	预测时间/s	2.462×10^{-1}	9.45×10^{-3}	2.74×10^{-2}	5.12×10^{-2}	7.78×10^{-2}	1.398×10^{-2}
六步预测精度	实时预测精度	1.62×10^{-1}	4.82×10^{-3}	2.78×10^{0}	2.00×10^{-3}	4.13×10^{0}	1.90×10^{-3}
	预测时间/s	3.31×10^{-1}	7.73×10^{-3}	3.09×10^{-2}	6.658×10^{-2}	2.11×10^{-2}	3.83×10^{-3}
七步预测精度	实时预测精度	1.05×10^{-1}	7.10×10^{-3}	4.50×10^{0}	2.70×10^{-3}	8.19×10^{0}	2.40×10^{-3}
	预测时间	3.62×10^{-1}	3.44×10^{-2}	2.92×10^{-2}	1.184×10^{-2}	1.50×10^{-2}	2.57×10^{-4}
八步预测精度	实时预测精度	4.41×10^{-1}	9.47×10^{-3}	7.01×10^{0}	2.90×10^{-3}	2.40×10^{-3}	2.80×10^{-3}
	预测时间/s	4.01×10^{-1}	9.50×10^{-3}	1.98×10^{-2}	5.62×10^{-3}	7.60×10^{-3}	2.71×10^{-3}

表 4　OSRCC-ELM 的预测效果

Table 4　Prediction performance of OSRCC-ELM

参数		时间点									
		11	12	13	14	15	16	17	18	19	20
实际值		87.2	86.9	85	85.8	85.43	85.36	84.23	83.51	82.805 3	82.676 1
一步预测	预测时间/s	1.53×10^{-3}	1.50×10^{-4}	1.10×10^{-5}	2.10×10^{-5}	1.60×10^{-5}	2.90×10^{-5}	2.80×10^{-5}	1.60×10^{-5}	1.60×10^{-5}	1.70×10^{-5}
	预测值	87.655 216 94	87.547 4	87.319 14	84.340 86	87.046 91	85.379 58	85.259 74	81.742 33	84.465 51	77.057 76
	误差	0.455 216 944	0.647 396	2.319 14	−1.459 142	1.616 909	0.019 581	1.029 744	−1.767 67	1.660 206	−5.618 344
二步预测	预测时间/s	1.70×10^{-5}	8.20×10^{-4}	4.30×10^{-4}	1.10×10^{-5}	1.90×10^{-5}	1.50×10^{-5}	1.50×10^{-4}	1.90×10^{-5}	1.30×10^{-5}	1.30×10^{-5}
	预测值	87.715 233 79	87.677 35	87.612 82	87.477 97	83.055 22	87.505 32	85.307 94	85.111 62	74.092 02	85.909 08
	误差	0.515 233 794	0.777 346	2.612 821	1.677 969	−2.374 784	2.145 32	1.077 94	1.601 621	−8.713 277	3.232 975
三步预测	预测时间/s	1.50×10^{-5}	1.60×10^{-5}	1.24×10^{-3}	2.20×10^{-5}	1.00×10^{-5}	1.80×10^{-5}	1.20×10^{-5}	3.40×10^{-5}	2.10×10^{-5}	1.70×10^{-5}
	预测值	86.572 709 3	87.715 44	87.677 65	87.618 06	87.514 14	79.909 79	87.469 99	85.203 89	84.883 3	81.492 7
	误差	−0.627 290 7	0.815 443	2.677 654	1.818 064	2.084 137	−5.450 211	3.239 993	1.693 891	2.078 004	−1.183 404
四步预测	预测时间/s	1.20×10^{-5}	1.50×10^{-5}	1.60×10^{-5}	1.19×10^{-3}	1.80×10^{-5}	4.40×10^{-5}	1.70×10^{-5}	1.10×10^{-5}	2.20×10^{-5}	1.80×10^{-5}
	预测值	87.750 396 33	86.502 94	87.715 44	87.677 66	87.618 39	87.520 52	81.710 21	87.476 63	85.048 07	84.509 27
	误差	0.550 396 327	−0.397 058	2.715 444	1.877 657	2.188 387	2.160 525	−2.519 79	3.966 63	2.242 765	1.833 174
五步预测	预测时间/s	1.60×10^{-5}	1.20×10^{-5}	1.30×10^{-5}	1.50×10^{-5}	2.74×10^{-3}	1.20×10^{-5}	2.50×10^{-5}	8.30×10^{-5}	1.10×10^{-5}	2.60×10^{-5}
	预测值	88.004 499 42	87.751 81	86.407 47	87.715 44	87.677 66	87.618 41	87.521 58	85.641 3	87.475 43	84.804 28
	误差	0.804 499 417	0.851 808	1.407 466	1.915 444	2.247 657	2.258 406	3.291 582	−2.151 303	4.670 133	2.128 176

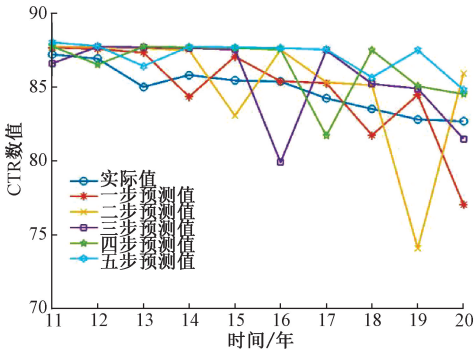

图 9　光电耦合器多步预测效果比较

Fig.9　The multi-step prediction accuracy comparison on OC

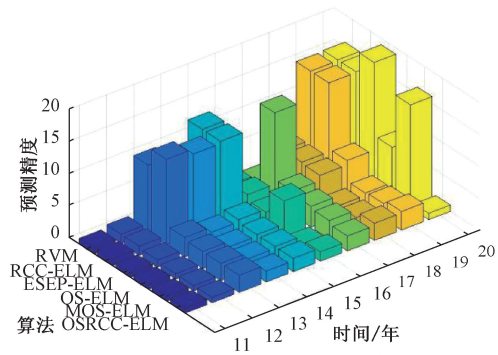

(b) 三步预测

(b) Three step prediction

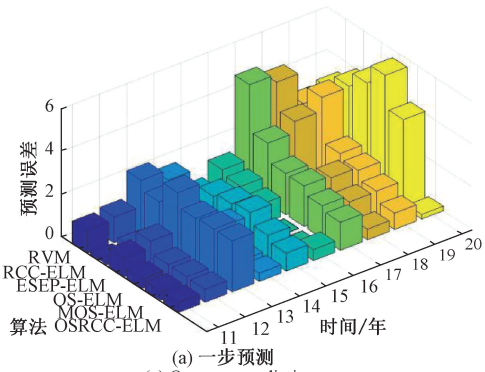

(a) 一步预测

(a) One step prediction

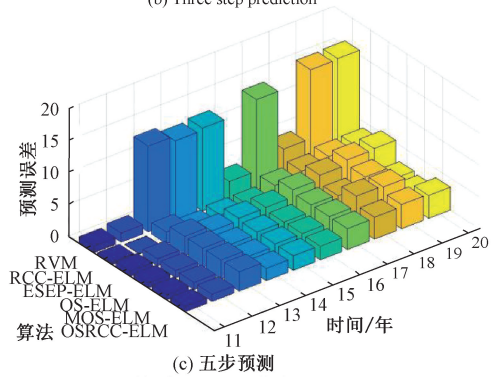

(c) 五步预测

(c) Five step prediction

图 10　光电耦合器的预测精度比较

Fig.10　The prediction accuracy comparison on OC

7 结 论

本文针对电子器件故障趋势实时流预测中对预测趋势准确性和预测模型更新快速性的要求,提出了 OSRCC-ELM 方法。借助相关熵对器件实时数据的局部性评估,有效地降低了数据中奇异值和噪声对预测模型的影响。并在此基础上建立了预测模型的动态更新方法,在实时流预测过程中,对 ELM 的输出层进行快速更新。同时,为了进一步避免器件数据中奇异值对预测模型的干扰,建立了误差编码本记录影响模型的相关样本,并根据 M-估计中的阈值隔离奇异值信息,再将这一部分信息对模型的影响提出,从而提升算法的鲁棒性。为验证本方法的效果,分别在数据集仿真的实际应用中与现有的在线预测方法进行比较。从实验结果中可以看出,相较于其他方法,本文方法能够更好地克服动态数据中噪声和奇异点带来的影响,达到更高的预测精度。同时算法的动态更新时间能很好地满足实时流预测的应用要求。

参考文献

[1] 丁家满,原琦,任东磊,等.不确定性信息条件下系统可靠性分析[J]. 仪器仪表学报,2019,40(4):153-162.
DING J M, YUAN Q, REN D L. System reliability analysis under uncertain information[J]. Chinese Journal of Scientific Instrument,2019,40(4):153-162.

[2] 邱伟,唐求,刘旭明,等.基于 MBBS 的电能计量设备故障率预估[J]. 仪器仪表学报,2019,40(1):43-51.
QIU W,TANG Q,LIU X M,et al. Estimation of failure rate of energy metering equipment based on MBBS[J]. Chinese Journal of Scientific Instrument, 2019, 40(1): 43-51.

[3] 阳洋,周财红,王岩,等.基于统计矩理论的框架结构检测技术研究[J]. 仪器仪表学报,2019,40(1):183-191.
YANG Y,ZHOU C H,WANG Y,et al. Research on frame structure detection technology based on statistical moment theory[J]. Chinese Journal of Scientific Instrument, 2019,40(1):183-191.

[4] 张宝珍,王萍,尤晨宇.国内外飞机预测与健康管理技术发展计划综述[J].计算机测量与控制,2016,24(6):1-7.
ZHANG B ZH, WANG P, YOU CH Y. Summary of domestic and international aircraft forecasting and health management technology development plans[J]. Computer Measurement & Control,2016,24(6):1-7.

[5] 周晨程,李军. 城轨车辆电气柜故障诊断方法研究[J]. 计算机测量与控制,2017,25(10):23-26.
ZHOU CH CH,LI J. Research on fault diagnosis method of urban rail vehicle electrical cabinet[J]. Computer Measurement & Control,2017,25(10):23-26.

[6] 邓宁,宋森森,羿昌宇. 软件无线电系统综合诊断平台设计与实现[J]. 电子测量与仪器学报,2016,29(6):968-974.
DENG N, SONG S S, YI CH Y. Design and implementation of software radio system integrated diagnostic platform [J]. Journal of Electronic Measurement and Instrumentation,2016,29(6):968-974.

[7] 年夫顺. 关于故障预测与健康管理技术的几点认识[J]. 仪器仪表学报,2018,39(8):1-14.
NIAN F SH. Some understandings about fault prediction and health management technology[J]. Chinese Journal of Scientific Instrumentation,2018,39(8):1-14.

[8] 姚芳,马静,唐圣学,等. IGBT 模块键合损伤机理、演化规律及状态监测[J]. 仪器仪表学报,2019,40(4):88-99.
YAO F,MA J,TANG SH X,et al. IGBT module bonding damage mechanism, evolution law and condition monitoring[J]. Chinese Journal of Scientific Instrument, 2019,40(4):88-99.

[9] 吴天舒,陈蜀宇,吴明.基于应力波分析的状态监控与故障预测研究[J]. 仪器仪表学报,2017,38(12):3061-3070.
WU T SH,CHEN SH Y,WU M. Research on condition monitoring and fault prediction based on stress wave analysis[J]. Chinese Journal of Scientific Instrument, 2017,38(12):3061-3070.

[10] 梁远远,杨生胜,文轩,等.脉冲涡流无损检测中缺陷定量化技术研究[J]. 仪器仪表学报,2018,39(11):70-78.
LIANG Y Y,YANG SH SH,WEN X,et al. Research on defect quantification technology in pulsed eddy current nondestructive testing[J]. Chinese Journal of Scientific Instrument,2018,39(11):70-78.

[11] MOHAMMAND S, SURESH P, ALIREZA A, et al. Developing prognostic models using duality principles for DC-to-DC converters [J]. IEEE Trans Power Elect, 2015,30(5):2872-2884.

[12] DAEIL K, JEONGAH Y. A model-based prognostic approach to predict interconnect failure using impedance analysis [J]. Journal of Mechanical Science and Technology, 2016,30(10):4447-4452.

[13] 许丽佳,龙兵,王厚军.基于 LSSVM-HMM 的发射机故障预测研究[J].仪器仪表学报,2008,29(1):21-26.
XU L J,LONG B,WANG H J. Research on transmitter fault prediction based on LSSVM-HMM [J]. Chinese Journal of Scientific Instrument,2008,29(1):21-26.

[14] 胡友涛,胡昌华.一种基于 GA 优化小波 LS-SVR 的实

时寿命预测方法[J]. 南京航空航天大学学报,2011,43(S):203-206.
HU Y T, HU CH H. A real-time life prediction method based on GA optimized wavelet LS-SVR[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2011,43(S):203-206.

[15] 刘月峰,赵光权,彭喜元. 锂离子电池循环寿命的融合预测方法[J]. 仪器仪表学报,2015,36(7):1462-1469.
LIU Y F, ZHAO G Q, PENG X Y. Fusion prediction method for cycle life of lithium ion battery[J]. Chinese Journal of Scientific Instrument,2015,36(7):1462-1469.

[16] 余永维,杜柳青. 深度学习框架下数控机床运动误差溯因方法[J]. 仪器仪表学报,2019,40(1):28-34.
YU Y W, DU L Q. Tracing method of motion error of CNC machine tools under deep learning framework [J]. Chinese Journal of Scientific Instrument, 2019, 40(1): 28-34.

[17] 施文,陆宁云,姜斌,等. 数据驱动的地铁车门微小故障智能诊断方法[J]. 仪器仪表学报,2019,40(6):192-201.
SHI W, LU N Y, JIANG B, et al. Data-driven intelligent diagnosis method for small faults of subway doors[J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 192-201.

[18] LIU H, MI X W, LI Y F, et al. Smart wind speed deep learning based multi-step forecasting model using singular spectrum analysis, convolutional gated recurrent unit network and support vector regression[J]. Renewable Energy,2019,143:842-854.

[19] PETER O'D, COLM G, KEVIN L, et al. A comparison of fog and cloud computing cyber-physical interfaces forIndustry4.0 real-time embedded machine learning engineering applications[J]. Computers in Industry, 2019,110:12-35.

[20] SADEKLA I, JACKEY K, KEVIN L, et al. Empirical prediction models for adaptive resource provisioning in the cloud[J]. Future Generation Computer Systems, 2012,28:155-162.

[21] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006,70:489-501.

[22] ZHANG CH, LIM P, QIN A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2306-2318.

[23] YONGBIN L, BING H, FANG L, et al. Remaining useful life prediction of rolling bearings using PSR, JADE and extreme learning machine[J]. Mathematical Problems in Engineering,2016:1-13.

[24] WAN J, TANG S, LI D, et al. A manufacturing big data solution for active preventive maintenance[J]. IEEE Transactions on Industrial Informatics, 2017, 13(4): 2039-2047.

[25] 李耀华,尚金秋.基于云计算的飞机 PHM 体系架构研究[J]. 计算机工程,2017,43(12):6-10.
LI Y H, SHANG J Q. Research on aircraft PHM architecture based on cloud computing[J]. Computer Engineering,2017,43(12):6-10.

[26] 黄予春,曹成涛,顾海.基于云计算和深度学习的电力电容器故障诊断和识别[J]. 电力电容器与无功补偿,2018,39(4):71-75.
HUANG Y CH, CAO CH T, GU H. Fault diagnosis and identification of power capacitors based on cloud computing and deep learning[J]. Power Capacitor Reactive Power Compensation,2018,39(4):71-75.

[27] 胡友涛,胡昌华,孔祥玉,等.基于 WSVR 和 FCM 聚类的实时寿命预测方法[J]. 自动化学报,2012,38(3):331-340.
HU Y T, HU CH H, KONG X Y, et al. Real-time life prediction method based on WSVR and FCM clustering[J]. Acta Automatica Sinica, 2012, 38(3): 331-340.

[28] LIANG N Y, HAUNG G B, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithm for feedforward networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2006,17(6):1411-1423.

[29] YIN H B, Y Y AN. Online transfer learning with extreme learning machine [C]. International Conference on Meterials Science, 2017, 020199.

[30] LU F, WU J, HUANG J, et al. Aircraft engine degradation prognostics based on logistic regression and novel OS-ELM algorithm[J]. Aerospace Science and Technology, 2018,84:661-671.

[31] RAZAVIFAR R, CHAKRABARTI S, SAIF M. Multi-step Parallel-Strategy for estimating the remaining useful life of batteries[J]. 30th Annual IEEE Canadian Conference on Electrical and Computer Engineering, 2017:1-4, doi: 10.1109/CCECE.2017.7946748.

[32] BADONG C, LEI X, NANNING Z, et al. Quantized minimum error entropy criterion[J]. IEEE Transactions on Neural Networks and Learning Systems,2017,40(6): 192-201.

[33] SUN L, CHEN B, TOH K A, et al. Sequential extreme

learning machine incorporating survival error potential[J]. Neurocomputing, 2015, 155:194-204.

[34] XING H J, WANG X M. Training extreme learning machine via regularized correntropy criterion[J]. Neural Computing and Applications, 2013, 23 (7-8): 1977-1986.

[35] GUO W, XU T, TANG K M. M-estimator-based online sequential extreme learning machine for predicting chaotic time series with outliers [J]. Neural Comput&Applic, 2017, 28:4093-4110.

[36] WANG W Y, SHI CH F, WANG W L, et al. Online sequential extreme learning machine algorithm based on the generalized maximum correntropy criterion [J]. Proceedings of ICSP, 2018:162-166.

[37] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1-3):489-501.

[38] GEBRAEEL N Z, LAWLEY M A, RONG L I, et al. Residual-life distributions from component degradation signals: A Bayesian approach [J]. IIE Transactions, 2005, 37(6): 543-557.

作者简介

梅文娟,2019 年于电子科技大学获得学士学位,现为电子科技大学硕士研究生,主要研究方向为机器学习、时间序列预测和测试优化分析。

E-mail: meiwenjuan@std.uestc.edu.cn

Mei Wenjuan received her B. Sc. degree from in 2019. Now, She is a M. Sc. candidate in University of Electronic Science and Technology of China. Her main research interests include machine learning, time series prediction and test strategy optimization.

刘震(通信作者),分别于 1999 年、2002 年、2007 年在西北工业大学于获得学士、硕士、博士学位,现为电子科技大学自动化工程学院教授,主要研究方向为基于机器学习的健康管理及预测、系统可靠性分析和寿命预测技术。

E-mail: scdliu@uestc.edu.cn

Liu Zhen(Corresponding author) received his B. Sc. degree, M. Sc. degree and Ph. D. degree all from Northwestern Polytechnical University in 1999, 2002 and 2007, respectively. He is currently a Professor with the Department of Instrument Science and Technology in the School of Automation Engineering at University of Electronic Science and Technology of China. His main research interests include learning-based prognostics and health management, system reliability analysis and lifetime prediction technology.

高媛,2014 年于电子科技大学获得博士学位,现为军委装备发展部某中心工程师,主要研究方向为故障诊断技术。

E-mail: c4isrmm@sohu.com

Gao Yuan received her Ph. D. degree from University of Electronic Science and Technology of China in 2014. She is currently an engineer at the development equipment of military equipment. Her main research interests include fault diagnosis technique.