

文章编号: 0254-0096(2018)03-0588-08

基于深度学习网络的风电机组主轴承故障检测

赵洪山, 刘辉海

(华北电力大学电气与电子工程学院, 保定 071003)

摘要: 针对风电机组数据采集与监视控制(supervisory control and data acquisition, SCADA)变量间存在的长期动态平衡关系,提出一种基于风电机组主轴承SCADA状态监测数据逐层编码网络的深度学习算法。首先利用受限玻尔兹曼机逐层智能学习主轴承样本数据蕴含的特定规则形成抽象的表示,构建深度学习网络模型。然后将主轴承SCADA数据输入网络,并计算反映主轴承整体状态的重构误差。根据故障状态下主轴承数据内部规则被破坏,选用指数加权移动平均值(exponentially weighted moving average, EWMA)阈值检测重构误差的趋势变化,并作为判定风电机组主轴承故障的决策准则。通过对主轴承故障前后记录数据进行仿真分析,仿真结果验证逐层编码网络深度学习算法对主轴承故障检测的有效性。

关键词: 风电机组; 主轴承; 深度学习; 故障检测

中图分类号: TM315

文献标识码: A

0 引言

风能以其清洁、可再生的特点,已成为发展最快的新型能源。考虑到风电机组运行条件恶劣、受力具有多变性,长时间运行易导致风电机组主轴承等关键部件发生故障,造成停机。主轴承作为风电机组传动链的重要部分,其运行状况对机组的良好运行具有重要影响。因此,本文研究风电机组主轴承的故障检测方法,有利于对主轴承实现故障预测,提前对故障采取措施,降低经济损失。

目前,风电机组主轴承的故障特征提取方法主要有状态变量残差检验法^[1]、振动监测分析法^[2-6]和声发射检测法^[7-9]。基于主轴承状态量残差的研究方法,文献[1]构建正常状态下主轴承温度的线性回归模型,通过建立温度预测值与实际值的残差函数,设定阈值检测温度的残差趋势,实现了主轴承异常状态的检测。针对主轴承的振动信号分析方法中,文献[2~4]采用经验模态分解分析法对轴承的振动信号进行分解,并以峭度为准则提取含有故障信息的模态函数,运用散度指标来描述故障程度,但在强噪声下,EMD分解往往受到影响。文献[5]通过对振动信号的分解,提取特征分量,实现对

主轴承的状态识别和故障检测,但该方法在分解过程中可能丢失特征分量。针对主轴承的早期故障特征往往受到环境噪声的干扰,文献[6]对原始振动信号进行小波降噪和包络解调分析,减小噪声的干扰,然后对解调信号进行处理,提取故障特征实现故障检测和诊断。针对风电机组主轴承的声发射技术研究中,通过比较不同测点测量到的声发射信号的幅值波动情况,判断出主轴承磨损位置,但考虑到不平稳状况下的振动情况,该方法的检测结果可能存在误差^[7-9]。

深度学习算法能够深度学习大量数据内在的特征规则,并将学习到的特征信息融入到模型的建立过程中,从而减少了人为设计特征的不足和传统特征提取所带来的复杂性^[10]。本文基于风电机组主轴承正常的SCADA运行数据,提出逐层编码网络(layer-wise encoder, LWE)模型,使其深度学习主轴承状态数据内部蕴含的规则,获得网络参数,利用输入与输出计算得到的重构误差作为主轴承的状态检测量,实现主轴承的故障预测。从而为风电场数据中心的风电机组健康管理提供一种新的思路。

收稿日期: 2016-11-22

基金项目: 国家科技支撑计划(2015BAA06B03)

通信作者: 赵洪山(1965—),男,博士、教授,主要从事电力系统分析与控制、故障预测与优化检修等方面的研究。zhaohshen@126.com

1 LWE 模型

LWE 模型通过多个受限玻尔兹曼机 (restricted Boltzmann machine, RBM) 堆叠构成深度学习网络,其底层表示原始数据的浅层特征,高层表示数据类别或属性^[11,12]。模型的输入和输出构成对称的网络,图 1 呈现了 LWE 模型的编码和解码的机制和结构。风电机组主轴承的 SCADA 状态数据 X 作为网络输入,通过 RBM 进行逐级特征提取,对隐含层单元节点进行激活输出编码 Y ,然后编码 Y 通过编码方式利用 RBM 进行逐级反向解码得到重构 \hat{X} 作为输出,输出 \hat{X} 称为输入 X 的重构值或估计值。模型编码和解码过程可用函数形式表示为:

$$Y = H(w_Y X + a_Y) \tag{1}$$

$$\hat{X} = G(w_{\hat{X}} Y + b_{\hat{X}}) \tag{2}$$

式中, w ——可见层与隐含层连接权重; a ——可见层; b ——隐含层的偏置。LWE 模型对于风电机组主轴承状态数据的训练结果是实现网络参数的优化,最大可能实现 \hat{X} 拟合 X :

$$\{w_i, a_p, b_j\} = \arg \min [c(X, \hat{X})] \tag{3}$$

式中, $c(X, \hat{X})$ ——整体误差。

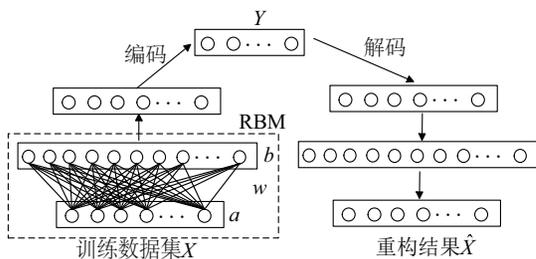


图1 LWE 模型结构
Fig. 1 Structure of LWE

LWE 模型对样本数据的学习过程包含由低层到高层的 RBM 训练和由高层到低层的参数调整两部分。

1.1 模型参数训练

模型参数初始化的实质是采用逐层无监督优化算法按照 RBM 单元网络对 LWE 模型的可见层和隐含层参数进行训练。RBM 的结构如图 2 所示。

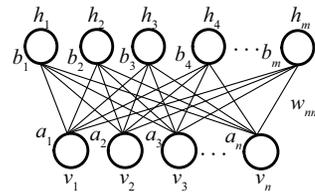


图2 RBM 的结构
Fig. 2 The structure of RBM

为了尽可能地描述风电机组主轴承的运行状态,选择主轴承的 SCADA 数据变量作为模型可见层的输入。主轴承状态变量如表 1 所示。

表 1 主轴承 SCADA 数据状态参数描述

Table 1 Description of wind turbine SCADA variables

变量名称	变量符号	单位
风速	v_0	m/s
发电功率	P	kW
轮毂温度	T_n	°C
齿轮箱油温度	T_o	°C
齿轮箱输入轴温度	T_i	°C
转子侧主轴承温度	T_r	°C
齿轮箱输出轴温度	T_t	°C
发电机轴承温度	T_b	°C
齿轮箱侧主轴承温度	T_c	°C

在训练过程中,这些变量选为风电机组主轴承长期正常运行状态下的无标签状态监测数据,将其作为训练样本。根据表 1, LWE 网络模型的输入 X 表示为:

$$X = [v_0, T_g, T_n, T_o, T_i, T_r, T_t, T_b, T_c] \tag{4}$$

为了减小风电机组主轴承不同类型变量的数值差异性引起计算误差,且保证原始数据结构相对不变,采用 $\bar{x}_i = x_i / x_{\max}$ 将数据处理为 $(0, 1]$ 。

RBM 网络的学习目的是尽可能表征输入数据的规则和特征。对于风电机组主轴承训练样本 S , 其必然服从一个 Q 分布。学习的目的使得 RBM 表示下的可见层分布 $P(v)$ 最大可能得拟合输入样本分布 $Q(v)$ 。为此引入能量模型,可视单元节点和隐含单元节点间的连接结构存在一个能量值^[13]。那么, RBM 作为一个网络所具备的能量定义,如式(5):

$$E(v, h) = h^T w v + a^T h + b^T v \tag{5}$$

式中, $\theta = \{w, b, a\}$ ——RBM 的参数; w ——可见层单元与隐含层单元之间的权值; a ——可见层单

元的偏置; b ——隐含层单元的偏置。基于该能量函数,可得到 (v, h) 的联合概率分布为:

$$P(v, h) = \frac{1}{Z} \exp(-\mathbf{h}^T \mathbf{w} \mathbf{v} - \mathbf{a}^T \mathbf{h} - \mathbf{b}^T \mathbf{v}) \quad (6)$$

式中, Z ——归一化因子, $Z = \sum_{v, h} \exp(-E(v, h))$ 。

通过对可见层与隐藏层积分可以得到可见层单元分布 $P(v)$:

$$P(v) = \frac{\sum_h e^{-E(v, h)}}{\sum_{v, h} e^{-E(v, h)}} \quad (7)$$

为了表征 RBM 表示下的样本分布 $P(v)$ 最大可能逼近输入样本的主轴承样本空间分布 $Q(v)$, 引入信息论中的 K-L 距离, 即相对熵, 表示两种分布的拟合程度, 如式(8), K-L 距离越小, 表示拟合程度越好。

$$\begin{aligned} KL(Q||P) &= \sum_{v \in \Omega} Q(v) \ln \frac{Q(v)}{P(v)} \\ &= \sum_{v \in \Omega} Q(v) \ln Q(v) - \sum_{v \in \Omega} Q(v) \ln P(v) \end{aligned} \quad (8)$$

当样本确定时, 式(8)中的第 1 项是确定的, 因此最小化 K-L 距离需最大化第 2 项, 为此对第 2 项求导:

$$\begin{aligned} &\frac{\partial \ln P(v)}{\partial \theta} \\ &= \frac{\partial}{\partial \theta} (\ln \sum_h e^{-E(v, h)}) - \frac{\partial}{\partial \theta} (\ln \sum_{v, h} e^{-E(v, h)}) \\ &= -\frac{1}{\sum_h e^{-E(v, h)}} \sum_h e^{-E(v, h)} \frac{\partial E(v, h)}{\partial \theta} + \frac{1}{\sum_{v, h} e^{-E(v, h)}} \sum_{v, h} e^{-E(v, h)} \frac{\partial E(v, h)}{\partial \theta} \\ &= -\sum_h P(h|v) \frac{\partial E(v, h)}{\partial \theta} + \sum_{v, h} P(v, h) \frac{\partial E(v, h)}{\partial \theta} \end{aligned} \quad (9)$$

式中, 第 1 项表示可见层单元为已知的样本 v 时隐含层单元的分布, 较易求取; 第 2 项 $P(v, h)$ 表示可见层与隐含层的联合概率分布, 不易求取。为此利用蒙特卡罗方法的随机化求积分原理来求取该项, 可得到:

$$\begin{aligned} \sum_{v, h} P(v, h) \frac{\partial E(v, h)}{\partial \theta} &= \sum_v \sum_h P(v) P(h|v) \frac{\partial E(v, h)}{\partial \theta} \\ &= \sum_v (P(v) \sum_h P(h|v) \frac{\partial E(v, h)}{\partial \theta}) \end{aligned} \quad (10)$$

因此可转化为求 $\sum_h P(h|v) \partial E(v, h) / \partial \theta$, 分别对 $\theta = \{w, b, a\}$ 求偏导并将其代入计算 $P(v)$ 偏导数的公式得到:

$$\frac{\partial \ln P(v)}{\partial w_{i,j}} = P(h_i = 1|v) v_j - \sum_v P(v) P(h_i = 1|v) v_j \quad (11)$$

$$\frac{\partial \ln P(v)}{\partial a_i} = v_i - \sum_v P(v) v_i \quad (12)$$

$$\frac{\partial \ln P(v)}{\partial b_i} = P(h_i = 1|v) - \sum_v P(v) P(h_i = 1|v) \quad (13)$$

由于 RBM 隐藏层内部和可视层内部不存在连接, 对于网络的隐含层单元的激活函数可表示为:

$$P(h_j = 1|v) = s(a_j + \mathbf{w}_j^T \mathbf{v}) \quad (14)$$

$$P(v_i = 1|h) = s(b_i + \mathbf{w}_i^T \mathbf{h}) \quad (15)$$

$$s(x) = \frac{1}{1 + e^{-x}} \quad (16)$$

式中, $s(x)$ ——激活函数。利用对比差异度算法实现参数的更新^[14], 结合式(14)、式(15)可求得参数 $\theta = \{w, a, b\}$ 的更新准则为 $\Delta \theta = \{\Delta w, \Delta a, \Delta b\}$, 即:

$$\begin{bmatrix} w_{ij}^{k+1} \\ b_i^{k+1} \\ a_j^{k+1} \end{bmatrix} = \begin{bmatrix} w_{ij}^k \\ b_i^k \\ a_j^k \end{bmatrix} + \begin{bmatrix} \eta \left\{ \langle v_i h_j \rangle_{P(h|v)} - \langle v_i h_j \rangle_{\text{recon}} \right\} \\ \eta \left\{ \langle v_i \rangle_{P(h|v)} - \langle v_i \rangle_{\text{recon}} \right\} \\ \eta \left\{ \langle h_j \rangle_{P(h|v)} - \langle h_j \rangle_{\text{recon}} \right\} \end{bmatrix} \quad (17)$$

式中, η ——学习率; $\langle \cdot \rangle_{P(h|v)}$ ——偏导数在 $P(h|v)$ 分布下的期望; $\langle \cdot \rangle_{\text{recon}}$ ——偏导数在重构模型分布下的期望。

1.2 模型确定

模型的初始参数作为 LWE 模型监督学习的先验值, 利用风电机组主轴承长期正常运行状态下的标签数据集进行监督学习实现参数优化获得模型的优化参数, 使得网络具有更好的表征性能, 该过程运用 BP 算法对网络参数进行微调, 最终使网络模型的表征性能达到全局最优。在模型训练完之后, 利用网络重构输出 $\hat{X}(k)$ 和输入样本 $X(k)$ 计算误差函数 e :

$$e = \frac{1}{2} \sum_{i=1}^n (\hat{X}_i(k) - X_i(k))^2 \quad (18)$$

计算误差函数对输出层单元的偏导数 $\delta_o(k)$, 然后利用输出层各单元 $\delta_o(k)$ 和隐含层各单元的输出来修正连接权重 w_{ho} :

$$\Delta w_{ho} = \eta \delta_o(k) h_{oh}(k) \quad (19)$$

$$w_{ho}^{N+1} = w_{ho}^N + \Delta w_{ho} \quad (20)$$

根据隐含层各单元的 $\delta_h(k)$ 和可见层各单元的输入修正权重:

$$\Delta w_{ih}(k) = \eta \delta_h(k) X_{ih}(k) \quad (21)$$

$$w_{ih}^{N+1} = w_{ih}^N + \Delta w_{ih} \quad (22)$$

式中, w_{ih} ——输入层隐含单元的权值,最后计算全局误差 E :

$$E = \frac{1}{2} \sum_{k=1}^p \sum_{i=1}^n (\hat{X}_o(k) - X_i(k))^2 \quad (23)$$

式中, p ——样本总数; n ——输出层单元数量; $\hat{X}(k)$ ——网络输出; $X(k)$ ——样本实际值。当全局误差满足精度要求时网络参数达到最优。参数调整过程得到的参数要比单纯 BP 算法的训练效果要好,因调优训练只需在训练参数的基础上进行局部搜索,该训练过程收敛速度明显提高^[15]。

1.3 主轴承状态检测变量

逐层编码深度学习网络利用主轴承的大量正常 SCADA 状态数据作为训练样本,不同于 BP 神经网络利用故障样本来训练的模式。利用深度学习网络对输入数据进行编码和解码后输出,输入变量与输出变量相对应且具有相同的物理意义。在模型的构建中利用 BP 网络实现 LWE 网络参数调优,从而使模型更好地拟合输入数据。

在对主轴承的故障检测中,利用建立的 LWE 模型计算新数据集的输入与输出的重构误差 (reconstruction error, R_E),将其作为主轴承状态趋势的检测量,通过对 R_E 的趋势分析实现主轴承的故障检测和异常状态的判别。因风电机组主轴承正常运行状态下的 SCADA 监测变量数据满足稳定的内部关系,当主轴承发生故障时,其数据蕴含的内部关系将会被破坏, R_E 的趋势将发生明显改变。因此选择 R_E 作为主轴承的状态检测量,正常状态下的 R_E 变化趋势如图 3 所示。由重构值 \hat{X} 与原始输入 X 计算得到 R_E ,如式(24):

$$R_E = \|\hat{X} - X\|^2 \quad (24)$$

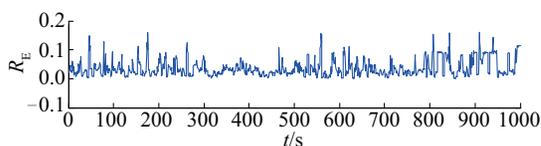


图3 正常状态下的 A30 号风电机组主轴承的 R_E

Fig. 3 R_E of A30 wind turbine main bearing under normal condition

2 指数加权移动平均值阈值设定

通过分析 R_E 的变化趋势或突变程度,实现对主

轴承的故障检测。考虑到风电机组正常运行状态下的 R_E 具有较小的波动性,采用指数加权移动平均值设定控制线,该阈值控制图具有检出过程均值小漂移的敏感性,因此可有效检测 R_E 的波动过程,且适合连续监测 R_E 的趋势变化。

指数加权移动平均值 (exponentially weighted moving-average, EWMA) 控制图的统计量为 l_t :

$$l_t = \lambda R_{E_t} + (1 - \lambda) l_{t-1} \quad (25)$$

式中, t ——时间; λ ——历史 R_E 对当前 EWMA 统计量的权重, $\lambda \in (0, 1]$; l_0 ——监测风电机组在某一时间段内 R_E 的均值。基于研究分析该过程中取 λ 为 0.2。

EWMA 统计量 l_t 的均值和方差可通过式(26)计算得到:

$$\mu_{l_t} = \mu_{R_E}, \sigma_{l_t}^2 = \frac{\sigma_{R_E}^2}{n_s} \left(\frac{\lambda}{2 - \lambda} \right) [1 - (1 - \lambda)^{2t}] \quad (26)$$

式中, μ_{R_E} ——某个风电场内同一类型风电机组主轴承 R_E 的均值; σ_{R_E} —— R_E 的标准差; n_s ——采样长度。因此风电机组主轴承的 EWMA 控制图基于时间 t 上下限函数为:

$$L_U(t) = \mu_{R_E} + z \sigma_{R_E} \sqrt{\frac{\lambda [1 - (1 - \lambda)^{2t}]}{(2 - \lambda) n_s}} \quad (27)$$

$$L_L(t) = \mu_{R_E} - z \sigma_{R_E} \sqrt{\frac{\lambda [1 - (1 - \lambda)^{2t}]}{(2 - \lambda) n_s}} \quad (28)$$

式中, z 通常取 2 和 3^[16]。当 z 取 2 时该阈值作为故障预警的界限; z 取 3 时作为风电机组主轴承故障检测的告警界限;当 $L_U < L_L(t)$, 主轴承处于安全区,其原理如图 4 所示。

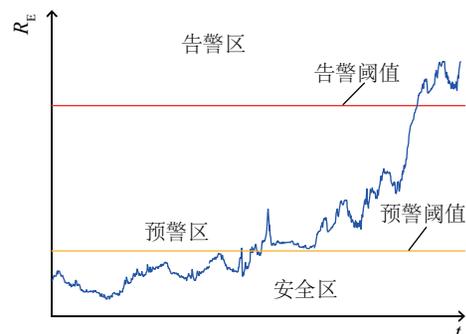


图4 风电机组主轴承 R_E 故障预测原理图

Fig. 4 Fault prediction diagram of wind turbine main bearing R_E

3 主轴承的LWE模型故障检测分析过程

在主轴承正常运行状态下,主轴承一直处于动态平衡,其 R_E 的波动维持在其EWMA阈值范围内,并保持长期稳定。当 R_E 趋势变化越过阈值时,并保持阈值之上,主轴承状态变量间的数据规则被破坏,实际值与重构值出现较大偏离,即与原有的平衡状态发生变化,判定主轴承发生了故障。

基于LWE模型的风电机组主轴承故障检测分析过程:首先选取主轴承的正常状态下的SCADA状态监测数据建立样本训练集,剔除异常数据。然后通过模型训练过程对参数初始化,选用主轴承训练数据集中的标签样本,运用BP算法对网络参数进行调整,建立关于主轴承的LWE网络模型。最后,利用新的数据集对模型进行测试,计算重构误差 R_E 序列,引入EWMA阈值检测其趋势变化并判定主轴承状态。

4 算例分析

4.1 数据集建立与模型参数设定

选取联合动力公司某风场A02号和A23号1.5 MW双馈式风电机组的主轴承作为测试对象,分别提取A02机组2015年1月1日~5月30日5个月和A23机组2015年3月10日~9月20日的正常SCADA状态监测数据建立训练样本集,数据断面数分别为 956820×9 和 969824×9 对主轴承的LWE网络模型进行参数训练。该机组的主传动链采用四点支撑式,其主轴安装在独立地前后两个轴承架上,通过两个独立安装在机舱底盘上的轴承支撑。由于运行环境变负荷、强冲击的特点,主轴承易发生表面损伤性故障和变形磨损故障。LWE模型设定4个隐含层,每个隐含层的单元数分别为1000、500、250、50。另选取该机组正常数据和故障前后数据作为主轴承的测试集。LWE模型的参数 w 、 a 、 b 初始化为服从高斯分布的随机较小值,初始学习率 η 设为0.1,网络更新速率设为0.001;BP算法对参数调整选择迭代周期为200。参数预训练过程中,数据集分批使RBM网络能够充分学习数据的特征规则。不同批次下的RBM输入样本对于网络的学习效果反映到重构误差 R_E 上,如图5所示。

根据重构误差越小,模型学习效果越优,因此选择每次输入数据批次为20。

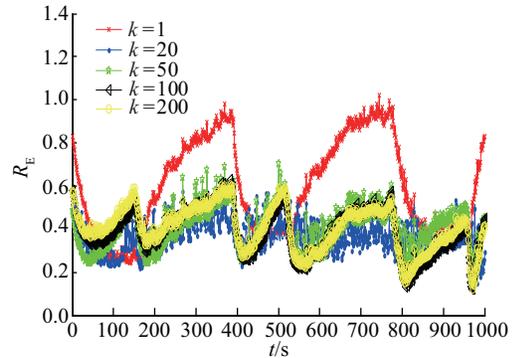


图5 不同批次 k 下的重构误差 R_E 结果

Fig. 5 R_E under different batches k

4.2 正常状态下的主轴承LWE模型测试

运用主轴承正常状态下的SCADA状态监测数据集建立LWE模型之后,对主轴承正常状态下的数据进行测试, R_E 由式(23)求取。在EWMA阈值条件下,由主轴承的LWE模型计算得到A02与A23风电机组主轴承 R_E 的变化趋势如图6、图7所示。可观察到正常状态下风电机组主轴承的 R_E 的波动处于其EWMA阈值范围内,且波动幅度较小,系统满足长期动态平衡关系。

4.3 故障状态下的主轴承LWE模型测试

选取A02号风电机组主轴承故障发生前后记录的数据,验证模型对故障检测的有效性。运用已训练好的LWE网络模型,计算故障状态下主轴承数据集的 R_E ,图8给出了A02号机组主轴承故障状态下的 R_E 结果。仿真结果显示,在 $0 \sim t_1$ 时间内, R_E

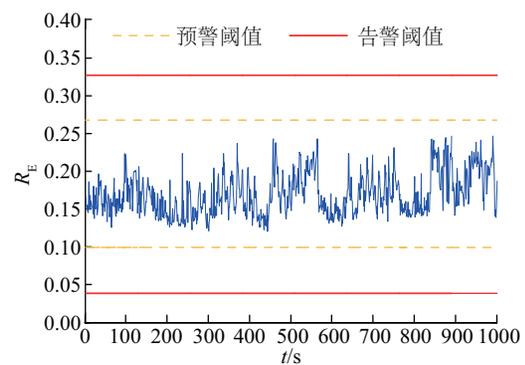


图6 正常状态下A02号风电机组主轴承 R_E 的EWMA阈值控制图

Fig. 6 The EWM chart of wind turbine main bearing R_E No. A02 in normal condition

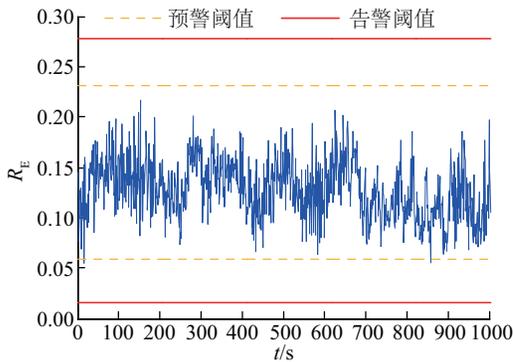


图7 正常状态下A23号风电机组主轴承 R_E 的EWMA 阈值控制图

Fig. 7 The EWMA chart of wind turbine main bearing R_E No. A23 in normal condition

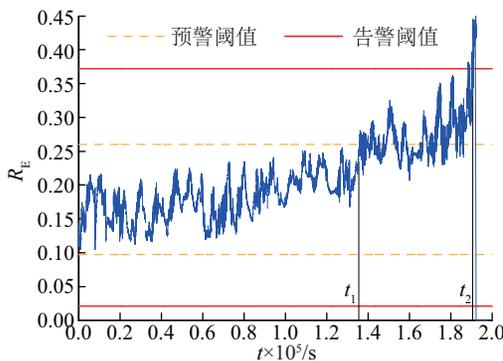


图8 故障状态下A02号风电机组主轴承 R_E 的EWMA 阈值控制图

Fig. 8 The EWMA chart of No. A02 wind turbine main bearing R_E under fault condition

变化曲线一直明显处于其 EWMA 阈值之内,且变化波动不大,较好地反映了主轴承的正常运行状态,从而建立了风电机组主轴承动态平衡关系。

根据故障状态下风电机组主轴承的LWE模型仿真结果,在 t_1 时刻主轴承的 R_E 变化趋势开始上升超过预警阈值,并一直处于EWMA阈值之上,从而判定主轴承出现异常,发出预警信号。主轴承的故障通常为渐变式的机械故障,伴随着主轴承异常的持续,故障越来越严重。从图8中可看出,随着 R_E 的趋势变化最终越过告警阈值,且 R_E 不断上升且上升速度加快,从而判定主轴承发生了故障。

在A23号风电机组建立深度学习模型后,选取其现场的SCADA状态监测数据进行测试,结果如图9所示。根据结果可看出,在 $0 \sim t_3$ 时间内 R_E 处于小范围波动,保持正常的安全状态。随着 R_E 的波动

变化, t_3 时刻越过预警阈值,此时主轴承出现轻微异常状况。 R_E 持续上升经过约10h越过告警阈值,此时判定A23号主轴承发生故障,经过一段时间之后发生故障停机。该测试结果与主轴承的实际状态对比相一致。因此LWE网络模型 R_E 检测法可有效检测主轴承的故障。

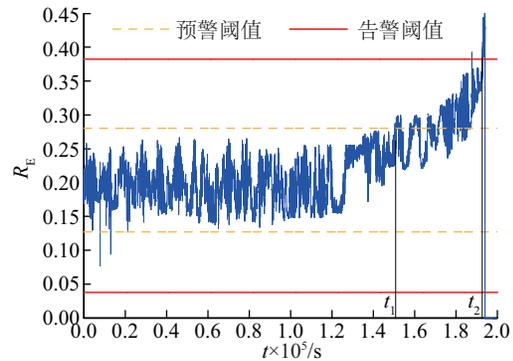


图9 故障状态下A23号风电机组主轴承 R_E 的EWMA 阈值控制图

Fig. 9 The EWMA chart of No. A23 wind turbine main bearing R_E under fault condition

在正常状态下主轴承是一个稳定平衡的动态系统,其变量之间存在的固有关联和规则保持不变,利用LWE模型提取的变量规则可最大拟合原始数据。 R_E 作为反映主轴承整体状态的一个重构误差变量,当主轴承出于安全状态时 R_E 趋势一直处于EWMA安全区内波动。当 R_E 序列趋势发生变化并超过EWMA预警阈值时并持续在阈值之上判定发生异常。 R_E 的变化越过告警阈值出现连续上升判定主轴承发生故障,发出告警信号,随后发生故障停机。从而实现了早期故障检测和预警,达到对主轴承的故障预测目的。

5 结论

运用逐层编码网络模型逐层学习提取风电机组主轴承正常SCADA数据内部蕴含的规则。通过运用正常状态下主轴承的状态数据建立LWE网络模型,使其深度逐层学习主轴承运行变量的关系。针对故障状态下,主轴承SCADA数据内部关系被破坏,选取重构误差 R_E 作为主轴承故障检测变量,并引入 R_E 的EWMA阈值作为主轴承故障预警和告警的决策准则。根据仿真结果可看出,该方法能够基于SCADA数据对风电机组主轴承故障实现有效

检测,可为风电场数据中心的风电机组健康管理提供一种新思路,是对目前主轴承故障检测方法不足的补充。由于风电机组是一个复杂的系统,对于该方法在风电机组的多部件、多故障的一致性分析中的研究提出了更高要求,因而应进一步考虑更多的风电机组状态变量和因素,实现该方法在风电机组多故障的研究以及故障定位中的应用。

[参考文献]

- [1] 张小田, 鄢盛腾, 周雪青, 等. 基于状态监测的风电机组主轴承早期故障预测方法[J]. 广东电力, 2012, 25(11): 6—10.
- [1] Zhang Xiaotian, Yan Shengteng, Zhou Xueqing, et al. Early stage failure forecast method for main bearing of wind turbine based on state monitoring[J]. Guangdong Electric Power, 2012, 25(11): 6—10.
- [2] 郭艳平, 颜文俊, 包哲静, 等. 基于经验模态分解和散度指标的风电机组滚动轴承故障诊断方法[J]. 电力系统保护与控制, 2012, 40(17): 83—88.
- [2] Guo Yanping, Yan Wenjun, Bao Zhejing, et al. Fault diagnosis of bearing in wind turbine based on empirical mode decomposition and divergence index [J]. Power System Protection and Control, 2012, 40(17): 83—88.
- [3] Jiang Qing, Li Tingyao, Yan Caijinhui, et al. Study of rolling bearing SVM pattern recognition based on correlation dimension of IMF [A]. Second International Conference on Intelligent System Design and Engineering Application[C], Sanya, China, IEEE Computer Society, 2012: 1132—1135.
- [4] Cheng Junsheng, Yu Dejie, Yang Yu. A fault diagnosis approach for rolling bearings based on EMD method and AR model[J]. Mechanical Systems and Signal Processing, 2006, 20(2): 350—362.
- [5] 安学利, 蒋东翔, 陈杰, 等. 基于ITD和LS-SVM的风力发电机组轴承故障诊断[J]. 电力自动化设备, 2011, 31(9): 10—13.
- [5] An Xueli, Jiang Dongxiang, Chen Jie, et al. Bearing fault diagnosis based on ITD and LS-SVM for wind turbine[J]. Electric Power Automation Equipment, 2011, 31(9): 10—13.
- [6] 赵洪山, 邵玲, 连莎莎. 基于最大信噪比的风电机组主轴承的故障特征提取[J]. 可再生能源, 2015, 33(3): 410—415.
- [6] Zhao Hongshan, Shao Ling, Lian Shasha. Method for extracting fault feature of wind turbine main bearing based on maximum signal to noise ratio[J]. Renewable Energy Resource, 2015, 33(3): 410—415.
- [7] 王晓伟, 刘占生, 张广辉, 等. 基于声发射的可倾瓦径向滑动轴承碰摩故障诊断[J]. 中国电机工程学报, 2009, 29(8): 64—69.
- [7] Wang Xiaowei, Liu Zhansheng, Zhang Guanghui, et al. Rubbing fault diagnose of tilting pad journal bearing by acoustic emission [J]. Proceedings of the CSEE, 2009, 29(8): 64—69.
- [8] 李宁, 魏鹏, 莫宏, 等. 光纤光栅声发射检测新技术用于轴承状态监测的研究[J]. 振动与冲击, 2015, 34(3): 172—177.
- [8] Li Ning, Wei Peng, Mo Hong, et al. Bearing state monitoring using a novel fiber bragg grating acoustic emission technique[J]. Journal of Vibration and Shock, 2015, 34(3): 172—177.
- [9] Li Ruoyu, He D. Rotational machine health monitoring and fault detection using EMD-based acoustic emission feature quantification[J]. Transaction on Instrumentation and Measurement, 2012, 61(4): 990—1001.
- [10] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436—444.
- [11] Chen Yushi, Lin Zhouhan, Zhao Xing, et al. Deep learning-based classification of hyperspectral data[J]. IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing, 2014, 7(6): 2094—2107.
- [12] Hinton G, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527—1554.
- [13] Bengio Y, Lamblin P, Popovici D, et al. Greedy layer-wise training of deep network[J]. Advances in Minimizing Contrastive Divergence. Neural Computation, 2002, 14(8): 1771—1800.
- [14] Carreira-Perpinan M A, Hinton G E. On contrastive divergence learning[A]. Proceedings of the Tenth International workshop on Artificial Intelligence and Statistics[C], Barbados, 2005, 33—40.
- [15] Williams D E, Rumelhart G E, Hinton R J, et al. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533—538.
- [16] 殷建军, 李兴林, 余忠华, 等. 蒙特卡罗方法的过程聚类 EWMA 控制图研究[J]. 中国计量学院学报, 2007, 18(4): 261—264.
- [16] Yin Jianjun, Li Xinglin, Yu Zhonghua, et al. Study on EWMA control chart for the process clustering based on

Monte Carlo method [J]. Journal of China Jiliang

University, 2007, 18(4): 261—264.

FAULT DETECTION OF WIND TURBINE MAIN BEAR BASED ON DEEP LEARNING NETWORK

Zhao Hongshan, Liu Huihai

(School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: According to the long-term dynamic stability relationship between supervisory control and data acquisition (SCADA) state variables of wind turbine, a deep learning method of layer-wise encoder network based on the wind turbine main bearing SCADA condition monitoring data is proposed in this paper. Firstly, a more abstract high-level abstraction representation is formed by learning features of original sample to discover the underlying rules and distribution characteristics of the data through layer-by-layer intelligent learning, and the rules and distribution characteristics between the main bearing variables are extracted to construct a layer-wise encoder network model. Then, the SCADA data of the main bearing is encoded and decoded to calculate the reconstruction error. According to the internal rules of the main bearing data are destroyed in fault condition, the reconstruction error is chosen as the that monitoring variable of main bearing. Exponentially Weighted Moving Average (EWMA) is used to detect the trend of the reconstruction error and serve as the decision criterion of the main bearing fault. The simulation results show that the proposed method is effective for fault detection of main bearing by using the main bearing failure before and after record data simulation analysis.

Keywords: wind turbine; main beaying; deep learning; fault detection