

# 基于 FISSA-DBN 模型的风电机组运行状态监测\*

周 凌<sup>1,2</sup>, 赵前程<sup>1</sup>, 朱岸锋<sup>1</sup>, 杨三英<sup>1</sup>, 阳雪兵<sup>1,3</sup>

(1. 湖南科技大学风电机组运行数据挖掘与利用技术湖南省工程研究中心 湘潭, 411201)

(2. 湖南工业大学电气与信息工程学院 株洲, 412002)

(3. 哈电风能有限公司 湘潭, 411102)

**摘要** 为提高风电机组运行效率,降低风电场运营成本,对风电机组运行状态监测显得尤为重要,提出一种基于数据采集与监控(supervisory control and data acquisition,简称 SCADA)系统和萤火虫改进麻雀搜索算法优化深度置信网络(firefly improved sparrow search algorithm optimized deep belief network,简称 FISSA-DBN)的风电机组状态监测新方法。首先,对 SCADA 数据进行预处理分析,并利用专家系统和皮尔逊相关系数分析,相关分析选取输入参数和输出参数;其次,利用预处理数据集建立基于 FISSA-DBN 的风电机组运行状态监测新模型,根据模型预测值和实际输出值之间的重构值误差,以及指数加权移动平均阈值(exponentially weighted moving average,简称 EWMA)判断是否有异常;最后,以华东某风电场实际数据为例进行实例验证。结果表明,所提出方法的预警时间比实际记录时间最早可提前 4 d 多。同时,将所提出方法与其他方法进行对比,结果表明该方法预警时间提前,模型预测误差更小。

**关键词** 风电机组;深度置信网络;状态监测;麻雀搜索算法;指数加权移动平均阈值

**中图分类号** TM315;TK83

## 引 言

随着国家节能减排政策的持续推进,风能作为绿色清洁能源,其发展越来越得到重视。风电机组是实现风能转换的核心部件之一,其运行状态的监控显得尤为重要<sup>[1]</sup>。由于风电机组通常运行在条件恶劣和高空等环境下,经常会出现发电机、变频器、轴承和各种传感器状态异常,因此有必要构建一个风电机组运行状态监测模型,实现风电机组部件早期异常状态报警和故障诊断<sup>[2-3]</sup>。

风电机组 SCADA 系统由许多传感器组成,数据体现了风电机组运行过程状态。学者们利用 SCADA 数据对风电机组状态监测和故障诊断进行了研究并取得了很大的发展。文献[4]提出利用一种机器学习实现风电机组状态异常监测的方法。文献[5]运用神经网络和随机过程理论,对 SCADA 数据进行分析,建立风电机组运行行为模型,提出了评估风电机组运行性能的指标并进行了验证。文献[6]利用主轴温度、齿轮箱润滑油温度和发电机绕组温度这 3 个温度信号,建立误差逆传播(back-propagation,简称 BP)神经网络模型,实现对风电

机组部件故障监测。文献[7]针对风电机组偏航系统故障处理问题,提出基于 SCADA 数据的偏航齿轮箱神经网络诊断模型,利用 ReliefF 算法和核密度一均值法得到 7 个反映偏航齿轮箱运行工况的 SCADA 参数,实现 3 种运行状态的诊断。可以看出,上述研究没有充分利用 SCADA 数据参数之间的关联特性,难以判断运行状态异常所产生的原因。因此,需要挖掘 SCADA 数据间的关联性以降低风电机组状态监测的虚警率。

近年来,采用深度学习网络对风电机组故障诊断得到了广泛应用。深度置信网络(deep belief network,简称 DBN)是一种新兴模拟人脑神经系统结构的机器学习方法,通过构建深度神经网络并利用层次学习方法,高效处理数据信息,挖掘重要故障信息和关键特征,适用于故障预测领域的研究<sup>[8]</sup>。DBN 能深层次学习大量数据内在的特征规则,将学习到的特征信息融入到模型的建立过程中,从而减少人为设计特征的不足和传统特征提取带来的复杂性<sup>[9]</sup>。文献[10]提出一种基于改进多特征提取和 DBN 相结合的模型,验证表明,该模型能提取出风

\* 国家自然科学基金资助项目(51875199,51905165);湖南省自然科学基金资助项目(2019JJ50186)

收稿日期:2022-04-01;修回日期:2022-06-17

电机组实际数据的故障特征,有更高的识别准确性。文献[11]提出一种基于级联深度学习预测模型的风电机组状态检测方法,采用距离相关系数选取输入参数,建立卷积神经网络和长短期神经网络的预测模型,能准确检测到齿轮箱轴承温度异常。文献[12]提出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方法,通过对主轴承故障前后记录数据的仿真分析,验证监测主轴承故障的有效性。文献[13]通过 DBN 网络构建故障诊断模型,并对比基于模型的诊断方法和数据驱动型诊断方法,验证了模型的诊断效果。文献[14]提出一种基于深度信念网络的风电机组主轴承状态监测方法,通过对主轴承温度残差序列分析,利用核密度估计方法确定故障阈值,实现了主轴承异常状态监测。以上研究由于 DBN 在故障诊断过程中,随机初始化网络参数容易引起局部最优解的生成,将导致降低故障诊断精度,因此对 DBN 参数进行优化设计十分重要。

为克服上述问题,挖掘隐藏在 SCADA 数据中的有效信息并快速提取故障特征,及时准确地发现机组潜在的早期故障,笔者提出一种 FISSA-DBN 的风电机组状态监测方法,并以华中某风电场实际数据为例进行了验证分析。

## 1 风电机组状态监测模型建立

### 1.1 深度置信网络

DBN 是一种无监督的人工神经网络,通过堆叠多个受限玻尔兹曼机 (restricted Boltzmann Machine, 简称 RBM) 而成<sup>[15]</sup>。与传统神经网络和识别模型相比,DBN 对数据的训练更为充分,适用于解决多模态和复杂问题的分类及识别,广泛应用于不同领域<sup>[16-18]</sup>。RBM 结构如图 1 所示。RBM 一共有 2 层,上层为隐层,下层为显层。RBM 堆叠成深度学习网络时,前一个 RBM 的输出层(隐层)作为下一个 RBM 单元的输入层(显层),依次堆叠,便构成基

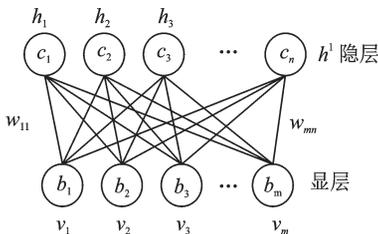


图 1 RBM 结构图

Fig.1 RBM structure

本的 DBN 结构,最后再添加一层输出层,就是最终的 DBN 结构<sup>[19]</sup>。

假设 DBN 模型包含  $l$  个隐藏层,其联合概率为  $p(v, h^1, h^2, \dots, h^l) = p(v|h^1)p(h^1|h^2)\dots p(h^{l-1}|h^l)$  (1) 其中:  $p(h^{j-1}|h^j), j = 2, 3, \dots, l$  为隐藏层第  $j-1$  层和第  $j$  层之间的条件概率分布。

显层神经元与隐藏神经元之间的能量定义为

$$E(v, h; \theta) = - \sum_{i=1}^m v_i b_i - \sum_{j=1}^n c_j h_j - \sum_{i=1}^m \sum_{j=1}^n v_i h_j \omega_{ij} \quad (2)$$

其中:  $\theta = \{\omega_{ij}, b_i, c_j\}$  为网络参数;  $\omega_{ij}$  为指显层神经元与隐层神经元之间的权重;  $b_i$  为显层神经元的偏置;  $c_j$  为隐层神经元的偏置;  $m$  为显层神经元个数;  $n$  为隐层神经元个数。

DBN 网络模型的输入  $X$  表示为

$$X = v = [v_1, v_2, v_3, \dots, v_m] \quad (3)$$

其中:  $X$  为 SCADA 中的相关参数集。

基于上述能量函数,式(1)表示为

$$p(v, h) = \frac{1}{Z} e^{-E(v, h)} \quad (4)$$

其中:  $Z$  为分配函数,用来调整  $e^{-E(v, h)}$  的分配值。

显层和隐层内部不存在连接,网络的显层神经元和隐层神经元的激活函数分别表示为

$$p(v_i = 1|h) = \sigma\left(\sum_{j=1}^n \omega_{i,j} h_j + b_i\right) \quad (5)$$

$$p(h_j = 1|v) = \sigma\left(\sum_{i=1}^m \omega_{i,j} v_i + c_j\right) \quad (6)$$

其中:  $\sigma(x)$  为 Sigmoid 函数,表达式为

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

通过对比散度学习算法来训练 RBM,寻找最优的权值  $\omega_{ij}$ ,不停地更新得到新权重和偏置,其更新表达式为

$$\omega_{ij}^{(s)} \leftarrow \omega_{ij}^{(s-1)} + \lambda (p(h_i|v_i; \theta) v_i - p(h_{i+1}|v_{i+1}; \theta) v_{i+1}) \quad (8)$$

$$c_i \leftarrow c_{i-1} + \lambda (h_i - h_{i+1}) \quad (9)$$

$$b_j \leftarrow b_{j-1} + \lambda (v_i - v_{i+1}) \quad (10)$$

其中:  $\lambda$  为学习率;  $s$  为 RBMs 的数量。

### 1.2 萤火虫扰动改进麻雀搜寻算法

在深度置信网络模型建立过程中,网络参数是随机初始化的,会引起局部最优解的产生。采用麻雀搜索算法 (sparrow search algorithm, 简称 SSA) 对 DBN 进行优化,通过寻求 DBN 学习速率和 RBM 各层隐藏神经元数目的最优值,实现在全局样本空间中获得更高的诊断精度,SSA 的原理可参考文献[20]。

萤火虫改进麻雀搜索算法 (firefly improved sparrow search algorithm, 简称 FISSA) 是将所有麻雀与最优麻雀利用萤火虫扰动方式进行位置更新, 提高搜索性, 把扰动后的麻雀与扰动前的麻雀进行对比, 如果更优则更新麻雀位置<sup>[21]</sup>。

萤火虫的相对荧光亮度为

$$I = I_0 e^{-\gamma r_{ij}^2} \quad (11)$$

其中:  $I_0$  为萤火虫的最大荧光亮度, 与目标函数值相关, 目标函数值越优自身亮度越高;  $\gamma$  为光强吸收系数, 荧光会随着距离的增加和传播媒介的吸收逐渐减弱;  $r_{i,j}$  为萤火虫  $i$  与  $j$  之间的空间距离<sup>[22]</sup>。

萤火虫的吸引度为

$$P = P_0 e^{-\gamma r_{ij}^2} \quad (12)$$

其中:  $P_0$  为最大吸引度。

萤火虫  $i$  被吸引向萤火虫  $j$  移动的位置更新公式为

$$x_i = x_i + P(x_j - x_i) + q(\text{rand} - 1/2) \quad (13)$$

其中:  $q \in [0, 1]$  为步长因子;  $\text{rand}$  为  $[0, 1]$  上服从均匀分布的随机数。

采用 FISSA 算法优化 DBN 模型, DBN 模型设置 2 个隐藏层, 根据式 (13) 得到最佳适应度位置  $x$ , 对 DBN 模型的 2 个隐藏层神经元数目及学习率进行优化, 即

$$\begin{aligned} \min f(\alpha, \beta, \lambda) &= x(1, 2, 3) \\ \text{s.t. } \alpha &\in x(1) \\ \beta &\in x(2) \\ \lambda &\in x(3) \end{aligned} \quad (14)$$

其中:  $x(k)$  为优化之后得到的最佳适应度值 ( $k=1, 2, 3$ );  $\alpha$  为 RBM 第 1 个隐藏层优化之后的神经元数目;  $\beta$  为 RBM 第 2 个隐藏层优化之后的神经元数目;  $\lambda$  为优化之后得到的学习率。

图 2 为 DBN 的 FISSA 优化流程, 具体步骤如下。

1) 设置 FISSA 的参数。根据多次实验选取迭代次数为 10, 种群规模为 40 只, 捕食者的比例为 20%, 安全阈值  $T$  取 0.8, 加入者的比例为 30%, 意识到危险的麻雀数量为 5 只。

2) 优化参数设置。随机初始化麻雀种群的位置, 设置  $\alpha$ ,  $\beta$  和  $\lambda$  的参数范围。

3) 计算适应度值。根据目标函数计算麻雀的适应度值, 更新捕食者位置、加入者位置和警戒者位置, 计算适应度并更新麻雀位置, 保存最佳位置个体, 表达式为

$$\text{Best\_pos}(t) = x_i = \text{Function}(\alpha, \beta, \lambda) \quad (15)$$

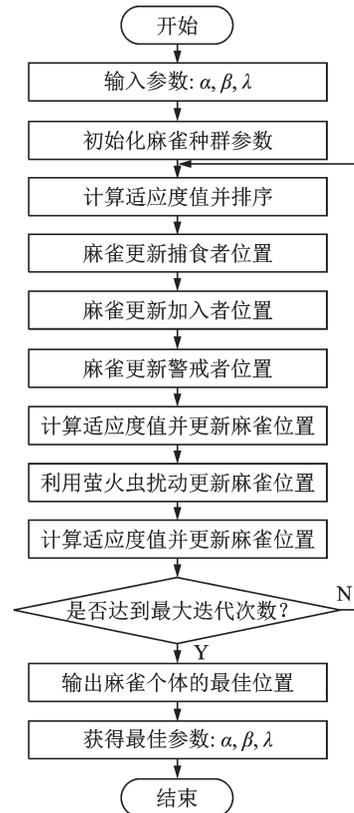


图 2 DBN 的 FISSA 优化流程

Fig.2 FISSA optimization flow chart of DBN

4) 萤火虫扰动。利用萤火虫扰动更新麻雀位置, 计算适应度值并更新麻雀位置, 保存最佳位置个体。

5) 优化结束。根据定义的最大迭代次数判断是否满足停止条件, 满足则退出, 输出最佳参数向量; 否则, 返回执行步骤 2, 重复上述步骤直到得到最优参数。

### 1.3 基于 FISSA-DBN 的风电机组运行状态监测模型建立

采用 FISSA 寻找 DBN 的最优参数, 并应用到已经建好的 DBN 中, 实现过程如下。

1) 数据选择: 根据风电机组运行记录, 从 SCADA 数据中提取风电机组的原始运行数据。

2) 数据预处理: 基于专家领域知识, 从原始 SCADA 数据中选取总的预测模型条件参数, 根据风场事故几率进一步处理数据信息, 删除原始数据中的错误数据和不必要数据。

3) 预测模型参数确定: 根据数据样本选择风电机组状态监测模型的输入输出参数, 把步骤 2 得到的预处理数据组利用皮尔逊相关系数分析, 得到各参数与输出参数之间的相关性, 选取相关性大的参数作为模型的输入。

4) 数据处理:对选取的数据进行标准化处理,将值归化到 $[0, 1]$ 区间,利用该数据样本进行预测模型训练或测试。选取每种状态下20 000组历史正常数据作为样本,80%的随机数据作为训练数据,20%作为测试数据。

5) 模型拓扑结构:设置麻雀的种群规模、迭代次数、生产者比例和DBN结构等相关参数。

6) DBN参数优化:通过FISSA来优化RBM层的学习率和隐藏层的神经元数目,得到DBN模型的最优初始向量。

7) 模型训练:根据风电机组运行状态监测研究对象,对模型进行训练和测试,得到EWMA控制图的上下限阈值。

8) 预测模型应用:将实际风场SCADA数据用预测模型进行验证,并与实际运行记录对比。

## 2 异常状态检测方法

DBN对输入数据进行编码和解码后输出,输入变量和输出具有相同的物理意义,通过FISSA对DBN参数调优,使模型更好地拟合输入数据。计算预测模型的预测值与实际值的重构误差 $\delta_E$ ,将其作为风电机组运行状态是否异常的判断依据。风电机组正常运行时,SCADA监测变量数据满足稳定的内部关系;当出现故障时,重构误差趋势会发生明显变化,其重构误差表达式为

$$\delta_E = |x(i) - \hat{x}(i)| \quad (16)$$

其中: $x(i)$ 为实际值; $\hat{x}(i)$ 为预测值。

通过分析 $\delta_E$ 的变化趋势或突变程度,实现对风电机组运行状态的监测。采用指数加权移动平均值法设置阈值线,检测出均值小漂移,适合连续监测 $\delta_E$ 的变化趋势。

EWMA控制图的统计量 $Z_t$ 为

$$Z_t = \lambda \delta_{E_t} + (1 - \lambda) Z_{t-1} \quad (17)$$

其中: $\lambda$ 为权重因子,表示历史 $\delta_E$ 对当前EWMA的影响, $\lambda \in (0, 1]$ ,参照参考文献[9],取值为0.2; $t$ 为时间; $\delta_{E_t}$ 为独立的随机变量。

EWMA统计量的均值为

$$\mu_{Z_t} = \mu_{\delta_E} \quad (18)$$

其中: $\mu_{\delta_E}$ 为同一类型风电机组对应设备的 $\delta_E$ 均值。

EWMA统计量的方差为

$$\sigma_{Z_t}^2 = \frac{\sigma_{\delta_E}^2}{n} \left( \frac{\lambda}{2 - \lambda} \right) [1 - (1 - \lambda)^{2t}] \quad (19)$$

其中: $n$ 为采样长度; $\sigma_{\delta_E}^2$ 为 $\delta_E$ 标准差的平方。

基于时间的风电机组运行状态监测的EWMA控制图的上下限函数定义为

$$U_c(t) = \gamma \mu_{\delta_E} + \kappa \sigma_{\delta_E} \sqrt{\frac{\lambda [1 - (1 - \lambda)^{2t}]}{(2 - \lambda)}} \quad (20)$$

$$U_L(t) = \gamma \mu_{\delta_E} - \kappa \sigma_{\delta_E} \sqrt{\frac{\lambda [1 - (1 - \lambda)^{2t}]}{(2 - \lambda)}} \quad (21)$$

其中: $\gamma$ 为告警系数,经过反复验证取值为4,表示预测重构误差为均值的4倍时,会发出故障告警; $\kappa$ 通常设置为2或3,当取2时,表示为故障预警阈值的界限;当取3时,表示为故障告警阈值的界限。

从式(20),(21)可知, $U_c(t)$ 和 $U_L(t)$ 为一组随时间变化的数据。随着 $t$ 的增加,这2个值趋向于常数,因此阈值线取最后的常数值。

当风电机组运行正常或停机时, $\delta_E$ 的值维持在EWMA阈值线以下,并能长期稳定运行,但当 $\delta_E$ 的变化趋势超过阈值线时,并保持在阈值线上,表示实际值与重构值出现较大偏差,原有平衡状态发生变化,运行状态出现异常<sup>[9]</sup>。

## 3 算例分析

### 3.1 数据预处理及参数确定

数据来源华东某风电公司提供的同一风场SCADA系统数据,单机容量均为2 MW,选取从2013-01-01~2017-12-30共5年内采样间隔为10 min的数据进行分析。剔除掉SCADA中的状态异常数据,风速与功率曲线如图3所示。选取建模训练和测试的SCADA数据,风速在3.5~20 m/s之间,并把停机状态下功率为0的数据剔除,保证是正常运行的健康数据。

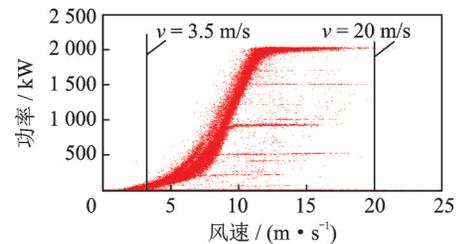


图3 风速与功率曲线图

Fig.3 Curve of wind speed and power

风电机组运行的时候,由于各个部件之间存在关联特性,状态参数会相互影响,因此要选择合适的输入参数以避免信息冗余,提高故障诊断的准确

度。笔者研究状态为风电机组运行、主轴承异常和发电机定子异常 3 种情况,经过专家系统判断和皮尔逊相关性计算,皮尔逊相关性评判标准取值为 0.8,得到 3 种情况下的输入状态参数。表 1 为风电机组状态评估模型参数表。风电机组状态监测模型参数间相关性如图 4 所示。为了验证 FISSA-DBN 模型对风电机组故障监测的性能,与 SSA-DBN 模型、鲸鱼算法 (whale optimization algorithm, 简称 WOA) 优化的 WOA-DBN 模型和 DBN 模型进行了对比分析。

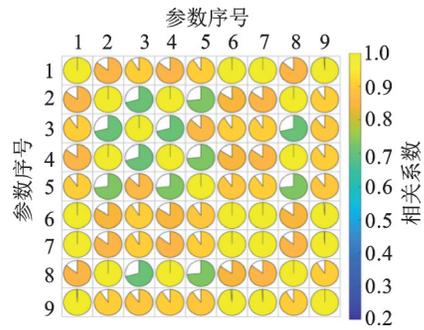


图 4 风电机组运行状态监测模型参数间相关性

Fig.4 Correlation between parameters of wind turbine operation monitoring model

表 1 风电机组状态评估模型参数表

Tab.1 Parameters of wind turbine condition assessment model

序号	参数	风电机组运行模型	主轴承异常模型	发电机定子异常模型
1	输出参数	变频器电网侧有功功率	主轴承温度 1	定子温度 2
2		轮毂转速	轮毂转速	轮毂转速
3		变桨电机 3 电流	超速传感器转速监测值	机舱气象站风速
4		超速传感器转速监测值	机舱气象站风速	变频器网侧有功功率
5		机舱气象站风速	发电机运行频率	发电机侧功率
6	输入参数	变频器电网侧电流	发电机电流	发电机运行频率
7		变频器发电机侧功率	发电机定子温度 1	发电机电流
8		发电机运行频率	机舱温度	发电机定子温度 6
9		发电机电流	控制柜温度	主轴承温度 1
10		—	—	机舱温度

### 3.2 风电机组运行状态监测

采用历史正常数据建立训练和测试样本集并进行归一化处理,设置模型初始化参数,运用 FISSA 寻找最佳适应度值,按照式(14)分别得到  $\alpha$ 、 $\beta$  和  $\lambda$  的值为 82,90 和 0.066 8。利用最优值设置模型参数,训练 DBN 模型,通过训练好的模型对测试样本集进行测试,根据式(17)~(21)得到 EWMA 控制图的上限值,阈值线取告警上限值。

对 2013 年 5 号风电机组进行实例验证,选取数据为 2013-06-25T18:05~2013-06-26T10:45,即数据点 25 310~25 410。经过 FISSA-DBN 模型预测,

风电机组运行状态预测结果如图 5 所示。图 6 为风电机组状态监测  $\delta_E$  曲线图。图 6(a)中,在 25 333 点即 2013-06-25T21:55 之前, $\delta_E$  值在告警阈值上限之下,此后, $\delta_E$  值持续超过告警阈值上限,表明风电机组出现异常。通过与实际情况对比发现,风电机组

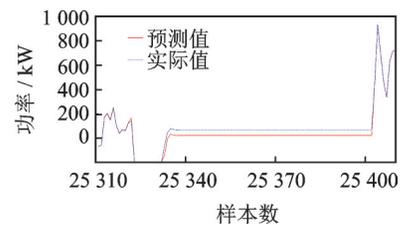


图 5 风电机组运行状态预测结果

Fig.5 Prediction results of wind turbine operation state

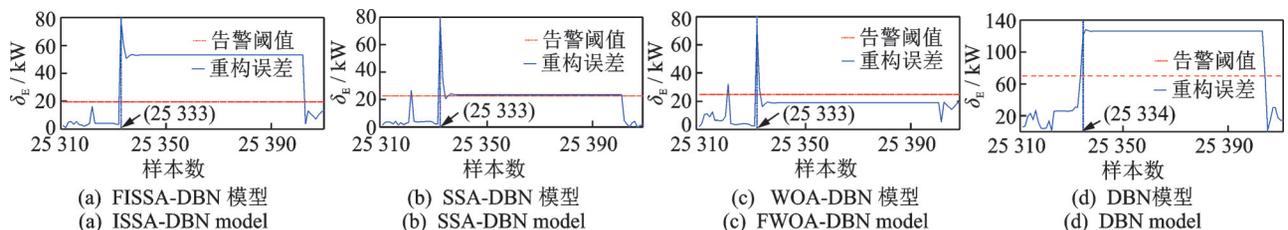


图 6 风电机组状态监测  $\delta_E$  曲线图

Fig.6 Wind turbine condition monitoring  $\delta_E$  curve

从 23:25 min 开始,风速仪出现异常状况,该模型预测结果比实际情况提前 90 min。图 6(b)中,SSA-DBN 模型虽然在 25 333 点  $\delta_E$  值超过告警阈值上限,但后面曲线回落,超过告警阈值上限值不多,容易造成忽视。图 6(c)中,WOA-DBN 模型在 25 333 点时超过告警阈值上限,但后面曲线回落在告警阈值上限值的下面,从而检测不出实际异常情况。图 6(d)中,模型在 25 334 点时超过告警阈值上限值,比 FISSA-DBN 模型晚 10 min 预测出来,且  $\delta_E$  值比较大,表明未优化的 DBN 模型误差较大。

### 3.3 主轴异常状态监测

直驱风力发电机组采用双主轴承结构形式,分析主轴承异常状态以主轴承温度 1 为研究对象。运用 FISSA 寻找最佳适应度值,得到式(14)中  $\alpha, \beta$  和  $\lambda$  的值分别为 30, 15 和 0.035 2。

对 2015 年 2 号风电机组 SCADA 数据进行验证,选取数据为 2015-12-23T03:05~19:45,即数据点 50 650~50 750。经过 FISSA-DBN 模型预测,主轴承异常状态预测结果如图 7 所示,图 8 为主轴承异常状态监测  $\delta_E$  曲线图。图 8(a)中,在 50 714 点即

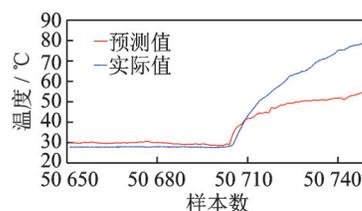


图 7 主轴异常状态预测结果

Fig.7 Prediction results of abnormal state of main bearing

2015-12-23T13:45 之前,  $\delta_E$  值在告警阈值上限之下,此后,  $\delta_E$  值持续超过告警阈值上限,温度值开始超过告警温度,之后  $\delta_E$  值不断上升且速度加快,表示故障越来越严重。运行记录显示在 2015-12-24T01:05 时,出现故障导致停机,模型检测结果比实际停机时间提前近 11 h。可见,检测结果可以实现早期异常监测和预警,为风电机组主轴承检修提供充足的时间。图 8(b)和 8(c)模型都在 50 714 点超过告警阈值。图 8(d)模型在 50 724 点,即 2015-12-23T15:25 检测出故障,比采用优化模型的检测晚 100 min。经停机检测发现,由于主轴承润滑脂缺少,导致主轴承温度过高,损坏了主轴承,从而导致停机时间长达 43 d,造成较大的经济损失。

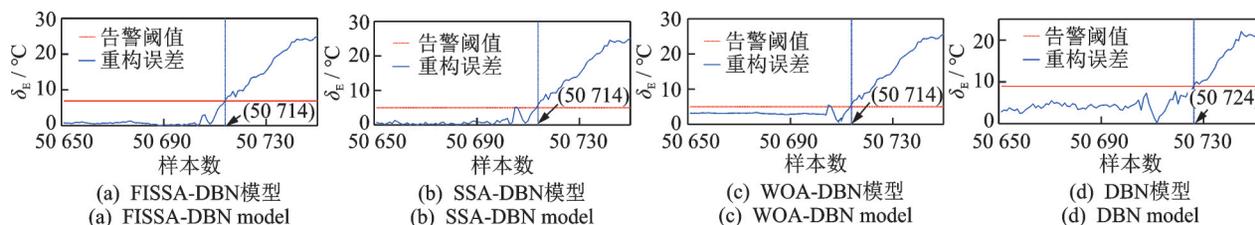


图 8 主轴异常状态监测  $\delta_E$  曲线图

Fig.8 Abnormal condition monitoring of main bearing  $\delta_E$

### 3.4 发电机定子异常状态监测

发电机定子有 6 个绕组温度传感器,笔者以发电机定子温度 2 作为研究对象,其输入输出参数如表 1 所示。运用 FISSA 寻找最佳适应度值,得到式(14)中  $\alpha, \beta$  和  $\lambda$  的值分别为 4, 82 和 0.021 5。

对 2013 年 19 号风电机组 SCADA 数据进行验证,选取数据为 2013-10-02T14:55~2013-10-07T11:35,即数据点 39 400~40 100。经过 FISSA-DBN 模型预测,发电机定子异常状态预测结果如图 9 所示,图 10 为定子异常状态监测  $\delta_E$  曲线图。图 10(a)中,在 39 409 点第 1 次出现  $\delta_E$  在告警阈值上限之上,预示定子绕组温度出现异常,后面曲线在告警阈值上下波动,一直到 39 704 点时,  $\delta_E$  开始直线上升,表明定子绕组 2 异常状态已经明显。在 40 002

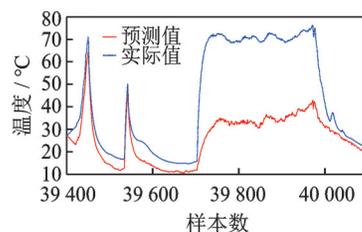
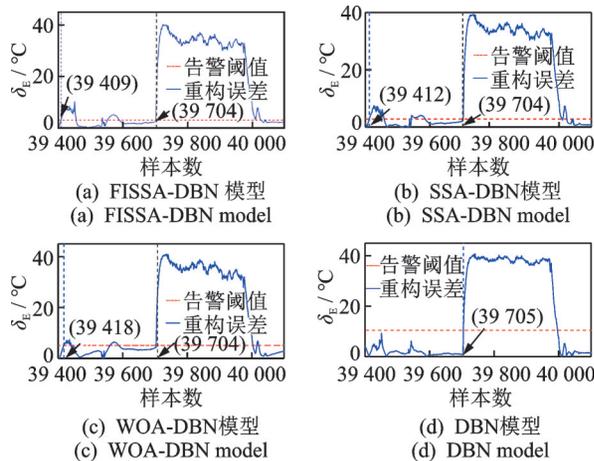


图 9 发电机定子异常状态预测结果

Fig.9 Prediction results of abnormal state of generator stator

点,即 2013-10-06T19:15,  $\delta_E$  下降到告警阈值下面。通过查阅记录,风电机组在该时刻停机,可以看出,最开始报警信号出现比实际停机时间提前 4 d 多。图 10(b)中最开始出现告警点为 39 412,比图 10(a)模型晚 30 min,而图 10(c)最开始出现告警点为 39 418,比图 10(a)模型晚 90 min。图 10(d)中,模型在 39 705 点,定子绕组温度异常明显时才检测

图10 定子异常状态监测  $\delta_E$  曲线图Fig.10 Abnormal state monitoring of stator  $\delta_E$  curve

出,比采用FISSA优化模型预测晚近50 h。

### 3.5 模型性能对比

采用均方根误差(root mean square error,简称RMSE)、平均绝对百分误差(mean absolute percentage error,简称MAPE)和平均绝对误差(mean absolute error,简称MAE)对4种预测模型的性能进行对比分析,3种状态下4000组测试数据为评价数据。表2为3种状态下各模型性能对比结果。可以看出,优化后的DBN模型误差比未优化的DBN小,有利于提高诊断的准确度。

表2 3种状态下各模型性能对比

Tab.2 Performance comparison of each model under three states

监测状态	模型	RMSE	MAPE/%	MAE
风电机组运行状态	FISSA-DBN	1.885	0.039 8	1.215
	SSA-DBN	1.924	0.041 3	1.255
	WOA-DBN	1.931	0.045 4	1.393
	DBN	3.407	0.082 5	2.453
主轴轴承异常状态	FISSA-DBN	1.608	0.026 1	1.088
	SSA-DBN	1.716	0.040 8	1.519
	WOA-DBN	1.630	0.026 8	1.093
	DBN	2.853	0.043 5	1.976
定子异常状态	FISSA-DBN	0.975	0.016 1	0.641
	SSA-DBN	1.556	0.024 2	0.941
	WOA-DBN	1.399	0.027 9	1.173
	DBN	2.509	0.067 4	2.431

## 4 结束语

针对风电机组通常工作在环境复杂多变、条件恶劣等维护不便的问题,笔者结合专家系统和皮尔

逊相关分析法,建立基于FISSA-DBN风电机组运行状态监测模型。利用重构误差和EWMA阈值监测风电机组部件的运行状态。通过华东某风电场的实际SCADA数据分析发现,FISSA-DBN模型的预测结果与风电机组实际运行记录相吻合,预测模型发现状态异常的时间早于记录时间,有利于工作人员尽早做出判断。对比SSA-DBN,WOA-DBN和DBN模型的综合结果表明,FISSA-DBN性能更佳,能有效监测风电机组部件的运行状态,实现早期故障预警。

## 参 考 文 献

- [1] 龙霞飞,杨苹,郭红霞,等.大型风力发电机组故障诊断方法综述[J].电网技术,2017,41(11):3480-3491. LONG Xiafei, YANG Ping, GUO Hongxia, et al. Review of fault diagnosis methods for large wind turbines [J]. Power System Technology, 2017, 41(11): 3480-3491. (in Chinese)
- [2] 程静,王维庆,樊小朝,等.基于二值双谱和模糊聚类的风电轴承故障诊断[J].振动、测试与诊断,2018,38(4):765-771. CHENG Jing, WANG Weiqing, FAN Xiaochao, et al. Bearing fault pattern recognition of wind turbine based on two-value bispectrum feature-fuzzy clustering method [J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(4): 765-771. (in Chinese)
- [3] 樊佶,齐咏生,高学金,等.基于形态学多重分形的风电机组轴承故障诊断[J].振动、测试与诊断,2021,41(6):1081-1089. FAN Ji, QI Yongsheng, GAO Xuejin, et al. Fault diagnosis of wind turbine bearing based on morphological multi-fractal analysis [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(6): 1081-1089. (in Chinese)
- [4] CUI Y, BANGALORE P, TJEMBERG L B. An anomaly detection approach based on machine learning and SCADA data for condition monitoring of wind turbines [C]//2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS). [S. l.]: IEEE, 2018: 1-6.
- [5] DU M, YI J, GUO J B, et al. Research on the application of neural networks on wind turbine SCADA data analysis [J]. Power System Technology, 2018, 42: 2200-2205.
- [6] 武鑫.基于数据驱动的风电机组关键部件监测预警技术研究[D].秦皇岛:燕山大学,2019.

- [7] 邓子豪,李录平,刘瑞,等.基于SCADA数据特征提取的风电机组偏航齿轮箱故障诊断方法研究[J].动力工程学报,2021,41(1):43-50.  
DENG Zihao, LI Luping, LIU Rui, et al. Research on diagnosis method of wind turbine yaw gearbox based on SCADA data feature extraction[J]. Journal of Chinese Society of Power Engineering, 2021, 41(1): 43-50. (in Chinese)
- [8] 龙霞飞.大型风力发电机组齿轮箱智能化故障诊断方法研究[D].广州:华南理工大学,2019.
- [9] 戴彦.新一代人工智能在智能电网中的应用研究综述[J].电力建设,2018,39(10):1-11.  
DAI Yan. Summary of application research of new generation artificial intelligence in smart grid[J]. Electric Power Construction, 2018, 39(10): 1-11. (in Chinese)
- [10] 郑小霞,陈广宁,任浩瀚,等.基于改进VMD和深度置信网络的风机易损部件故障预警[J].振动与冲击,2019,38(8):153-160.  
ZHENG Xiaoxia, CHEN Guangning, REN Haohan, et al. Fault detection of vulnerable units of wind turbine based on improved VMD and DBN [J]. Journal of Vibration and Shock, 2019, 38(8): 153-160. (in Chinese)
- [11] 向玲,王朋鹤,李京蓄.基于CNN-LSTM的风电机组异常状态检测[J].振动与冲击,2021,40(22):11-17.  
XIANG Ling, WANG Penghe, LI Jingxu. Abnormal state detection of wind turbines based on CNN-LSTM [J]. Journal of Vibration and Shock, 2021, 40(22): 11-17. (in Chinese)
- [12] 赵洪山,刘辉海.基于深度学习网络的风电机组主轴承故障监测[J].太阳能学报,2018,39(3):588-595.  
ZHAO Hongshan, LIU Huihai. Fault detection of wind turbine main bear based on deep learning network [J]. Acta Energiæ Solaris Sinic, 2018, 39(3): 588-595. (in Chinese)
- [13] 李梦诗,余达,陈子明,等.基于深度置信网络的风力发电机故障诊断方法[J].电机与控制学报,2019,32(2):114-122.  
LI Mengshi, YU Da, CHEN Ziming, et al. Fault diagnosis and isolation method for wind turbines based on deep belief network [J]. Electric Machines and Control, 2019, 32(2): 114-122. (in Chinese)
- [14] 王洪斌,王红,何群,等.基于深度信念网络的风机主轴承状态监测方法[J].中国机械工程,2018,29(8):948-953.  
WANG Hongbin, WANG Hong, HE Qun, et al. Condition monitoring method for wind turbine main bearings base on DBN [J]. China Mechanical Engineering, 2018, 29(8): 948-953. (in Chinese)
- [15] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines [C] //International Conference on International Conference on Machine Learning. [S.l.]: Omni Press, 2010:807-810.
- [16] HINTON G E. Deep belief networks [J]. Scholarpedia, 2009, 4(6):5947-5960.
- [17] HINRON G E, OSINDERO S, Teh Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1535.
- [18] BENGIO Y, LAMBLIN P, DAN P, et al. Greedy layer-wise training of deep networks [C] //International Conference on Neural Information Processing Systems. [S.l.]: MIT Press, 2006: 153-155.
- [19] 苏冠华.基于深度学习的滚动轴承智能故障诊断方法研究[D].秦皇岛:燕山大学,2019.
- [20] JIANKAI X, BO S. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [21] 田梦楚,薄煜明,陈志敏,等.萤火虫算法智能优化粒子滤波[J].自动化学报,2016,42(1):89-97.  
TIAN Mengchu, BO Yuming, CHEN Zhimin, et al. Firefly algorithm intelligence optimized particle filter [J]. Acta Automatica Sinica, 2016, 42(1): 89-97. (in Chinese)
- [22] 郁书好,杨善林,苏守宝.一种改进的变步长萤火虫优化算法[J].小型微型计算机系统,2014,35(6):1396-1400.  
YU Shuhao, YANG Shanlin, SU Shoubao. An improved variable step size firefly optimization algorithm [J]. Journal of Chinese Computer Systems, 2014, 35(6): 1396-1400. (in Chinese)



**第一作者简介:**周凌,男,1982年3月生,博士生。主要研究方向为风电机组智能检测与故障诊断。曾发表《Fault diagnosis and reconstruction of wind turbine anemometer based on RWSSA-AANN》(《Energies》,2021, Vol. 14)等论文。  
E-mail: 46930031@qq.com

**通信作者简介:**赵前程,男,1969年10月生,博士、教授、博士生导师。主要研究方向为机械测量测试与控制。  
E-mail: qczhao@hnust.edu.cn