

10-18-2021

Optimized-XGBoost Early Warning of Wind Turbine Generator Front Bearing Fault

Le Wei

1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;;

Xiaodong Hu

1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China; ;2. Department of Automation, North China Electric Power University, Baoding 071003, China;

Yin Shi

1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Optimized-XGBoost Early Warning of Wind Turbine Generator Front Bearing Fault

Abstract

Abstract: In order to identify the abnormal running state of the generator in time, a wind turbine generator front bearing fault early warning method based on *Bayesian optimized extreme gradient boosting algorithm* is proposed. The historical data collected by SCADA (Supervisory Control And Data Acquisition) are preprocessed by effective data preprocessing methods. The temperature prediction model of the front bearing of wind turbine generator is constructed based on the Bayesian-optimized XGBoost (eXtreme Gradient Boosting) algorithm and *the fault early warning threshold of the front bearing of the wind turbine generator is determined based on the 3σ criterion*. The experimental results show that the proposed method can detect the abnormal signals of the front bearing of the wind turbine generator in advance. Compared with the models established by random search and grid search, the advantages of Bayesian optimization model in generalization performance and prediction accuracy are verified.

Keywords

XGBoost (eXtreme Gradient Boosting) algorithm, wind turbine, failure early warning, Bayesian optimization

Recommended Citation

Wei Le, Hu Xiaodong, Yin Shi. Optimized-XGBoost Early Warning of Wind Turbine Generator Front Bearing Fault[J]. Journal of System Simulation, 2021, 33(10): 2335-2343.

基于优化 XGBoost 的风电机组发电机前轴承故障预警

魏乐¹, 胡晓东^{1,2*}, 尹诗¹

(1. 华北电力大学 控制与计算机工程学院, 北京 102206; 2. 华北电力大学 自动化系, 河北 保定 071003)

摘要: 为了及时有效地识别发电机的异常运行状态, 提出了基于贝叶斯优化极限梯度提升算法的风电机组发电机前轴承故障预警方法: 利用有效的数据预处理方法处理数据采集与监视控制系统历史数据; 基于贝叶斯优化的 XGBoost (eXtreme Gradient Boosting) 算法构建风电机组发电机前轴承温度预测模型; 基于 3σ 准则, 确定风电机组发电机前轴承故障预警阈值。实验结果表明所提方法能提前监测到风电机组发电机前轴承异常信号。通过与采用随机搜索和网格搜索所建立的模型进行对比分析, 验证了贝叶斯优化模型在泛化性能和预测精度上具有优势。

关键词: XGBoost (eXtreme Gradient Boosting) 算法; 风电机组; 故障预警; 贝叶斯优化

中图分类号: TH133.3; TP391 文献标志码: A 文章编号: 1004-731X (2021) 10-2335-09

DOI: 10.16182/j.issn1004731x.joss.20-0538

Optimized-XGBoost Early Warning of Wind Turbine Generator Front Bearing Fault

Wei Le¹, Hu Xiaodong^{1,2*}, Yin Shi¹

(1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;

2. Department of Automation, North China Electric Power University, Baoding 071003, China)

Abstract: In order to identify the abnormal running state of the generator in time, a wind turbine generator front bearing fault early warning method based on *Bayesian optimized extreme gradient boosting algorithm* is proposed. The historical data collected by SCADA (Supervisory Control And Data Acquisition) are preprocessed by effective data preprocessing methods. The temperature prediction model of the front bearing of wind turbine generator is constructed based on the Bayesian-optimized XGBoost (eXtreme Gradient Boosting) algorithm and *the fault early warning threshold of the front bearing of the wind turbine generator is determined based on the 3σ criterion*. The experimental results show that the proposed method can detect the abnormal signals of the front bearing of the wind turbine generator in advance. Compared with the models established by random search and grid search, the advantages of Bayesian optimization model in generalization performance and prediction accuracy are verified.

Keywords: XGBoost (eXtreme Gradient Boosting) algorithm; wind turbine; failure early warning; Bayesian optimization

引言

风能是成为现阶段发展最快的可再生能源之一, 风力发电在全球电力生产结构中的占比逐年上升, 并拥有广阔的发展前景。风电机组的发电机是

连接齿轮箱和电网的核心部件, 主要功能是将机械能转换为电能, 是风电机组的薄弱环节, 发电机一旦损坏, 其维修费用高、周期长, 严重影响风电场的经济效益^[1]。

风电机组发电机的故障预警能够在故障发生

收稿日期: 2020-07-28 修回日期: 2020-09-12

基金项目: 国家自然科学基金(51676068); 华能集团总部科技项目(HNKJ20-H88)

第一作者: 魏乐(1976-), 女, 满族, 博士, 教授, 研究方向为控制系统建模及故障诊断。E-mail: 1638887543@qq.com

通讯作者: 胡晓东(1995-), 男, 藏族, 硕士生, 研究方向为风电机组故障预警。E-mail: hu_xiaod@163.com

前预警发电机的异常运行状态,为现场运维工作人员合理地制定运维计划及维修预留必要的时间。有效而可靠的预警技术不仅能够实时监测发电机运行的状态参数、掌握发电机健康状态,还能发现潜在的故障。

发电机的故障主要有:发电机震动过大、发电机过热、轴承过热、偏心震动、转子/定子线圈短路等^[2]。在发电机的所有故障中,轴承的故障率为 40%,是发电机中发生故障频率最高的故障^[3];而发电机前轴承温度异常又是表征发电机故障的重要指标^[4]。因此本文从发电机前轴承温度为切入点研究发电机的故障预警。

目前对风电机组发电机故障预警的研究主要基于风电机组状态监测系统震动数据或 SCADA (Supervisory Control And Data Acquisition)数据。由于震动数据信号的采集需要加装传感器,且震动信号具有非线性、低信噪比、信号复杂等问题,因此难以直接从原始信号中挖掘有用的特征信息,需借助信号处理的方法^[5]。而 SCADA 系统是风电机组必备的数据采集装置,基于 SCADA 数据的预警技术具有良好的现场实施条件,因此基于 SCADA 数据的研究更受学者欢迎。

文献[6]利用 SCADA 数据,采用基于工况辨识的 Bi-RNN 神经网络与随机森林算法相结合建立预警模型对风电机组主轴承运行状态进行监测。文献[7]提出了基于大数据挖掘的发电机组温升故障预警方法,通过温度残差趋势实现预警。文献[8]采用最小二乘曲面拟合算法建立主轴温度预测模型,预测精度有了较大的提升。

以上研究在不同程度上对风电机组关键核心部件的状态监测和故障预警起到了推动作用,但是普遍存在超参数假设性强、预测模型的可靠性不足、泛化能力弱等问题,限制了故障预测实用性的进一步提升。且现有的方法大多以固定阈值进行故障判断,需要根据运行状态调整阈值,这在一定程度上影响了诊断的准确性和有效性。

相较于其他建立预测模型的机器学习算法,优

化 XGBoost (eXtreme Gradient Boosting)算法更加注重模型复杂度的控制和模型的泛化能力,适合于工程实现。但是, XGBoost 算法面临着缺乏对模型预测精度有较大影响的众多超参数的高效优化方法。

在机器学习模型的超参数调优中,只能看到模型的输入和输出,不能获取模型训练过程的梯度信息,也不能假设模型超参数和最终指标符合凸优化条件,所以很难通过求导及凸优化方法求得模型超参数最优解^[9]。目前常用的超参数调优方法有网格搜索、随机搜索和贝叶斯优化。

基于以上分析,本文提出了以发电机前轴承温度为切入点、根据 SCADA 数据、基于贝叶斯优化超参数的 XGBoost 算法的风电机组发电机前轴承故障预警方法:通过贝叶斯优化的 XGBoost 算法建立发电机前轴承温度预测模型,监测发电机前轴承温度实际值与预测值的变化趋势,利用滑动窗口实时监控发电机前轴承的运行状态,提高预警精确度。

1 问题的分析和解决方案

图 1 给出了发电机前轴承故障预警的流程。从图 1 可以分析出预测模型的泛化能力及其准确性以及故障阈值选取的合理性,直接决定着故障预警的精确度。

(1) 关于预测模型泛化能力及准确性的预测模型建模方法的选取问题:本文选用 XGBoost 算法来建立风电机组发电机前轴承温度的预测模型。对 XGBoost 算法中的超参数,采用贝叶斯优化方法进行优化,同时与网格搜索和随机搜索优化方法进行对比分析。

(2) 关于故障预警值选取合理性的故障阈值选取方法问题:由于温度预测模型是基于正常运行数据训练得到的,因此可以根据预测模型输出的温度预测值,建立风电机组发电机前轴承正常行为模型,再结合 3σ 准则和滑动窗口设定动态阈值,对实时运行机组进行在线状态监测,从而实现故

障预警。

图 1 所示故障预警系统从功能上可以划分为: 数据准备、温度预测、确定阈值、故障预警 4 个部分。本文后续内容将围绕着这 4 个功能块展开。

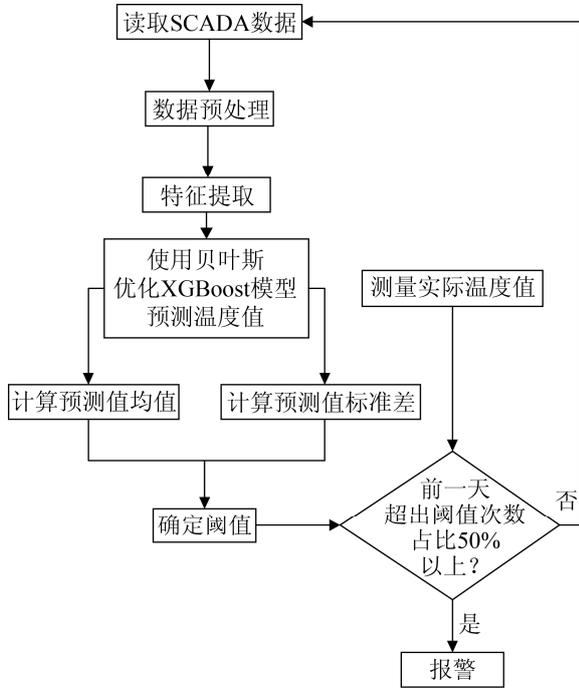


图 1 故障预警流程图

Fig. 1 Flow chart of fault early-warning

2 数据准备

2.1 SCADA 数据采集

本文所采用的 SCADA 数据出自河北某风电场, 该风电场切入风速为 3 m/s, 切出数据为 25 m/s。其中的风机都是由联合动力生产的型号为 UP82-1500 的双馈异步发电机组。

为了消除偶发性的故障对发电机前轴承温度预测模型精度的影响, 本文随机选取了 10 台该风场内稳定运行的机组的历史 SCADA 数据(共 36 378 组)对发电机前轴承温度预测模型进行训练和测试, 这 10 台正常运行风机的生产厂家和型号相同, 且都处于同一个风电场、地理环境相似, 能够表征该风电场正常机组的所有运行工况。

另外随机选取没有参与预测模型训练与测试的 6 台(3 台没有发生过故障, 3 台发生过故障)机组

的数据(共 11 968 组)验证本文提出方法的有效性。

2.2 去除异常噪声数据

由于存在风电机组所处运行环境受外部环境影响、传感器损坏、SCADA 系统宕机、数据传输网络等因素, SCADA 数据中夹杂着很多异常噪声数据, 需要去除。

去除异常噪声数据的具体步骤为:

step 1: 采用分区间 bin 方法按风速 0.5 m/s 的间隔将工况区间划分为多个子工况区间。

step 2: 采用统计学中四分位原理^[10]对每个子工况区间的 SCADA 数据进行清洗。

如图 2 所示, 为了说明异常噪声数据的去除效果, 本文对#09 风电机组(随机选取自 2.1 节提到的 10 台风电机组)历史的 SCADA 数据(如图 2 中蓝色及红色数据点)进行了异常噪声数据去除。图 2 中蓝色的数据点是去除后的数据, 红色的数据点是异常噪声数据。

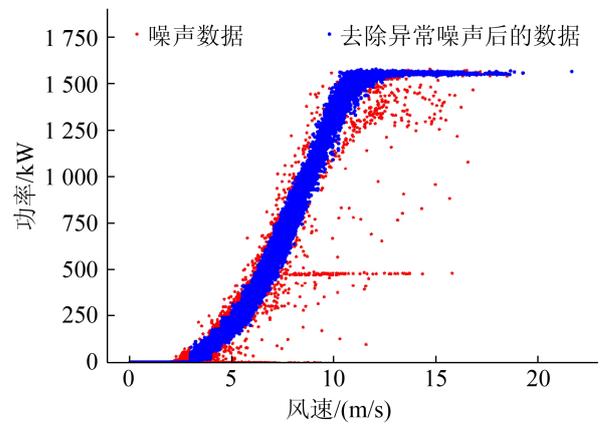


图 2 风功率 SCADA 数据去除异常噪声效果图

Fig. 2 Effect chart of abnormal noise removal by wind power SCADA data

2.3 数据特征选取

SCADA 系统采集的数据包括近百个维度的数据, 其中很多参数与机组发电机无关, 因此需要对 SCADA 数据进行特征提取, 本文应用相关系数收敛快、可解释性好、且对数据分布没有特殊要求的斯皮尔曼相关性分析方法提取能直接或者间接反

映风电机组发电机前轴承温度特征的特征集。斯皮尔曼相关系数的计算步骤^[11]为:

step 1: SCADA 数据特征中发电机前轴承温度定义为 \mathbf{Y} , 其他特征定义为 $\mathbf{X}_i (i=1,2,\dots,N)$, 其中 N 为除去发电机前轴承温度后 SCADA 数据特征总数。将 \mathbf{X}_i 和 \mathbf{Y} 列所对应的数据转换为各自列向量的排名, 记为 $R(\mathbf{X}_i)$ 和 $R(\mathbf{Y})$ 。

step 2: 计算各组数据 $R(\mathbf{X}_i)$ 和 $R(\mathbf{Y})$ 之间的差异的平方, 再求和, 记为 d 。

step 3: 计算两个列向量 \mathbf{X}_i 和 \mathbf{Y} 之间的相关系数 R_s :

$$R_s = 1 - \frac{6 \times d}{M(M^2 - 1)} \quad (1)$$

式中: M 为 SCADA 特征数据的列向量长度, 一般认为当相关系数高于 0.8 时特征之间的相关性为强相关, 因此, 如表 1 所示, 保留了 SCADA 数据中与发电机前轴承温度相关系数高于 0.8 的发电机转速、机舱温度、L1 电流等 9 项特征作为温度预测模型的输入特征。

表 1 斯皮尔曼相关性系数
Tab. 1 Spearman correlation coefficient

| 选取特征名称 | 斯皮尔曼相关性系数 | 特征编号 |
|-----------|-----------|-------|
| 发电机转速 | 0.809 | A_1 |
| 机舱温度 | 0.849 | A_2 |
| 发电机 U 相温度 | 0.965 | A_3 |
| 风速 | 0.816 | A_4 |
| 发电机后轴承温度 | 0.988 | A_5 |
| 轮毂温度 | 0.912 | A_6 |
| 中控箱温度 | 0.887 | A_7 |
| 桨角温度 | 0.908 | A_8 |
| L1 电流 | 0.801 | A_9 |

2.4 数据归一化处理

提取的特征中往往具有不同的量纲和量纲单位, 为了消除特征之间的量纲影响, 需要进行数据归一化处理:

$$\bar{x}_{A_i} = \frac{x_{A_i} - \text{avg}(A_i)}{\max(A_i) - \min(A_i)} \quad (2)$$

式中: x_{A_i} 为样本 x 在 SCADA 特征 A_i 上的数据值,

$(i=1,2,\dots,9)$; $\text{avg}(A_i)$ 为特征 A_i 的均值; $\max(A_i)$ 为特征 A_i 的最大值; $\min(A_i)$ 为特征 A_i 的最小值; \bar{x}_{A_i} 为归一化以后的 x_{A_i} 。

3 温度预测

将预处理后的数据输入到贝叶斯优化 XGBoost 温度预测模型, 即可得到预测的温度值。下面是预测模型的建模过程。

3.1 超参数的优化目标的确定

XGBoost 每次迭代的目标函数为:

$$\bar{L}^* = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (3)$$

其中:

$$G_j = \sum_{i \in I_j} \frac{\partial l(y_i, \hat{y}_i^{(t-1)})}{\partial \hat{y}_i^{(t-1)}}, H_j = \sum_{i \in I_j} \frac{\partial^2 l(y_i, \hat{y}_i^{(t-1)})}{\partial (\hat{y}_i^{(t-1)})^2} \quad (4)$$

式中: T 为树叶子节点数; j 为每个叶子节点的索引; i 为数据集中的 i 第个样本; y_i 为真实值; $\hat{y}_i^{(t-1)}$ 为 $t-1$ 次迭代中的预测值, 定义索引为 j 的叶子上的样本的集合是 I_j ; γ 为自定的控制叶子数量的参数。

超参数优化的公式为:

$$x^* = \arg \min_{x \in X} \bar{L}^* \quad (5)$$

式中: X 为 x 可选的数据集; \bar{L}^* 为 XGBoost 的目标函数; x^* 为使目标函数最优时 X 中的一组 x 。

3.2 预测模型数据集的选取

本文选用的 10 台稳定运行机组的历史 SCADA 数据经 2.2 节所述方法去除异常值后得到共 29 099 组数据, 这些数据的 70% 用作训练集去训练发电机前轴承温度预测模型, 剩余的 30% 数据用作测试集去测试发电机前轴承温度预测模型的精度。

3.3 实验环境的设置

本文所有实验运行环境均为: Windows10 操作系统, python 3.7.1 版本, anaconda3 集成开发环境。XGBoost 算法调用的是 sklearn API, 贝叶斯优

化所调用的包为 `bayes_opt`, 作为对比的网格搜索和随机搜索调用的是 `sklearn` API。

3.4 XGBoost 算法待优化超参数的选取

XGBoost 算法中主要包含 3 类超参数: 常规参数、提升器参数、任务参数。对于同一个超参数, 用贝叶斯优化、网格搜索、随机搜索三种方法搜索超参数的取值范围相同。表 2 为本文设定的超参数取值范围, 其他超参数保持默认设定值。

表 2 XGBoost 超参数设定范围及含义
Tab. 2 Range and meaning of XGBoost hyperparameters

| 超参数 | 超参数范围 | 超参数含义 |
|-------------------------------|------------|-----------|
| <code>n_estimators</code> | (0,500) | 树的数量 |
| <code>subsample</code> | (0,1) | 随机抽取的样本比例 |
| <code>Eta</code> | (0.01,0.2) | 特征权重缩减系数 |
| <code>max_depth</code> | (5,30) | 树的最大深度 |
| <code>colsample_bytree</code> | (0,1) | 特征随机采样比例 |
| <code>gamma</code> | (0,30) | 复杂度的惩罚项 |
| <code>lambda</code> | (0,15) | L2 正则项参数 |
| <code>max_child_weight</code> | (0,10) | 叶子节点权重之和 |

3.5 基于贝叶斯优化算法的超参数寻优流程

在确定 XGBoost 算法超参数范围后, 利用贝叶斯进行超参数寻优, 其流程为:

- (1) 设定 XGBoost 算法超参数范围。
- (2) 将贝叶斯优化算法嵌套到 XGBoost 算法中选择超参数。
- (3) 基于贝叶斯优化算法寻找组合参数的惩罚函数的最优值。
- (4) 将全局最优参数组合输入 XGBoost 算法进行训练, 计算 XGBoost 算法预测精度。
- (5) 如满足要求, 输出最优超参数值, 不符合返回(3)。

3.6 超参数寻优方法性能比较

贝叶斯优化、随机搜索、网格搜索在模型超参数寻优过程中采用平均绝对误差 (MSE), r^2 (r^2_score), 寻优时间(t)作为评估指标。三种寻优方法性能比较结果见表 3。

由表 3 可知, 相比于网格搜索和随机搜索, 贝叶斯优化方法在寻优时间上占很大优势, 其寻优时间大约是随机搜索的 1/3, 是网格搜索的 1/6; 贝叶斯优化方法在测试集中的平均绝对误差均小于其他两种超参数寻优算法; 贝叶斯优化方法的 r^2 分数也是 3 种方法中最高的。这些数据表明: 贝叶斯优化后的 XGBoost 算法具有较高的预测精度和泛化能力。因此, 选择贝叶斯寻优的超参数作为模型的初始化参数, 然后对模型进行训练和预测。图 3 为贝叶斯优化 XGBoost 算法在测试上的状态预测图。由预测结果可知, 发电机前轴承温度预测值和真实值基本吻合。预测值减去真实值为残差值, 残差值中最大值为 0.175 4, 残差平均值为 0.007 8, 该模型的具有很好的预测精度。

表 3 XGBoost 寻优方法性能比较

Tab. 3 Comparison of optimization model

| 寻优方法 | MSE | r^2 | t/s |
|-------|-------|-------|-------|
| 贝叶斯优化 | 0.006 | 0.896 | 1 122 |
| 随机搜索 | 0.008 | 0.864 | 3 257 |
| 网格搜索 | 0.020 | 0.827 | 6 212 |

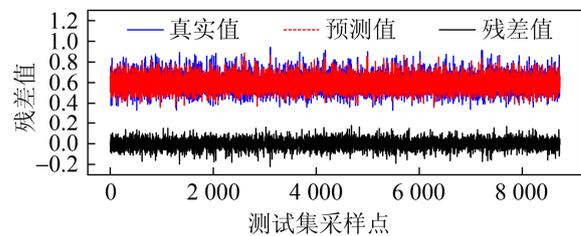


图 3 测试集状态预测

Fig. 3 Test set state prediction chart

4 确定预警阈值

当机组处于正常状态时, 发电机前轴承温度处于受控状态, 不会出现温度过高或者温度突变的情况^[12], 预测模型预测的发电机前轴承温度与发电机前轴承实际温度值偏差不大; 当机组发电机前轴承出现异常(如轴承不平衡、轴承不对中、内圈损伤、外圈损伤等)时, 由于摩擦生热, 使得发电机前轴承的实际温度值将会远远偏离预测模型预测的理论温度值。在本文中通过滑动窗口监测异常点出现

的次数占比就能实现故障预警的目的。待监测机组由于环境因素致使风电机组工况变化频繁时,出现少量发电机前轴承温度值超出阈值属于正常现象。但是,待监测机组发电机前轴承实际温度值前一天有 50% 的温度值超出阈值时,基本能判定发电机出现了不稳定的情况,在一定程度上能反映发电机前轴的异常运行状态。

3σ 准则是指假设一组监测数据只含有随机误差,对其进行计算得到均值和标准偏差。根据正态分布置信区间原理,待监测数据分布在 $[\mu_z-3\sigma, \mu_z+3\sigma]$ 中的概率为 0.997 3,凡是超过这个区间的数据就是异常值。在此处 μ_z 代表模型预测的一天的发电机前轴承温度值的均值, σ 代表模型预测的一天的发电机前轴承温度的标准偏差。

本文所采用的预警阈值的确定步骤为:

step 1: 建立基于贝叶斯优化 XGBoost 算法的风电机组发电机前轴承温度预测模型。

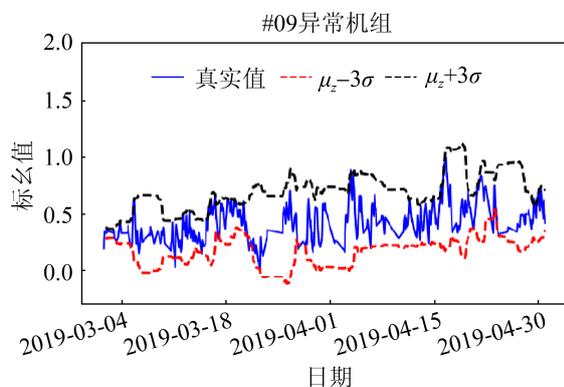
step 2: 将待检测机组的特征数据输入到(1)所建模型中,预测出发电机前轴承温度值。

step 3: 选择滑动窗口宽度 $N=144$ (一天),对窗口内的发电机前轴温度预测值计算 μ_z 和 σ 。

step 4: 分别以当天 $\mu_z+3\sigma$ 和 $\mu_z-3\sigma$ 为上、下限阈值,当前一天发电机前轴实际值温度值超限次数占比超过 50% 时,则进行报警。

5 实例应用验证

如 2.1 节中提到的,为了验证本文提出的故障



(a) #09 机组状态监测情况

预警方法的有效性,另外选取没有参与预测模型训练与测试的河北某风电场的 3 台正常机组(机组 #13、#32、#93)和 3 台异常机组(机组 #84、#09、#91)的 SCADA 数据(共 11 968 组)进行测试。异常机组数据选取系统报警点前两个月数据。正常机组数据随机选取两个月数据。这 6 台机组的工作状态正常与否都是由通过某电力公司审批的故障申诉记录得知。

5.1 应用实例的实际故障情况

3 台异常机组的具体故障情况为:

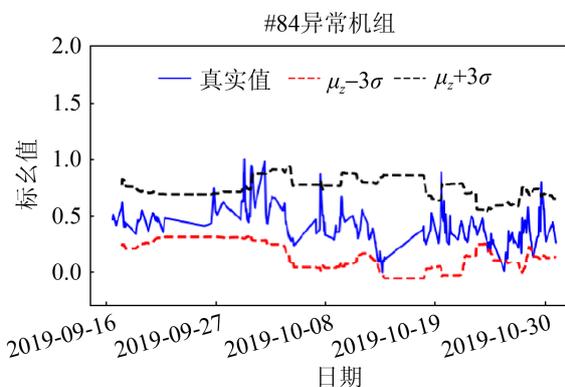
(1) 机组 #09 由故障申诉记录得到在 2019-04-23 T 14:02 报警,诊断为发电机内圈损伤。

(2) 机组 #84 由故障记录申诉得到该机组在 2019-10-31 T 10:40 发电机轴承高温报警,诊断结果为前轴承不平衡。

(3) 机组 #91 由故障申诉记录得到在 2019-04-19 T 10:32 报警,诊断为发电机外圈损伤。

5.2 实验结果分析

图 4 为 6 台机组的状态监测情况,蓝色的实线是风电机组发电机前轴承的实际温度值,黑色虚线是对发电机前轴承预测温度值通过 $\mu_z+3\sigma$ 公式计算得到的上限阈值,红色虚线是对发电机前轴承预测温度值通过 $\mu_z-3\sigma$ 公式计算得到的下限阈值。图 5 为 6 台机组的状态判断情况。



(b) #84 机组状态监测情况

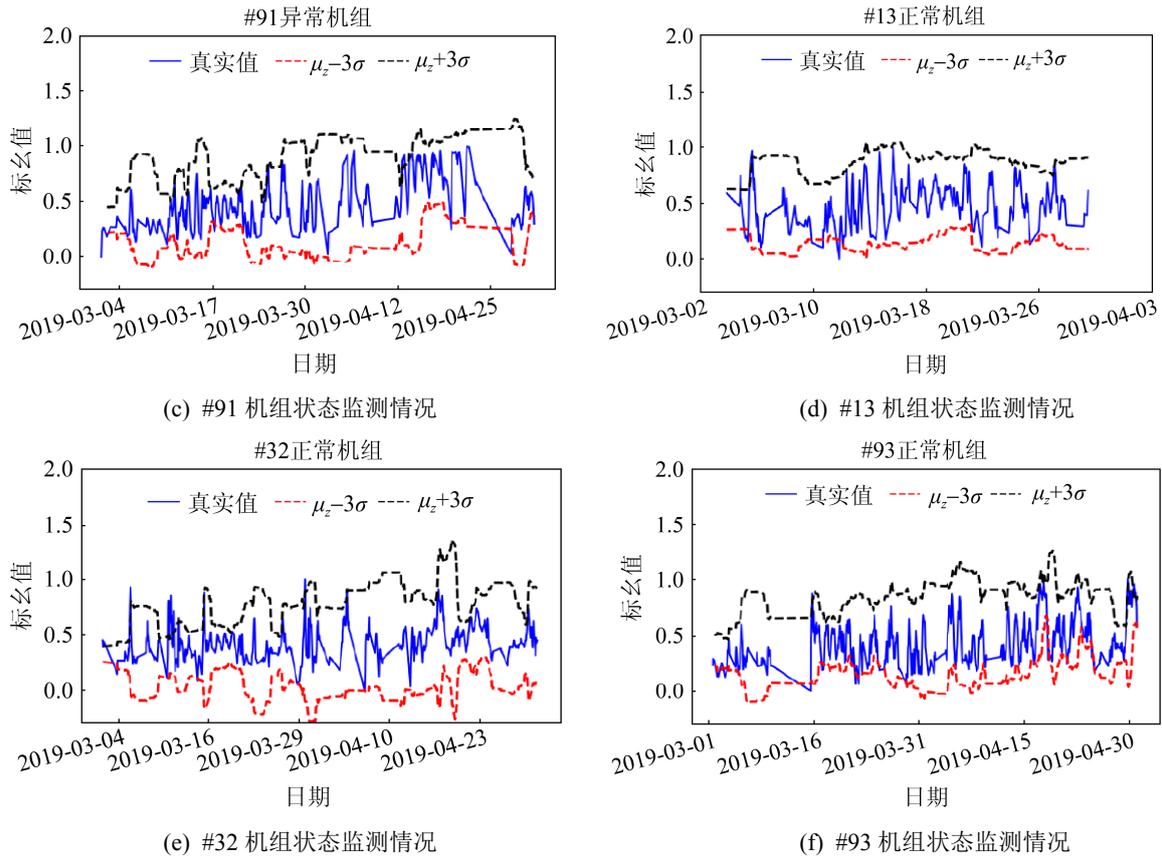
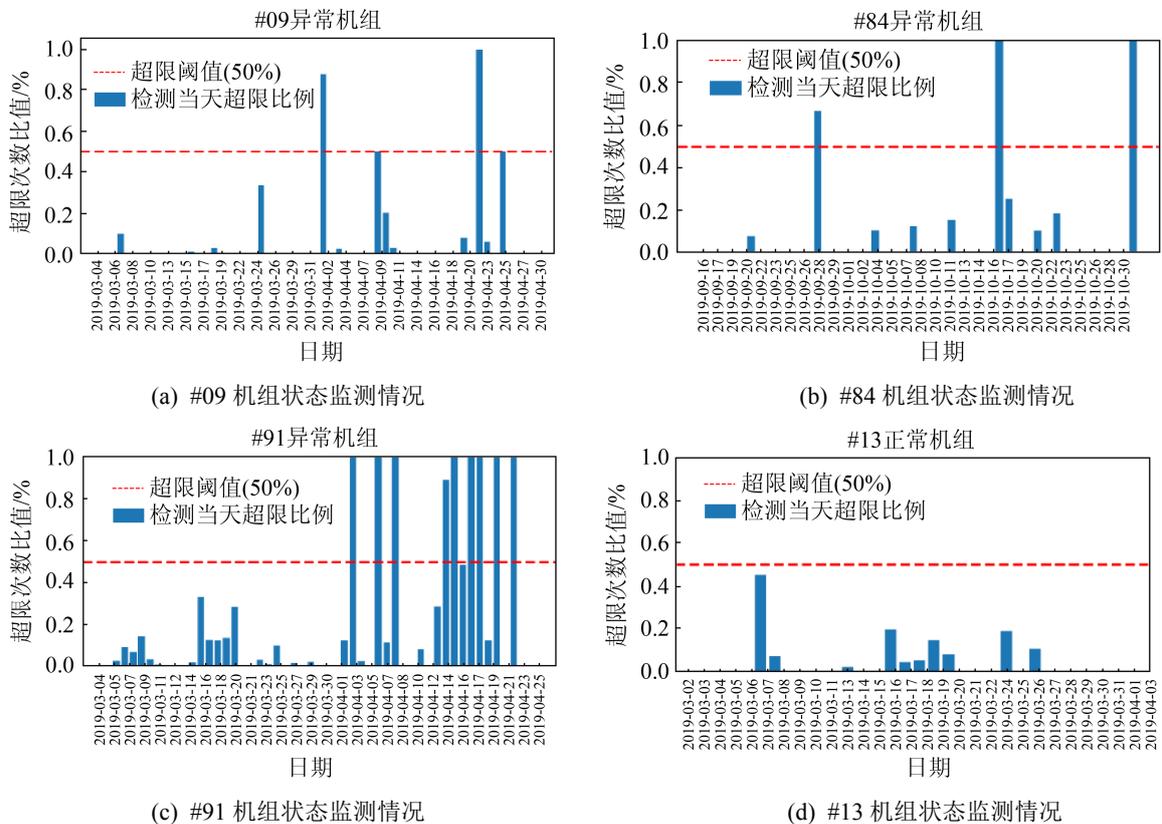


图 4 测试机组状态监测情况
Fig. 4 Test unit condition monitoring



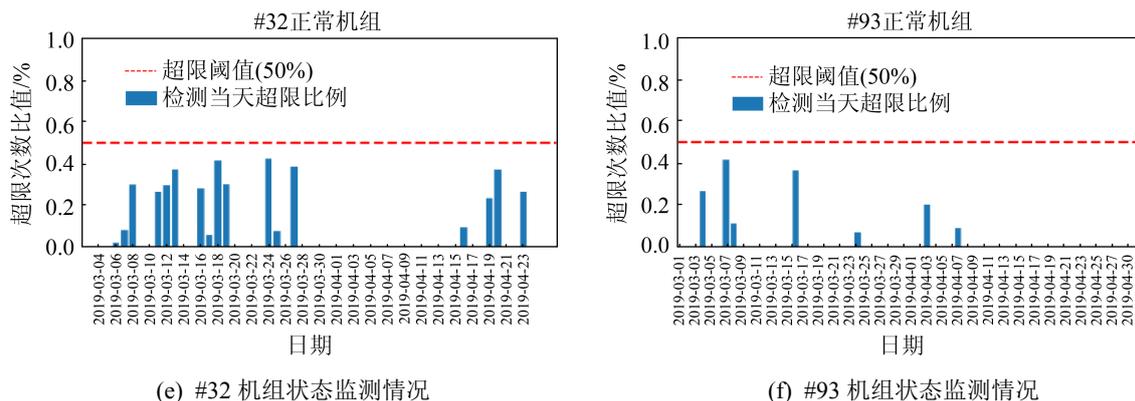


图 5 测试机组状态判断情况
Fig. 5 Test unit condition judgment

由图 5(a)可知机组#09 在 2019 年 4 月 1 日, 2019 年 4 月 21 日有 50% 以上的发电机前轴承实际值超出阈值, 判定该机组发电机前轴承为异常运行状态, 比 SCADA 监控系统早 22 天预警。

由图 5(b)可知机组#84 在 2019 年 9 月 28 日, 2019 年 10 月 16 日, 2019 年 10 月 31 日有 50% 以上的发电机前轴承实际温度值超过阈值, 判定该机组发电机前轴承为异常运行状态, 比 SCADA 监控系统早 32 天进行预警。

由图 5(c)可知机组#91 在 2019 年 4 月 2 日、2019 年 4 月 5 日, 7 日, 13 日, 14 日, 16 日, 19 日, 21 日都有 50% 以上的发电机前轴承真实值超出阈值, 判断该机组发电机前轴承为异常运行状态, 比 SCADA 监控系统早预警 17 天。

由图 5(d)中可知机组#13 发电机前轴承温度真实值虽有超限, 但是超限比例没有达到异常的判定标准, 判定该机组发电机前轴承为正常运行状态。

同理可以判定, 图 5(e), 5(f)判定#32, #93 机组发电机前轴承为正常运行状态。

6 结论

本文基于河北某风电场采集的历史 SCADA 数据, 利用 XGBoost 算法构建发电机前轴承温度预测模型对风电机组发电机前轴承进行异常状态监测, 于此同时采用贝叶斯优化算法对 XGBoost 算法进行超参数寻优。

(1) 贝叶斯优化 XGBoost 算法相对网格搜索和随机搜索迭代有更高的效率。贝叶斯优化迭代次数少且效果好, 寻优时间大约是随机搜索的 1/3, 是网格搜索的 1/6。贝叶斯优化后的 XGBoost 温度预测模型的预测精度和泛化性能均优于网格搜索和随机搜索。

(2) 通过 6 台(3 台正常, 3 台异常) 1.5 MW 双馈异步发电机组为测试对象, 实验结果表明: 该方法能有效监测到风电机组发电机前轴承异常信号, 对风电机组设备运行维修具有借鉴意义。

本文建模方法简单易行, 可扩展到同样以温度为观测特征的 1.5 MW 双馈异步发电机组的其他机械部件, 如风电机组的主轴、齿轮箱轴承等。

参考文献:

- [1] 李泽宇, 郭创新, 朱承治. 采用 GA-BPNN 与 TLS 模型的风电机组异常辨识方法[J]. 电力系统自动化, 2020, 44(9): 95-102.
Li Zeyu, Guo Chuangxin, Zhu Chengzhi. Anomaly Identification Method of Wind Turbine Based on Gene Algorithm-back Propagation Neural Network and t-location Scale Model[J]. Automation of Electric Power Systems, 2020, 44(9): 95-102.
- [2] 吴定会, 祝志超, 韩欣宏. 基于 BO-SDAE 多源信号的风电机组轴承故障诊断[J]. 系统仿真学报, 2021, 33(5): 1148-1156.
Wu Dinghui, Zhu Zhichao, Han Xinhong. Fault Detection of Wind Turbine Bearing Based on BO-SDAE Multi-source Signal[J]. Journal of System Simulation, 2021, 33(5): 1148-1156.

- [3] 陈雪峰, 郭艳婕, 许才彬, 等. 风电装备故障诊断与健康监测研究综述[J]. 中国机械工程, 2020, 31(2): 175-189.
Chen Xuefeng, Guo Yanjie, Xu Caibin, et al. Review of Fault Diagnosis and Health Monitoring for Wind Power Equipment[J]. China Mechanical Engineering, 2020, 31(2): 175-189.
- [4] 杨文珺, 何婷, 王贵军. 风力发电机组的故障及维护策略[J]. 机械研究与应用, 2019, 32(5): 190-193, 198.
Yang Wenjun, He Ting, Wang Guijun. Faults and Maintenance Strategy of Wind Turbine[J]. Mechanical Research & Application, 2019, 32(5): 190-193, 198.
- [5] 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.
Wu Xin. Research on Data-Driven Monitoring And Warning Technologies for Critical Components in Wind Turbines[D]. Qinhuangdao: Yanshan University, 2019.
- [6] 尹诗, 侯国莲, 于晓东, 等. 基于 Bi-RNN 的风电机组主轴温度预警方法研究[J]. 郑州大学学报(工学版), 2019, 40(5): 45-51.
Yin Shi, Hou Guolian, Yu Xiaodong, et al. Research on Temperature Prediction Method for Main Bearing of Wind Turbine Based on Bi-RNN[J]. Journal of Zhengzhou University (Engineering Science), 2019, 40(5): 45-51.
- [7] 李俊卿, 王焕仲, 季刚, 等. 基于大数据分析的风机轴承故障预警[J]. 智慧电力, 2020, 48(2): 25-30.
Li Junqing, Wang Huanzhong, Ji Gang, et al. Fault Early Warning of Wind Turbine Bearing Based on Big Data Analysis[J]. Smart Power, 2020, 48(2): 25-30.
- [8] 董兴辉, 马晓双, 程友星, 等. 风电机组轴承健康劣化趋势建模与仿真[J]. 系统仿真学报, 2019, 31(1): 151-157, 165.
Dong Xinghui, Ma Xiaoshuang, Cheng Youxing, et al. Modeling and Simulation of Health Degradation Trend for Wind Turbine Bearing[J]. Journal of System Simulation, 2019, 31(1): 151-157, 165.
- [9] 陈明华, 刘群英, 张家枢, 等. 基于 XGBoost 的电力系统暂态稳定预测方法[J]. 电网技术, 2020, 44(3): 1026-1034.
Chen Minghua, Liu Qunying, Zhan Jiashu, et al. XGBoost-based Algorithm for Post-fault Transient Stability Status Prediction[J]. Power System Technology, 2020, 44(3): 1026-1034.
- [10] 沈小军, 付雪皎, 周冲成, 等. 风电机组风速-功率异常运行数据特征及清洗方法[J]. 电工技术学报, 2018, 33(14): 3353-3361.
Shen Xiaojun, Fu Xuejiao, Zhou Chongcheng, et al. Characteristics of Outliers in Wind Speed-Power Operation Data of Wind Turbines and Its Cleaning Method[J]. Transactions of China Electrotechnical Society, 2018, 33(14): 3353-3361.
- [11] 许清. 基于运行数据的风电机组故障诊断的研究[D]. 保定: 华北电力大学, 2019.
Xu Qing. Research on Fault Diagnosis of Wind Turbine Based on Operation Data[D]. Baoding: North China Electric Power University, 2019.
- [12] 谭博文. 风电机组齿轮箱高速轴端滚动轴承漏电流故障研究[D]. 南京: 南京理工大学, 2017.
Tan Bowen. Rolling Bearing at Wind Turbine Gearbox High Speed End[D]. Nanjing: Nanjing University of Science and Technology, 2017.