

DOI: 10.13382/j.jemi.B2306457

基于图注意力和时间卷积网络的风电齿轮箱故障预警方法*

王鹏飞¹ 刘长良^{1,2} 徐健¹ 刘卫亮^{1,2}

(1. 华北电力大学控制与计算机工程学院 保定 071000; 2. 保定市综合能源系统状态检测与优化调控重点实验室 保定 071000)

摘要:针对风电齿轮箱故障预警中数据信息挖掘不充分问题,提出一种基于图注意力和时间卷积网络的风电齿轮箱故障预警方法。分别从时间与空间尺度建立各特征点的物理联系,拓宽特征维度以提升故障预警精度。图注意力网络构建不同数据测点间的空间拓扑结构,遍历每个节点的相邻节点进行加权求和达到聚合信息的目的;时间卷积网络使用特殊的因果膨胀卷积和残差网络,扩大感受野,提升时间特征捕捉能力。以华北某风电场实际数据为例进行验证,结果表明,提出方法能够在故障发生前122 h监测到风电齿轮箱的异常状态并发出预警信号;与其他方法进行对比,提出方法预警时间提前52~63 h,模型预测误差减小1.05%~3.76%;使用t-SNE和概率密度曲线提升结果可解释性。

关键词:风电齿轮箱;故障预警;图注意力网络;时间卷积网络

中图分类号: TM315 **文献标识码:** A **国家标准学科分类代码:** 480.6040

Wind turbine gearbox fault warning method based on graph attention and temporal convolutional network

Wang Pengfei¹ Liu Changliang^{1,2} Xu Jian¹ Liu Weiliang^{1,2}

(1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071000, China;

2. Baoding Key Laboratory of State Detection and Optimization Regulation for Integrated Energy System, Baoding 071000, China)

Abstract: In the context of wind turbine gearbox fault early warning, this paper proposes a method based on graph attention and temporal convolutional networks to address the issue of insufficient data information mining. By establishing physical connections for each feature point in both temporal and spatial scales, the method expands the feature dimension to enhance fault warning accuracy. Graph attention network captures spatial relationships, while temporal convolutional network improves temporal feature capturing. Experimental results using real data from a wind farm show that the proposed method can issue fault warnings 122 hours in advance, outperforming other methods by 52 to 63 hours with reduced prediction errors (1.05% to 3.76%). The approach also enhances result interpretability using t-SNE and probability density curve analysis.

Keywords: wind power gearbox; fault warning; graph attention network; temporal convolutional network

0 引言

风电是最重要的清洁能源之一,具有很大的发展潜力。根据国家能源局发布的2022年全国电力工业统计数据,风电装机容量约 3.65×10^8 kW,同比增长11.2%。然而,风电机组长时间运行下频繁的启停操作、调峰及变负荷操作都会对其运行状态带来负面影响,甚至会导致

运行事故的发生。因此,提出一种风电齿轮箱早期故障预警方法,对风电安全稳定运行,减少经济效益损失有着重要意义。

目前已提出的风电故障预警方法从原理上可分为两类,一是基于传感器的振动监测^[1-2]、油液监测方法^[3-4],二是基于风电数据采集与监控系统(supervisory control and data acquisition, SCADA)数据与智能算法结合的数据驱动方法^[5]。振动监测和油液监测要在风电机组加装

收稿日期: 2023-04-21 Received Date: 2023-04-21

* 基金项目:北京市自然科学基金(4182061)项目资助

额外的传感器,需要较大的前期投资和后期维护成本;相比之下,基于 SCADA 数据的故障预警方法无需加装额外的装置,只需对风电运行数据进行特征挖掘,因此越来越多的学者和业内人士着手研究基于 SCADA 数据的风电故障预警方法^[6]。部分学者采用机器学习方法进行风电故障预警,如文献[7]提出一种基于贝叶斯优化的 XGBoost 算法用于风电轴承温度预测,分析滑动窗口监测异常点出现的次数占比实现故障预警。文献[8]提出灰狼算法优化支持向量回归模型,使用随机森林选取特征变量,实现了风电机组齿轮箱超温故障报警。文献[9]提出了一种基于随机森林的风电变频器故障预警模型,经实例验证该方法准确率达到 88.9%。但上述方法并不能深层次挖掘风电多个变量之间的相关性,因此很难全面表征风电的运行状态。

深度学习模型强大的数据挖掘和特征学习能力受到广泛关注,越来越多基于深度学习的风电故障预警方法被众多学者提出。文献[10]提出一种基于生成对抗网络的风电机组在线状态监测方法,与其他方法相比能检测出更多异常样本,并且误报次数更少。文献[11]将自编码器和 CNN 相结合,提出基于深度卷积自编码的风电故障预警方法,使用 EMWA 控制图实时对机组状态监测并进行故障预警,结果表明该方法可以提前 1 天左右提前预警。上述方法重点关注 SCADA 数据的时间关系,没有考虑数据空间关系,很难更深层次地提取数据特征。

图神经网络提出后,最大的应用领域是计算机视觉,其强大的特征学习能力在处理非结构化数据方面效果显著,并且可以将其应用于提取时间序列各特征之间的依赖关系,挖掘时间序列中数据结构的特征。文献[12]提出一种图注意力时域卷积网络(GATCN)用于挖掘交通网络数据中复杂的时空相关性。文献[13]提出一种基于注意力的时空图神经网络(ASTGNN)用于捕获交通数据的周期性和空间异质性。文献[14]受图注意力网络启发,提出一种基于相关图注意力的长短期记忆力网络(CGA-LSTM)用来捕获多个时间序列与外生序列的时空相关性。可见基于图神经网络的研究已经比较深入,但将图注意力网络应用于风电齿轮箱故障预警的相关研究还比较少。

时间卷积网络具有强大的时间序列特征提取能力,已在流量预测和时间序列预测领域广泛应用。文献[15]使用时间卷积网络来预测多区域的短期旅客需求。文献[16]提出了一种基于 SG 滤波器和 TCN 的 LSTM 混合方法用于网络流量预测,TCN 用于提取短期局部特征,实验结果表明该方法精度优于其他模型。文献[17]提出一种自校准时间卷积网络(SCTCN)用于风电齿轮箱轴承的剩余寿命预测,实验证明 SCTCN 平均绝对误差比其他方法小 10%。以上研究表明,时间卷积网

络在处理时间序列数据时优势明显。

在上述研究的基础上,针对风电 SCADA 数据在时间维度上前后相关,特征空间维度上相互耦合的特点,提出一种基于图注意力网络(graph attention network, GAT)和时间卷积网络(temporal convolutional network, TCN)的风电齿轮箱故障预警方法,拓宽了预警特征维度,对风电正常运行工况下 SCADA 数据进行建模,分别使用 GAT 和 TCN 提取特征,并离线训练确定故障报警阈值,之后基于风电故障案例对所提预警方法的有效性进行了验证。

1 算法基础

1.1 图注意力网络

不同于图卷积网络模型中每个相邻节点具有相同权重,图注意力网络认为不同的节点在学习的过程中贡献不同,为此图注意力网络^[18]在图算法中引入了注意力机制,通过遍历每个节点的相邻节点进行加权求和达到聚合信息的目的。

GAT 的训练基于相邻节点间的关系,消除了图结构的约束;并且 GAT 的图结构较为简单,因此适用于处理风电 SCADA 数据。在风电故障预警的任务中,使用 GAT 提取风电数据不同变量之间的空间相关性。GAT 的输入是 SCADA 数据每个滑动窗口内的数据序列,图中的每个节点对应一个滑动窗口内数据的每个变量;相邻节点间的边表示两个变量的空间相关性。GAT 的网络结构如图 1 所示。

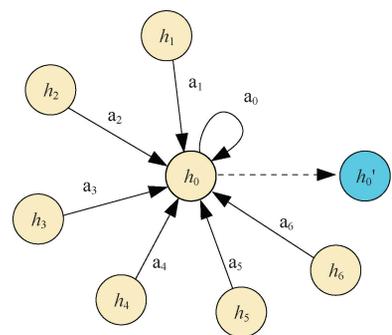


图 1 图注意力网络结构示意图

Fig. 1 Schematic diagram of graph attention network structure

相邻两个节点 h_i 和 h_j 之间的完整的权重系数空间相关性计算方法如式(1)所示。

$$a_{ij} = \frac{\exp(\text{LeakyReLU}(\vec{a}^T[\vec{W}h_i \parallel \vec{W}h_j]))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(\vec{a}^T[\vec{W}h_i \parallel \vec{W}h_k]))} \quad (1)$$

式中: a_{ij} 为相邻节点 h_i 和 h_j 之间的边权重系数; \vec{a} 为可学习权重向量; \vec{W} 为共享权重向量; N_i 为第 i 个节点的相

邻节点数。

每个节点的最终输出特征向量如式(2)所示。

$$\vec{h}_i' = \sigma \left(\sum_{j \in N_i} a_{ij} \vec{W} h_j \right) \quad (2)$$

为了避免节点过多关注自身的位置,引入了多头注意力机制^[19]来稳定自注意力的学习过程。

GAT 的注意力机制如图 2 所示。使用 K 个独立的注意力机制来计算隐藏状态,这里使用拼接操作以减少输出维度,如式(3)所示。

$$\vec{h}_i' = \sigma \left(\frac{1}{K} \sum_{k=1}^K \sum_{j \in N_i} a_{ij}^k \vec{W}^k h_j \right) \quad (3)$$

式中: K 为多头注意力总头数; k 为注意力头数; a_{ij}^k 为第 k 组注意力机制计算出的权重系数; \vec{W}^k 为对应的输入线性变换矩阵。

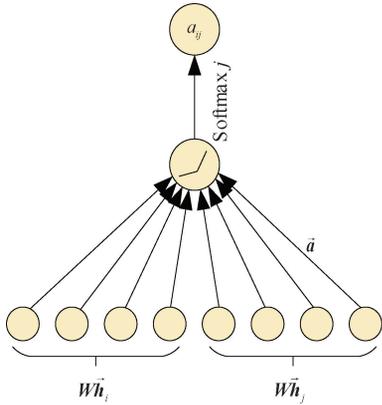


图 2 GAT 注意力机制示意图

Fig. 2 Schematic diagram of GAT attention mechanism

1.2 时间卷积网络

时间卷积网络^[20]属于卷积神经网络的一种变体,本质是将一维卷积神经网络^[21]与因果卷积相结合。TCN 使用了特殊的因果膨胀卷积和残差网络,因果卷积的优势在于防止未来信息的泄露;膨胀卷积可以在堆叠卷积时扩大感受野;残差网络允许上层误差传入下层,以保持网络的稳定性。时间卷积网络的结构如图 3 所示。

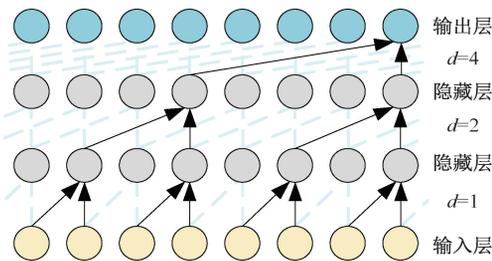


图 3 时间卷积网络的结构

Fig. 3 Structure of temporal convolutional networks

使用 TCN 可以从输入序列中提取时间特征,文献[22]实例对比了 TCN 与 LSTM、CNN+LSTM 和多元线性回归等模型的性能,结果表明一般情况下 TCN 的预测精度更高。

对于一维时间序列 $x_n = \{x_{t-w+1}, \dots, x_{t-1}, x_t\}$, $x \in RD$, 卷积核为 $f: \{0, \dots, k-1\} \rightarrow R$, 在 t 时刻卷积运算的定义如式(4)所示。

$$F(t) = (x * df)(t) = \sum_{i=0}^{k-1} f(i) \times x_{t-d-i} \quad (4)$$

式中: d 为扩张因子; k 为卷积核大小。

经过一系列卷积运算,输入的数据序列被映射为包含时间信息的隐式向量,如式(5)所示。

$$y_i' = \mathcal{F}(x_i, \{W_l\}) + Conv_{1 \times 1}(x_i) \quad (5)$$

式中: \mathcal{F} 为由非线性因果展开卷积、ReLU 函数、权重归一化和 dropout 正则化组成的卷积运算模块; W_l 为可学习权重向量。

2 提出的故障预警方法

2.1 基于 GAT-TCN 的预警模型

首先,从风电 SCADA 导出的数据中提取出风电正常运行状态下的数据,挑选与风电运行状态相关联的特征数据,划分为模型的训练集、验证集和测试集。之后对数据预处理操作,主要是对风电 SCADA 系统中缺失或者错误数据进行补全或删除。

其次使用 1-D 卷积层提取原始输入序列的特征,卷积层的输出分别输入到并行的 GAT 层和 TCN 层。GAT 层用于提取数据空间分布特征,对多特征风电 SCADA 序列使用滑动窗口法处理,过程如图 4 所示,为每个滑动窗口内的子序列建立一个特征图,每个风电特征 a_i 作为图的一个节点 h_i ,两个特征之间的相关性作为图相邻节点的边;TCN 层用于提取数据时间特征,以捕捉风电数据时间依赖关系。

特征拼接层将卷积层、GAT 层和 TCN 层的输出进行拼接聚合,通过全连接层和输出层,得到与模型输入子序列具有相同长度和维数的输出向量。GAT-TCN 模型的结构如图 5 所示。

2.2 故障预警流程

基于 GAT-TCN 的风电齿轮箱故障预警方法在流程上分为离线训练和在线监测两个阶段,监测流程如图 6 所示,共有 4 个步骤。

1) 数据预处理阶段:离线训练阶段对风电正常运行的历史数据预处理,方便模型训练;在线监测阶段对采集到的实时数据使用同样的方式预处理。

2) 训练模型:使用经预处理后的风电正常运行数据离线训练 GAT-TCN 模型,然后将模型保存,便于在线监

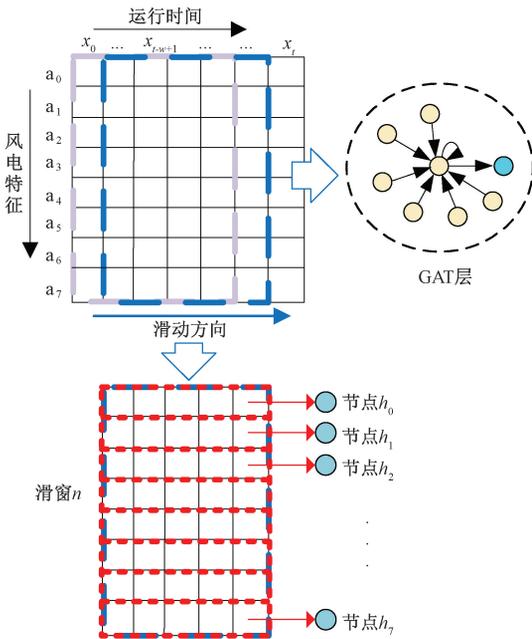


图 4 滑动窗口法处理 GAT 数据

Fig. 4 Sliding window method to process GAT data

测阶段使用。

3) 阈值确定:根据离线训练 GAT-TCN 预警模型输出的预测值和实际数据值,使用 POT 算法自动确定异常报警阈值。

4) 在线监测:将经预处理的风电实时运行数据输入已训练好的 GAT-TCN 模型中,得到当前风电运行状态下的综合误差,如果连续 5 个采样点超过异常阈值,则判定风电当前运行状态异常,否则认为风电处于正常运行状态。

3 案例分析

为验证基于 GAT-TCN 的风电齿轮箱故障预警方法的有效性,使用华北某风电场一台额定功率为 1.5 MW 的双馈风力发电机组 SCADA 数据进行模型的训练和评估,该台风电的具体参数为:切入风速 3 m/s,切出风速 25 m/s,SCADA 数据每 1 min 采样一次。得到采集 SCADA 数据共 182 879 组,该机组在 2017 年 11 月 17 日 8:31 发生故障导致停运,故障原因是齿轮箱油温度超出

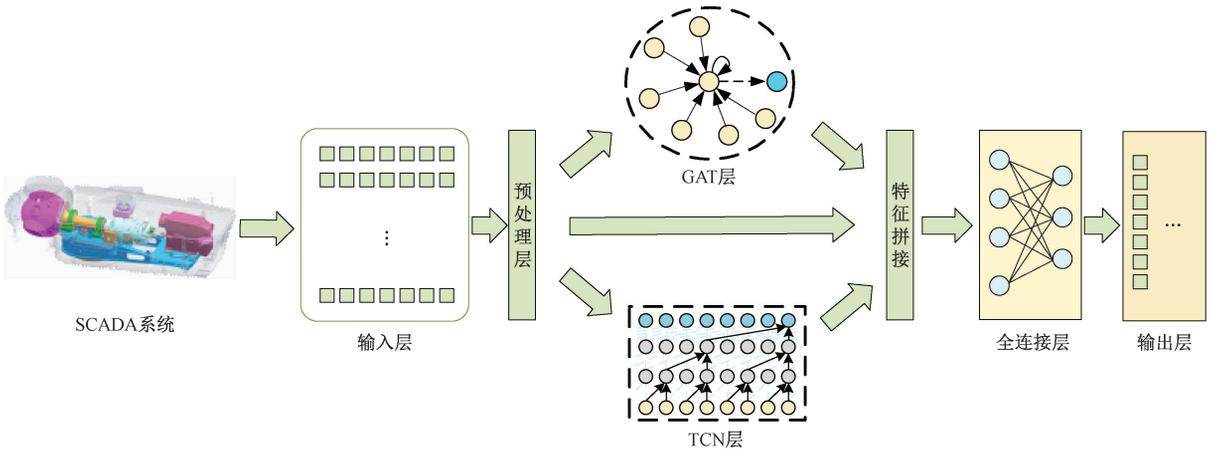


图 5 GAT-TCN 模型结构

Fig. 5 GAT-TCN model structure

报警温度 70 ℃。

3.1 数据预处理

风电 SCADA 系统记录了多维运行时间序列数据,剔除异常、补全缺失处理后剩余 127 085 组数据,为避免使用过多维度数据导致模型复杂度高和信息冗余等问题,对变量进行相关性分析。

在风电数据中,各参数能表征风电运行状态的程度不同,因此需选择与齿轮箱油温相关性较大的参数训练模型。与皮尔逊、斯皮尔曼等相关系数法相比,使用最大信息系数^[23](maximal information coefficient, MIC)对风电运行数据进行相关性分析更具优势,因其可以表征两

变量间复杂的非线性相关性。文献[23]介绍了 MIC 计算过程, MIC 的计算式如式(6)所示。

$$MIC(X;Y) = \max_{a \times b < B} \frac{I(X;Y)}{\log_2(\min(a,b))} \quad (6)$$

将 MIC 法筛选出的变量和齿轮箱油温共同作为训练 GAT-TCN 模型的变量集,选取的 SCADA 变量名称和 MIC 相关性分析结果如表 1 所示。为便于模型训练,令不同变量数据具有相同的度量尺度,对选取数据进行归一化处理,计算方法如式(7)所示。

$$y_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

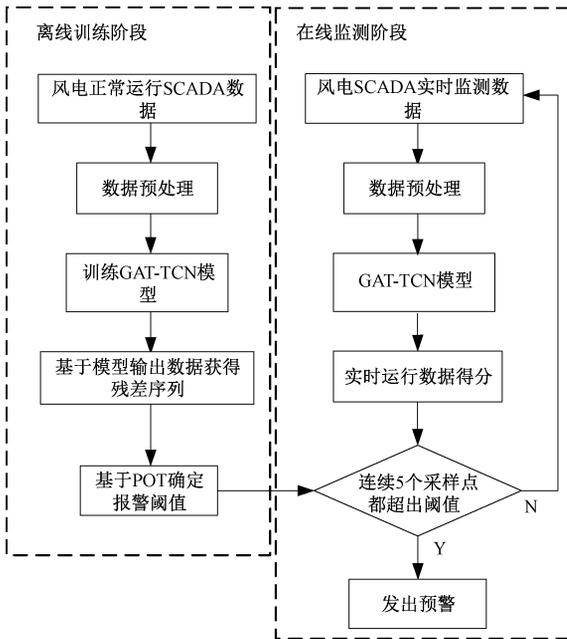


图 6 GAT-TCN 风电齿轮箱故障预警方法流程

Fig. 6 GAT-TCN wind power gearbox fault early warning method flow

式中: y_i 为第 i 个归一化后的数据; x_i 为第 i 个归一化前的数据; x_{\max} 、 x_{\min} 分别为变量序列 x 中的最大值和最小值。

表 1 用于训练模型的 SCADA 变量表

Table 1 SCADA variables used to train the model

序号	SCADA 变量	MIC 相关性系数
A0	风速/($m \cdot s^{-1}$)	0.698 4
A1	有功功率/kW	0.685 0
A2	发电机转速/($r \cdot \min^{-1}$)	0.736 9
A3	齿轮箱入口油压/Bar	0.681 2
A4	齿轮箱滤网前油压/Bar	0.656 7
A5	齿轮箱驱动端轴承温度/ $^{\circ}C$	0.834 8
A6	齿轮箱非驱动端轴承温度/ $^{\circ}C$	0.840 0
A7	齿轮箱油池温度/ $^{\circ}C$	1.000 0

经过归一化处理后训练集和验证集的各维度输入变量随时间变化曲线如图 7 所示。对选取的数据进行划分,每个数据集包含的数据组数和功能如表 2 所示。

表 2 数据集的划分

Table 2 Partition of the data set

数据集名称	SCADA 数据组数	数据集功能描述
训练集	66 987	用于建立风电正常运行状态下的模型
验证集	16 740	查看模型训练的效果
测试集 1	16 746	模型预测性能对比研究
测试集 2	26 612	风电发生故障案例

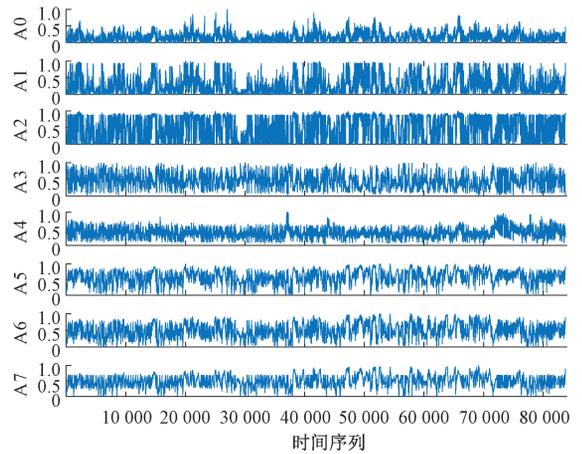


图 7 训练模型的输入数据

Fig. 7 Input data to train the model

3.2 模型训练

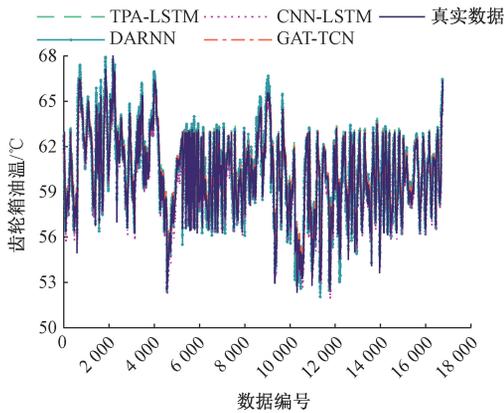
GAT-TCN 风电齿轮箱故障预警方法基于 Pytorch 训练框架,经预处理的数据输入到卷积核大小为 1×7 的 1-D 卷积层,激活函数使用 ReLU。卷积运算后的数据分别输入到并行的 GAT 层和 TCN 层。GAT 层的 window_size 设置为 100,激活函数使用 LeakyReLU, alpha 设置为 0.2。TCN 层的卷积核大小设置为 4,卷积层数设置为 3。全连接层输入维度设置为 3 倍的原数据维度,隐含层状态维度设置为 150。模型的输出层节点数为 8,包含信息为模型预测的 A0~A7 这 8 个参数。

训练时,模型的学习率设置为 0.001,训练轮数设置为 200, dropout 设置为 0.3,损失函数为均方误差 MSELoss,模型的优化器使用 Adam。

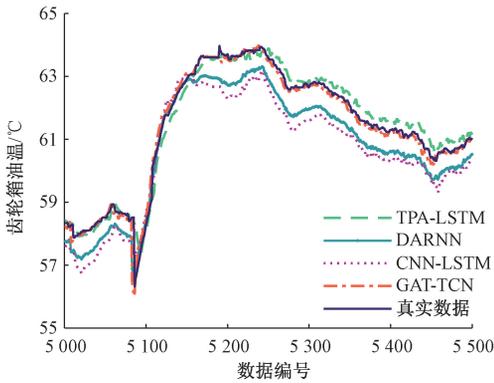
为直观验证模型的性能,将 GAT-TCN 模型与 CNN-LSTM、TPA-LSTM^[24]、DARNN^[25] 3 种方法进行对比。在使用同样数据集的情况下,使用上述方法分别构建风电正常运行状态下的模型。不同方法在测试集 1 上的油温预测效果如图 8(a) 所示,为便于区分曲线,从预测结果中选取数据编号为 5 001~5 500 的部分绘制对比曲线如图 8(b) 所示。经对比可以看出,基于 GAT-TCN 的预警模型误差最小,预测曲线更贴合真实曲线。原因是相比于其他几种方法,GAT-TCN 能够从时间和空间两个维度提取风电 SCADA 数据更深层次的特征,拥有比其他方法更加精确表征风电运行状态的能力。

为精确评估各个模型性能优劣,采用平均绝对百分比误差(mean absolute percentage error, MAPE)、均方根误差(root mean squared error, RMSE)和平均绝对误差(mean absolute error, MAE)作为评估指标,以上指标计算方法如式(8)~(10)所示。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (8)$$



(a) 不同方法在测试集1上的预测效果
(a) The prediction effect of different methods on the test set 1



(b) 部分对比曲线
(b) Partial contrast curve

图 8 不同模型的预测效果

Fig. 8 Predictive effects of different models

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| \quad (10)$$

各模型在测试集 1 上的预测性能如表 3 所示。若以上指标越小,则说明模型的预测精度更高。从表 3 数据可以看出,GAT-TCN 模型的预测性能优于其他 3 种模型,其次是 TPA-LSTM 和 DARNN 模型,CNN-LSTM 在测试集 1 上的预测性能最差。

表 3 预测结果性能指标

Table 3 Prediction Results Performance Indicators

模型	性能指标		
	MAPE	MAE	RMSE
CNN-LSTM	6.893%	0.453	0.950
DARNN	6.021%	0.395	0.845
TPA-LSTM	4.181%	0.268	0.574
GAT-TCN	3.132%	0.197	0.432

3.3 预警结果

基于 GAT-TCN 对风电正常运行状态建立模型后,利

用模型预测输出和实际数据为风电每一个特征计算误差,将所有特征的误差平均求和作为当前风电运行状态的综合评估误差^[26],计算方法如式(11)所示。

$$R_i = \frac{1}{a} \sum_{i=0}^a r_i = \frac{1}{a} \sum_{i=0}^a (c_i - x_i)^2 \quad (11)$$

式中: R_i 为当前时刻运行状态的综合评估误差; r_i 为每个特征的预测误差; c_i 为模型输出预测值; x_i 为数据实际值; a 为训练数据风电变量个数。

使用超阈值(peaks over threshold, POT)算法对测试集 1 的结果确定模型的报警阈值。POT 是极值理论中的经典模型,立足于初始样本确定阈值^[27],不需要人工设定阈值和分布假设。如果连续 5 个时刻综合评估误差都超过阈值,那么认为此时风电运行状态异常,发出故障预警信号。POT 置信度设置为 0.995,异常发生概率 q 设置为 0.001,使用 POT 方法得到故障报警综合误差阈值为 0.022 341 971。

在风电正常运行工况的测试集 1 上,模型的预测误差和报警信号如图 9 所示。可以看出,当风电处于正常工况时,GAT-TCN 在测试集 1 的预测综合误差始终维持在一个较低的水平,没有超过 POT 设置的阈值,模型也没有发出故障预警。

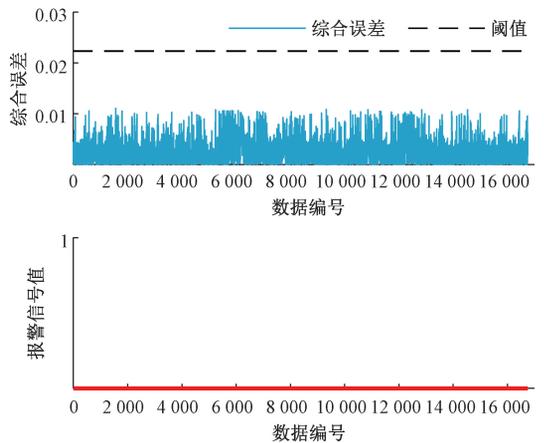


图 9 GAT-TCN 在测试集 1 的预测综合误差和报警信号

Fig. 9 GAT-TCN prediction comprehensive error and warning signal on test set 1

将测试集 2 的数据输入到 GAT-TCN 模型中预警结果如图 10 所示。可以看出,在测试集 2 上编号前 19 000 数据点的预测综合误差较小,不超过 0.02。在编号为 19 243~19 939 的连续 696 个数据点,预测综合误差超过 POT 设定的阈值,模型首次发出报警信号;随后在编号第 22 397 个数据点后,一共有连续 1 409 个数据点超出阈值,此时模型持续发出报警信号,最后在编号第 26 270 点再次发出报警信号,直到 SCADA 系统报警齿轮箱油温超过 70 °C,此时风电发生故障停运。综合以上结果,基

于 GAT-TCN 的风电故障预警模型可以在线监测齿轮箱劣化程度,并且在故障发生前发出预警。

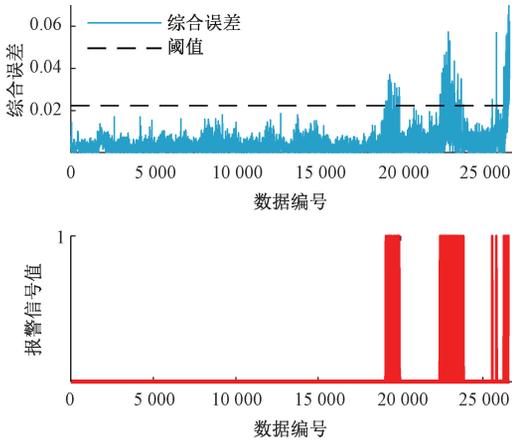


图 10 GAT-TCN 在测试集 2 的预测综合误差和报警信号
Fig. 10 GAT-TCN prediction comprehensive error and warning signal on test set 2

基于 CNN-LSTM、DARNN 和 TPA-LSTM 方法的预警结果如图 11 所示。可以看出以上 3 种方法相比 GAT-TCN 首次预警时间更晚,原因是在编号为 19 591 数据点附近的异常状态都未能准确检测出,仍然在报警阈值范围内,而基于 GAT-TCN 的故障预警方法可以监测到此处的异常状态。此外 CNN-LSTM 和 DARNN 在风电运行状态未明显劣化时,存在少数点预测综合误差超过阈值的情况,说明这两种模型在该阈值下预测精度不够,有可能导致虚假报警的情况出现。

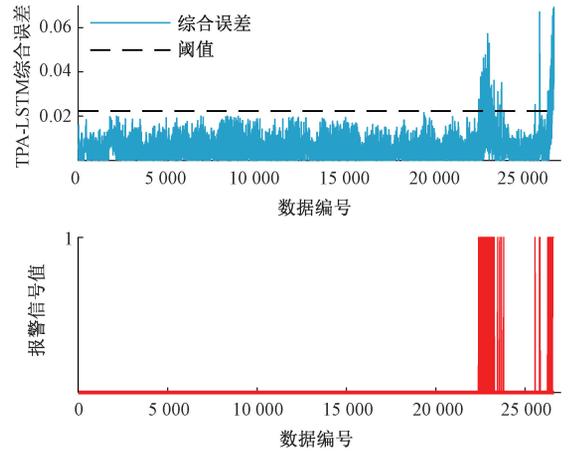
不同模型在测试 2 上的预警效果如表 4 所示,GAT-TCN 首次预警时间比其他 3 种方法更早,提前了 5 天 2 小时 49 分,且捕获有效超出阈值异常点也是最多的,说明 GAT-TCN 有着比其他 3 种方法更早发现齿轮箱早期故障的能力。

表 4 几种方法的预警结果对比

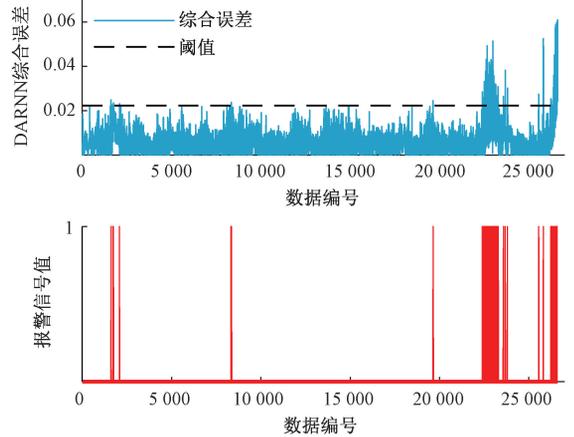
Table 4 Comparison of early warning results of several methods

模型	首次预警时间和编号	检测出有效异常点个数
CNN-LSTM	2017 年 11 月 14 日 20:39 (编号 23 020)	1 036
DARNN	2017 年 11 月 14 日 11:47 (编号 22 488)	1 497
TPA-LSTM	2017 年 11 月 14 日 10:16 (编号 22 397)	1 551
GAT-TCN	2017 年 11 月 12 日 5:42 (编号 19 243)	2 447

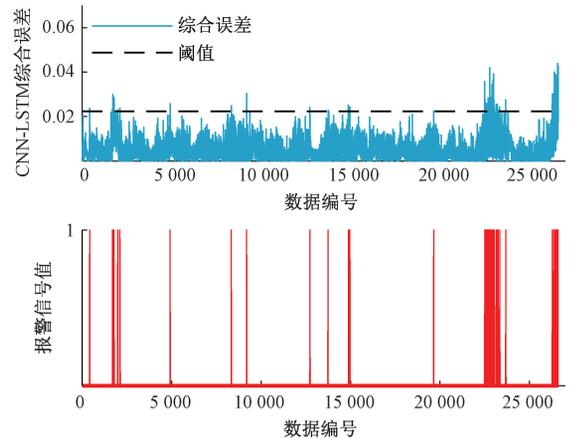
GAT-TCN 捕获风电运行数据之间的时空分布关系,可以表征风电正常运行状态。由于风电是强耦合的机电系统,当风电发生不同类型故障时,运行数据之间的分布



(a) TPA-LSTM 在测试集 2 的预测综合误差和报警信号
(a) TPA-LSTM prediction comprehensive error and warning signal in test set 2



(b) DARNN 在测试集 2 的预测综合误差和报警信号
(b) DARNN prediction comprehensive error and warning signal in test set 2



(c) CNN-LSTM 在测试集 2 的预测综合误差和报警信号
(c) CNN-LSTM prediction comprehensive error and warning signal in test set 2

图 11 不同方法在测试集 2 上的预警效果

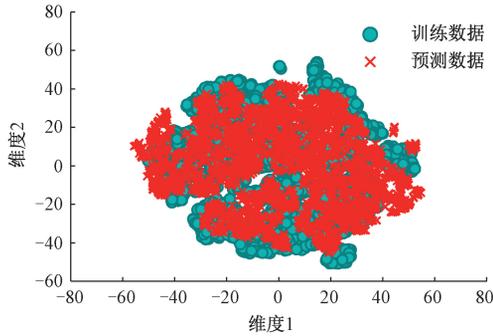
Fig. 11 Early warning effects of different methods on test set 2

会偏离正常区间,所以对于风电其他故障,GAT-TCN 也

能及时发现并给出预警结果。

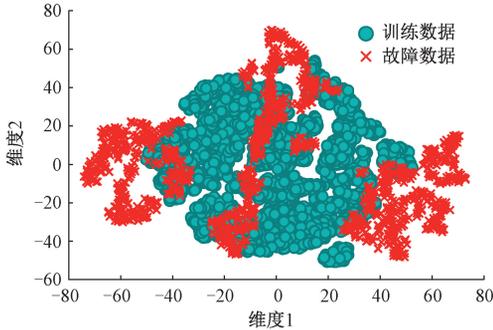
3.4 t-SNE 可视化分析

为对比风电正常运行和发生故障两种工况数据分布情况,实例分析 GAT-TCN 模型是否可靠,首先使用 t-SNE 算法将风电齿轮箱油温数据和本文所提模型预测输出值降维到二维可视化空间中,如图 12 所示。



(a) 真实数据与正常工况预测数据分布

(a) Distribution of real data and predicted data under normal working conditions



(b) 真实数据与发生故障前预测数据分布

(b) Distribution of real data and pre-failure predicted data

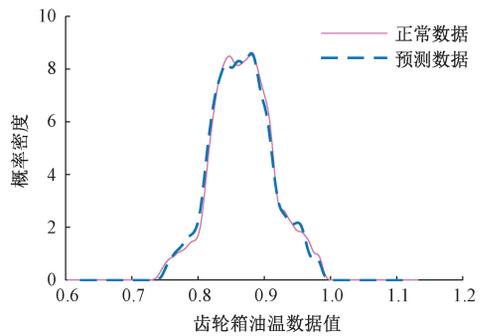
图 12 t-SNE 可视化数据二维分布情况

Fig. 12 t-SNE visualizes the two-dimensional distribution of data

从图 12(a) 可以看到风电正常运行时,模型预测输出和真实数据都分布在以原点为中心,30 为半径的圆形区域内,数据点呈均匀分布的状态。而在风电发生故障前一段时间,如图 12(b) 所示只有少量模型预测输出值分布正常,这些点都是距离故障发生时间较远的点,在维度 1 的正负 70 区域有大量预测值已经偏离正常圆形区域,说明此时风电已经偏离正常运行状态。

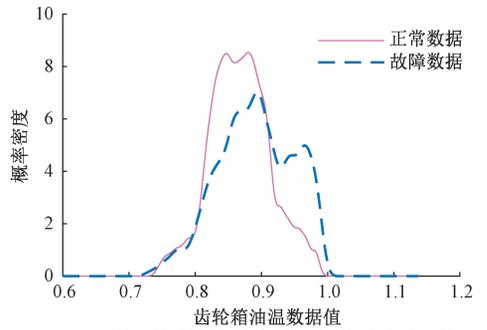
使用核密度估计方法分别绘制风电正常运行和发生故障两种工况下模型预测数据的概率密度曲线,如图 13 所示。

从图 13(a) 可以看到风电正常运行工况下,模型预测输出数据和训练正常数据的概率密度曲线基本重合,且近似于正态分布,说明此时机组运行状态正常。如图 13(b) 所示,风电发生故障前模型预测输出的概率密度曲线已经偏离了正常状态,少数预测值已经超过高限值,高油温数据占比增多,而且出现明显的双峰,原因是发生



(a) 训练正常数据与正常工况预测数据概率密度曲线

(a) Probability density curve of training normal data and normal working condition prediction data



(b) 训练正常数据与故障预测数据概率密度曲线

(b) Training normal data and failure prediction data probability density curve

图 13 预测数据概率密度曲线变化

Fig. 13 Training normal data and failure prediction data probability density curve

故障前齿轮箱磨损导致油温高于正常水平,风电运行状态异常。

综合以上分析,GAT-TCN 模型预警过程与风电数据劣化有着紧密联系,使用 t-SNE 和概率密度曲线可视化方法验证了 GAT-TCN 风电故障预警模型是可靠有效的,增加了模型的可解释性。

4 结论

为及时准确地监测风电齿轮箱早期异常状态,提出一种基于图注意力和时间卷积网络的风电齿轮箱故障预警方法。使用某风电场实际运行数据进行实例分析,得到如下结论:

- 1) 提出 GAT-TCN 方法预测精度优于对照方法,说明其能够分别从数据的时间和空间维度更深层次挖掘风电 SCADA 数据中的隐含特征。
- 2) 在实例中能够提前 5 天 2 小时 49 分进行故障预警,与现有几种方法相比,其发现早期异常能力更强。
- 3) 使用 t-SNE 算法和概率密度曲线可视化展示风电数据劣化前后的变化,提升模型的可解释性。

风电故障预警模型的精度受多方面的影响,训练数据的质量是最关键的一个因素,本文对数据缺失值和异常值只进行简单的处理,如何有效填补 SCADA 缺失值是未来值得关注的方向。

参考文献

- [1] 刘少康,武英杰,田野,等. 基于振动信号耦合调制新模型和参数辨识的风电齿轮箱齿圈故障监测[J]. 仪器仪表学报,2022,43(10):260-269.
LIU SH K, WU Y J, TIAN Y, et al. Fault monitoring of ring gear of wind turbine gearbox based on coupling modulation new model of vibration signal and parameter identification [J]. Chinese Journal of Scientific Instrument, 2022,43(10):260-269.
- [2] 刘长良,武英杰,甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报,2015,35(13):3358-3365.
LIU CH L, WU Y J, ZHEN CH G. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering[J]. Proceedings of the CSEE, 2015,35(13):3358-3365.
- [3] 许少凡,李秋秋,覃楚东,等. 基于油液监测的风机主齿轮箱磨损预测[J]. 润滑与密封,2022,47(4):183-188.
XU SH F, LI Q Q, QIN CH D, et al. Wear prediction of wind turbine main gear-box based on oil monitoring[J]. Lubrication Engineering,2022,47(4):183-188.
- [4] YANG X Y, FANG Z G, YANG Y J, et al. A novel multi-information fusion grey model and its application in wear trend prediction of wind turbines [J]. Applied Mathematical Modelling,2019,71:543-557.
- [5] 王梓齐,张书瑶,刘长良. 基于增量式相对熵的风电机组实时状态监测[J]. 电子测量与仪器学报,2020,34(12):125-132.
WANG Z Q, ZHANG SH Y, LIU CH L. Real-time condition monitoring of wind turbine based on incremental relative entropy [J]. Journal of Electronic Measurement and Instrumentation,2020,34(12):125-132.
- [6] 王梓齐,刘长良. 基于 Box-Cox 变换和相对熵残差分析的风电机组齿轮箱状态监测[J]. 中国电机工程学报,2020,40(13):4210-4218.
WANG Z Q, LIU CH L. Wind turbine gearbox condition monitoring based on Box-Cox transformation and relative entropy residual analysis[J]. Proceedings of the CSEE, 2020,40(13):4210-4218.
- [7] 魏乐,胡晓东,尹诗. 基于优化 XGBoost 的风电机组发电机前轴承故障预警[J]. 系统仿真学报,2021,33(10):2335-2343.
WEI L, HU X D, YIN SH. Optimized-XGBoost early warning of wind turbine generator front bearing fault[J]. Journal of System Simulation, 2021, 33(10):2335-2343.
- [8] 刘杰,曹静,赵昕. 基于 OOB-GWO-SVR 的风电机组齿轮箱故障预警[J]. 电子测量与仪器学报,2022,36(12):97-105.
LIU J, CAO J, ZHAO X. Wind turbine gearbox fault warning based on OOB-GWO-SVR [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(12):97-105.
- [9] 刘冰冰,王安琪,张传江,等. 基于随机森林的风电变频器故障预警模型研究与应用[J]. 船舶工程,2020,42(S2):181-186.
LIU B B, WANG AN Q, ZHANG CH J, et al. Research and application of fault prediction model for wind power inverter based on random forest[J]. Ship Engineering, 2020,42(S2):181-186.
- [10] 金晓航,许壮伟,孙毅,等. 基于生成对抗网络的风电机组在线状态监测[J]. 仪器仪表学报,2020,41(4):68-76.
JIN X H, XU ZH W, SUN Y, et al. Online condition monitoring of wind turbine based on generative adversarial network [J]. Chinese Journal of Scientific Instrument, 2020,41(4):68-76.
- [11] 刘家瑞,杨国田,杨锡运. 基于深度卷积自编码器的风电机组故障预警方法研究[J]. 太阳能学报,2022,43(11):215-223.
LIU J R, YANG G T, YANG X Y. Research on wind turbine fault warning method based on deep convolution auto-encoder [J]. Acta Energetica Solaris Sinica, 2022, 43(11):215-223.
- [12] ZHANG K, HE F, ZHANG Z, et al. Graph attention temporal convolutional network for traffic speed forecasting on road networks [J]. Transportmetrica B: Transport Dynamics,2021,9(1):153-171.
- [13] GUO S, LIN Y, WAN H, et al. Learning dynamics and heterogeneity of spatial-temporal graph data for traffic forecasting [J]. IEEE Transactions on Knowledge and Data Engineering,2022,34(11):5415-5428.
- [14] HAN S, DONG H, TENG X, et al. Correlational graph attention-based long short-term memory network for multivariate time series prediction [J]. Applied Soft Computing,2021,106:107377.
- [15] ZHANG K, LIU Z, ZHENG L. Short-term prediction of passenger demand in multi-zone level: Temporal convolutional neural network with multi-task learning [J]. IEEE Transactions on Intelligent Transportation Systems, 2020,21(4):1480-1490.

- [16] BI J, ZHANG X, YUAN H, et al. A hybrid prediction method for realistic network traffic with temporal convolutional network and LSTM[J]. IEEE Transactions on Automation Science and Engineering, 2022, 19(3): 1869-1879.
- [17] HE K, SU Z, TIAN X, et al. RUL prediction of wind turbine gearbox bearings based on self-calibration temporal convolutional network[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-12.
- [18] DONG Y, LIU Q, DU B, et al. Weighted feature fusion of convolutional neural network and graph attention network for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2022, 31: 1559-1572.
- [19] WANG Y, HU L, WU Y, et al. Graph multihed attention pooling with self-supervised learning [J]. Entropy, 2022, 24(12): 1745.
- [20] 阳景, 潘强, 潘红兵. 基于时间卷积网络的模拟电路故障诊断方法[J]. 电子测量技术, 2019, 42(5): 128-132.
- YANG J, PAN Q, PAN H B. Fault diagnosis method of analog circuits based on temporal CNN[J]. Electronic Measurement Technology, 2019, 42(5): 128-132.
- [21] 陈星. 基于卷积神经网络算法的飞机发电机故障诊断研究[J]. 国外电子测量技术, 2020, 39(11): 57-60.
- CHEN X. Fault diagnosis of aircraft generator based on convolution neural network algorithm [J]. Foreign Electronic Measurement Technology, 2020, 39(11): 57-60.
- [22] MEKA R, ALAEDDINI A, BHAGANAGAR K. A robust deep learning framework for short-term wind power forecast of a full-scale wind farm using atmospheric variables[J]. Energy, 2021, 221: 119759.
- [23] 纪少波, 李洋, 李萌, 等. 纯电动共享汽车驾驶行为对能耗的影响[J]. 吉林大学学报(工学版), 2022, 52(4): 754-763.
- JI SH B, LI Y, LI M, et al. Influence of driving behavior on energy consumption of pure electric shared vehicles[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(4): 754-763.
- [24] SHIH S Y, SUN F K, LEE H Y. Temporal pattern attention for multivariate time series forecasting [J].

Machine Learning, 2019, 108(8): 1421-1441.

- [25] LI J, LIU Y, LI Q. Intelligent fault diagnosis of rolling bearings under imbalanced data conditions using attention-based deep learning method[J]. Measurement, 2022, 189: 110500.
- [26] ZHAO H, WANG Y, DUAN J, et al. Multivariate time-series anomaly detection via graph attention network[C]. 2020 IEEE International Conference on Data Mining (ICDM), 2020: 841-850.
- [27] 于群, 肖松青, 曹娜, 等. 基于超阈值模型的中国电网停电事故极值风险分析[J]. 山东大学学报(工学版), 2022, 52(6): 157-166.
- YU Q, XIAO S Q, CAO N, et al. Extreme value risk analysis of blackout in China power grid based on over threshold model [J]. Journal of Shandong University (Engineering Science), 2022, 52(6): 157-166.

作者简介



王鹏飞(通信作者), 2021年于华北电力大学获得学士学位, 现为华北电力大学控制与计算机工程学院硕士研究生, 主要研究方向为风电机组故障预警。

E-mail: wpf_ncepu@163.com

Wang Pengfei (Corresponding author)

received his B. Sc. degree from North China Electric Power University in 2021. Now he is a M. Sc. candidate in the School of Control and Computer Engineering, North China Electric Power University. His main research interest includes wind turbine failure early warning.



刘长良, 分别在1985和1990年于华北电力学院获得学士和硕士学位, 2002年于华北电力大学获得博士学位, 现为华北电力大学教授、博士生导师, 主要研究方向为风电机组故障诊断、火电机组建模与仿真等。

E-mail: 13603123513@163.com

Liu Changliang received his B. Sc. degree and M. Sc. degree both from North China Electric Power College in 1985 and 1990, and received his Ph. D. degree from North China Electric Power University in 2002. Now he is a professor and a Ph. D. advisor at North China Electric Power University. His main research interests include wind turbine fault diagnosis, thermal power unit modeling and simulation, etc.