

DOI:10.19651/j.cnki.emt.2416285

基于 Transformer 的风电机组故障预测^{*}朱彦民¹ 李忠虎¹ 王金明¹ 杨立清¹ 张鑫宇²

(1. 内蒙古科技大学自动化与电气工程学院 包头 014010; 2. 内蒙古科技大学机械工程学院 包头 014010)

摘要: 为了研究基于 SCADA 数据的风电机组故障预测方法,将一台 2 000 kW 双馈风电机组 14 个月的 SCADA 数据作为研究对象,首先对数据进行预处理,保证数据的可用性,其次,考虑到传统 Transformer 模型存在模型结构复杂且模型参数设置多等问题,通过引入线性解码器结构构建 Transformer 模型,并使用该模型对风电机组故障进行预测研究。研究表明:所构建的算法模型具备长期使用稳定性,模型可以消除误预测现象,可以提前 6 天时间做出故障预测,避免因故障恶化而引起突然停机提供了保障。

关键词: 风电机组;深度学习;数据分析;SCADA 系统;故障预测

中图分类号: TM315; TN03 **文献标识码:** A **国家标准学科分类代码:** 470.4047

Transformer based fault prediction for wind turbines

Zhu Yanmin¹ Li Zhonghu¹ Wang Jinming¹ Yang Liqing¹ Zhang Xinyu²

(1. School of Automation and Electrical Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China;

2. School of Mechanical Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China)

Abstract: To study fault prediction methods for wind turbines based on SCADA data, the SCADA data of a 2 000 kW doubly-fed wind turbine over 14 months is used as the research subject. First, the data is preprocessed to ensure its usability. Considering the issues with the traditional Transformer model, such as complex structure and numerous parameter settings, a Transformer model is constructed by introducing a linear decoder structure. This model is then used for fault prediction research on wind turbines. The study shows that the constructed algorithm model has long-term stability, can eliminate false predictions, and can predict faults 6 days in advance, providing a safeguard to prevent sudden shutdowns due to fault deterioration.

Keywords: wind turbine unit; deep learning; data analysis; SCADA system; fault prediction

0 引言

风能作为一种可再生能源,近几年越来越受到世界各国的重视,我国风力发电总装机容量也不断攀升。作为风电场单机信息管理的重要依据,风电机组运行的数据采集与监视控制(supervisory control and data acquisition, SCADA)系统在风电场优化控制和发电功率预测等工程领域有着广泛应用^[1]。然而,仅依靠 SCADA 系统对风电机组进行故障监测,远不能满足实际运维需求,为了降低风电机组的故障率和高昂的停机维护成本,亟需研究风电机组故障预测方法。

在整机故障研究方面,李森娟等^[2]提出一种基于支持向量机的风电机组故障预测方法,在某些特定类型的故障方面预测精度高达 92%;Ren 等^[3]提出一种基于主动学习

的风力发电机组故障预测方法,该模型可以应用于不同风电场的风电机组;Lima 等^[4]提出一种正常行为模型,完成对风电机组的故障预测,可以在严重故障发生的前几周产生警报;张西晨等^[5]设计并搭建了一套基于边缘智能技术的微型风电机组设备状态监测系统,验证了基于边缘训练与推理的边缘智能服务方式用于风电机组设备日常监测的可落地性。在风电机组关键部件故障研究方面,周伟波等^[6]提出一种改进深度学习模型,以海上风电机组齿轮作为研究对象,对海上风电机组齿轮展开故障预测研究,所用方法可以提升风电机组齿轮早期故障预测时间、准确率和抗噪抗干扰能力;何群等^[7]利用长短期神经网络,完成对风电机组齿轮箱的故障预测,可以表现出更好的预测性能,能够较早预测故障的发生;马永光等^[8]提出一种双重改进的完全噪声辅助聚合经验模态分解、主成分分析和门控循环

收稿日期:2024-06-21

^{*} 基金项目:内蒙古自治区科技计划项目(2021GG0433)资助

网络融合的风电机组齿轮箱故障预警方法,可以实现对风电机组齿轮箱的早期故障预警;韩万里等^[9]提出一种数据融合的方法对风电机组变桨系统进行故障预警,该方法可提前发现风电变桨系统故障征兆,实现对风电变桨系统的早期故障预警;田雯雯^[10]等提出基于旗鱼优化的改进自联想核回归算法,该方法能够反映风电机组齿轮箱的早期故障及发展趋势。

目前所研究的方法仍存在泛化性较差、所需准备时间长及长期使用中模型是否能够保持稳定等问题。基于目前对风电机组及核心部件的研究方法的优势和不足,本文提出基于 Transformer 的风电机组故障预测模型,实现对风电机组的故障预测。

1 Transformer 模型算法

Transformer 是基于 Seq-to-Seq 框架建立的模型,对比经典的深度学习模型,Transformer 的最突出优势是使用了多头注意力机制。多头注意力层的目的是在序列中为单词/标记之间赋予不同的重要性从多个方面(头)^[11]。传统的 Transformer 模型主要由输入、编码器、解码器及输出等部分构成,整体结构如图 1 所示。




图 1 Transformer 整体结构

Fig.1 The overall structure of Transformer

1.1 位置编码

位置编码层是为了确定序列的位置信息,由于没有 RNN 与 CNN 中的递归层和卷积层,仅仅依靠自注意力机制无法获取输入的顺序信息,需要主动将序列的顺序信息传递给模型^[12]。Transformer 模型采用正弦和余弦函数相结合的方式对序列进行位置编码,计算方式如下:

$$PE_{(pos, 2i)} = \sin(pos/10\,000^{2i/d_{model}}) \quad (1)$$

$$PE_{(pos, 2i+1)} = \cos(pos/10\,000^{2i/d_{model}}) \quad (2)$$

式中: pos 为当前序列的位置; i 为维度; d_{model} 为输入特征

的维度。

1.2 多头注意力机制

多头注意力机制是使用多个注意力机制并行地进行运算,然后通过线性变换将运算结果拼接起来^[13]。Transformer 中的核心技术为多头注意力机制,利用多头注意力机制提取数据间的依赖关系特征,捕获数据之间的相关关系并建立上下文预测模型,计算方式如下:

$$Q = W_1 \cdot X \quad (3)$$

$$K = W_2 \cdot X \quad (4)$$

$$V = W_3 \cdot X \quad (5)$$

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (6)$$

$$MultiHead(Q, K, V) = \text{Concat}(head_1, \dots, head_h)W^O \quad (7)$$

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (8)$$

式中: Q 为查询矩阵; K 为键矩阵; V 为值矩阵; W_1, W_2, W_3 为可训练的参数矩阵; X 为经过处理后的输入; d_k 为键矩阵的维度; W^O, W_i^Q, W_i^K, W_i^V 为可学习的参数矩阵。

1.3 前馈网络与求和和归一化

在 Transformer 模型中编码部分和解码部分还包含前馈网络与求和和归一化。

前馈神经网络的计算公式如下:

$$FFN(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (9)$$

式中: x 为输入; W_1, W_2, b_1, b_2 为可通过训练得到的参数。

求和和归一化的计算公式如下:

$$x = \text{LayerNorm}(x + \text{Sublayer}(x)) \quad (10)$$

式中: x 为输入; $\text{Sublayer}(x)$ 为经过模块处理后的结果。

由于传统的 Transformer 模型存在模型结构复杂,模型参数设置多的问题,因此本文通过引入线性解码器结构构建 Transformer 模型。本文采用 Pytorch 构建 Transformer 模型,为考虑风电机组故障预测的灵活性,在位置编码处设定最大序列长度为 1;编码部分由 4 层编码层构成,编码层设置头数为 10。模型处理流程为:将输入数据通过位置编码后送入编码部分,将编码部分的输出展平后送入线性解码器中之后最终做出预测。

2 SCADA 数据处理

本文采集了风电场一台风电机组 14 个月的 SCADA 数据,数据全天候不间断采样,采样频率为每 5 min 采样一次,其 SCADA 数据处理流程如图 2 所示。首先对获取的 SCADA 数据划分训练集和测试集,之后对训练集进行数据处理,数据处理完毕后,对训练集进行归一化处理,测试集使用训练集的归一化参数进行归一化处理,最后利用归一化后的训练集数据进行特征值的选取。

2.1 训练集和测试集处理

对风电机组 14 个月的 SCADA 数据进行划分,选取前 4 个月风电机组未出现故障的健康运行数据作为训练集,




图 2 SCADA 数据处理流程

Fig. 2 SCADA data processing flow chart

剩余后续 10 个月的数据作为测试集进行风电机组的故障预测研究。经过划分后,训练集含有 34 849 组数据,测试集中含有 87 552 组数据。

为保证模型在训练集中训练的效果和稳定性,需要对训练集进行处理,剔除因各种因素导致的风电机组停机时段的空白数据和 SCADA 系统由于外部因素影响而出现的记录异常数据。在风机数据清洗中采用最多的研究对象是风速-功率曲线(P-V 图),将原始的风功率散点图根据其运行状态和分布特征分为 4 类,即正常运行点、停机点、限功率点和异常运行点^[14]。风电机组风速和有功功率曲线反映了风电机组整体的状态关系,因此结合实际情况综合考虑,首先对风速和有功功率分别进行数据处理,剔除风速等于 $0 \text{ m}\cdot\text{s}^{-1}$ 以及有功功率等于 0 kW 的风电机组数据点,之后采用 K 近邻算法,进一步对风速和有功功率间的数据点进行处理,在处理完成后训练集剩余 23 519 组数据,用于对模型的训练。

2.2 数据归一化处理

归一化处理就是将数据进行比例缩放,使其分布在特定的范围内,归一化之后可以消除量纲的限制,将其转变为无量纲数,还能适当提升运算速度。由于特征提取中具有不同的量纲和量纲单位,因此必须进行数据归一化处理,否则模型精度会受到影响,甚至得不出正确的结果。本文对处理后的训练集和测试集采用 MIN-MAX 归一化方式,其中在进行测试集的 MIN-MAX 归一化时,MIN-MAX 最大和最小值参数选用训练集的最大和最小值参数,MIN-MAX 归一化方式如下:

$$\overline{x_{A_i}} = \frac{x_{A_i} - \min(A_i)}{\max(A_i) - \min(A_i)} \quad (11)$$

式中: x_{A_i} 为样本在 SCADA 特征 A_i ($i=1,2,3\cdots,N$) 上的值; $\max(A_i)$ 为特征 A_i 的最大值; $\min(A_i)$ 为特征 A_i 的最小值; $\overline{x_{A_i}}$ 为归一化以后的 x_{A_i} 。

2.3 特征值选取

风电机组运行过程中并不是所有的 SCADA 数据特征都与研究的状态变量有关,为了提高风电机组故障预测模型的精度并降低预测模型的训练时长,训练集和测试集需要选取与风电机组有功功率相关的特征子集。本文选取斯皮尔曼相关性分析方法提取能直接或间接反映风电机组有功功率的参数集,斯皮尔曼相关系数是以 Charles Spearman 命名的相关系数,是衡量 2 个变量的依赖性的非参数指标^[15]。斯皮尔曼计算公式为:

$$r_s = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (12)$$

式中: x_i 为变量第 i 个的位次 ($i=1,2,3\cdots,N$); y_i 为另一变量第 i 个位次 ($i=1,2,3\cdots,N$); $\bar{x}$ 为变量的平均位次; $\bar{y}$ 为另一变量的平均位次。

在实际应用中,变量间的连结是无关紧要的,于是在一定情况下可以由以下公式计算得到:

$$r_s = 1 - \frac{6 \sum_{i=1}^N d_i^2}{N(N^2 - 1)} \quad (13)$$

$$d_i = x_i - y_i \quad (14)$$

式中: x_i 为变量第 i 个的位次 ($i=1,2,3\cdots,N$); y_i 为另一变量第 i 个位次 ($i=1,2,3\cdots,N$); N 为变量的列向量长度。

相关性系数的绝对值越大时特征之间的相关性越强,本文采用 scipy 中封装的斯皮尔曼相关性系数函数进行计算。

表 1 列出了与风电机组有功功率相关性系数较强的特征值,分别为风速、发电机转速、发电机绕组 1 温度、发电机非驱动端轴承温度,选取上述 4 种特征值作为与有功功率有关的特征子集。

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

选取特征名称	斯皮尔曼相关性系数	特征编号
风速/ $(\text{m}\cdot\text{s}^{-1})$	0.98	A_1
发电机转速/ $(\text{r}\cdot\text{min}^{-1})$	0.70	A_2
发电机绕组 1 温度/ $^{\circ}\text{C}$	0.84	A_3
发电机非驱动端轴承温度/ $^{\circ}\text{C}$	0.66	A_4

3 Transformer 模型算法验证

在完成数据预处理后,进行 Transformer 模型的方法验证,验证流程如图 3 所示。首先将模型放入处理好的训练集进行训练,获取模型在处理好的训练集中所预测的有

功率,求取实际有功功率和预测有功功率的残差,结合实际情况和残差进行阈值的判定及报警规则的设定,之后将训练好的模型放入测试集,获得测试集有功功率真实值与预测值的残差,根据所设定的阈值及报警规则,对测试集有功功率的残差进行判定,进而做出故障预测,最后将模型做出的故障预测结果与实际记录结果进行对比,验证方法的准确性。




图 3 Transformer 模型方法验证流程

Fig. 3 Transformer model method validation flow chart

在完成对训练集和测试集的处理后,将训练集放入 Transformer 模型,设定时间步长为 1,每 64 组采样点数据作为一批进行训练,采用自适应矩估计(adaptive moment estimation, Adam)优化器和均方误差(mean squared error, MSE)损失函数,学习率为 0.000 1,训练次数为 50。训练完成后,训练集有功功率真实值与预测值对比如图 4 所示,训练集有功功率残差如图 5 所示。




图 4 训练集有功功率真实值和预测值对比

Fig. 4 Comparison of real and predicted active power of training set

采用正态分布的性质,对训练集有功功率的真实值与预测值的残差设置合适的阈值 a ,使得阈值区间 $[-a, a]$ 内包含绝大部分的正常数据,未在阈值区间内的数据为异常数据,通过对训练集有功功率残差的分析计算后得到阈值 a 为 0.433,如图 6 所示。

考虑到 SCADA 系统的采样频率为每 5 min 采样一次,连续 3 次采样的时间间隔为 10 min,对故障的恶化影响程度较低,因此对连续的 3 次信号进行分析,可保证预测方法报警的可靠性。综上所述,设定报警规则为当有功功率残




图 5 训练集有功功率真实值和预测值残差

Fig. 5 Residual diagram of real and predicted active power of training set




图 6 风电机组训练集残差分布

Fig. 6 Residual distribution diagram of wind turbine training set

差连续 3 次超出阈值点时做出风电机组出现故障的预测。

利用训练好的模型对后续 10 个月的测试集数据展开故障预测,测试集有功功率真实值与预测值对比如图 7 所示,其有功功率残差如图 8 所示。




图 7 测试集有功功率真实值和预测值对比

Fig. 7 Comparison of real and predicted active power of the test set




图8 测试集有功功率真实值和预测值残差

Fig. 8 Residual diagram of the true and predicted active power of the test set

将阈值放入测试集有功功率残差图中,其结果如图9所示,通过之前设定的报警规则进行故障预测。经过判定共产生2次故障预测,第1次在79 107样本点处做出故障预测(样本点0为起始点),通过查阅SCADA系统日志发现,实际在模型做出故障预测后风电机组的发电机轴承发生了故障,在80 638样本点处引起SCADA系统报警,进而后续对风电机组进行了停机检修,所提模型方法相较SCADA系统提前5天07小时35分钟对风电机组做出故障预测;第2次在85 113样本点处做出故障预测,通过查阅SCADA系统日志发现,风电机组在SCADA系统发出报警后,后续停机更换了新的轴承,之后继续投入使用,通过查阅文献资料可知,在该位置模型做出故障预测,是因为新安装的轴承处于磨合期,由于新部件与风电机组的磨合造成模型做出故障预测,属于正常现象。




图9 测试集有功功率残差和阈值结果

Fig. 9 Test set active power residual and threshold result graph

4 实验结果对比分析

考虑到其他深度神经网络算法也可用于风电机组整机的故障预测研究,为了进行更加直观的对比,首先选用长短时记忆网络(long short-term memory, LSTM)模型进行故

障预测对比,采用与上述相同的时间步长、优化器、损失函数进行模型的训练,选取训练后损失值基本收敛稳定的模型放入测试集进行测试。获得阈值 a 为0.390,采用相同的报警规则,其测试集有功功率真实值与预测值残差和阈值结果如图10所示。




图10 测试集有功功率残差和阈值结果

Fig. 10 Test set active power residual and threshold result graph

经过报警规则的判断后,LSTM模型共做出5次故障预测(样本点0为起始点),经过查阅SCADA系统报警日志发现,9 116样本点、15 450样本点和76 215样本点所预测出的结果为误预测,实际风电机组并未出现故障,在79 107样本点处做出故障预测,相较SCADA系统报警提前5天07小时35分钟,85 113样本点处的故障预测实际为风电机组更换部件后部件磨合所致。分析原因是因为LSTM模型受到了异常噪声数据的影响,从而产生了误预测。

基于上述缺点,对LSTM模型进行改进,选用双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)模型继续进行对比验证,采用与上述相同的时间步长、优化器、损失函数进行模型的训练,选取训练后损失值基本收敛稳定的模型放入测试集进行测试。获得阈值为0.399,采用相同的报警规则,其测试集有功功率真实值与预测值残差和阈值结果如图11所示。

经过报警规则的判断后,BiLSTM模型共做出3次风电机组故障预测(样本点0为起始点),经过查阅SCADA系统报警日志发现在76 215样本点所预测出的结果为误预测,实际风电机组并未出现故障,在79 107样本点处做出故障预测,比实际SCADA系统报警提前5天07时35分,在85 113样本点处做出风电机组故障预测,实际为风电机组更换部件后部件磨合所致。该模型虽然成功预测出风电机组潜在故障,在一定程度上减少了误预测,但是仍然出现了误预测。

在故障研究中除使用基础模型之外,还普遍将基础模型与其他结构进行组合,构建组合模型进行研究,其中卷积神经网络模型^[16](convolutional neural network, CNN)和注意




图 11 测试集有功功率残差和阈值结果

Fig. 11 Test set active power residual and threshold result graph

力机制^[17](Attention)与基础模型结合较为普遍,因此使用卷积神经网络-长短时记忆网络(convolutional neural network-long short-term memory,CNN-LSTM)和双向长短时记忆网络-注意力机制(bidirectional long short-term memory-Attention,BiLSTM-Attention)模型与文章所提模型继续对比,两种对比模型均采用与上述相同的时间步长、优化器、损失函数进行模型的训练。

在 CNN-LSTM 模型中,使用卷积神经网络可以提取输入时间序列数据的空间特征^[18],简化输入数据复杂度。选取训练后损失值基本收敛稳定的模型放入测试集进行测试。获得阈值 a 为 0.390,采用相同的报警规则,其测试集有功功率真实值与预测值残差和阈值结果如图 12 所示。




图 12 测试集有功功率残差和阈值结果

Fig. 12 Test set active power residual and threshold result graph

经过报警规则的判断后,CNN-LSTM 模型共做出 3 次风电机组故障预测(样本点 0 为起始点),经过查阅 SCADA 系统报警日志发现在 76 215 样本点所预测出的结果为误预测,实际风电机组并未出现故障,在 79 107 样本点处做出故障预测,比实际 SCADA 系统报警提前 5 天 07 时 35 分,在 85 113 样本点处做出风电机组故障预测,实际为风电机组更换部件后部件磨合所致。

在 BiLSTM-Attention 模型中,使用注意力机制可以使

模型快速关注到一些关键性的特征,忽略不重要的特征^[19]。选取训练后损失值基本收敛稳定的模型放入测试集进行测试。获得阈值 a 为 0.407,采用相同的报警规则,其测试集有功功率真实值与预测值残差和阈值结果如图 13 所示。




图 13 测试集有功功率残差和阈值结果

Fig. 13 Test set active power residual and threshold result graph

经过报警规则的判断后,BiLSTM-Attention 模型共做出 4 次风电机组故障预测(样本点 0 为起始点),经过查阅 SCADA 系统报警日志发现在 15 450 样本点和 76 215 样本点所预测出的结果为误预测,实际风电机组并未出现故障,在 79 107 样本点处做出故障预测,比实际 SCADA 系统报警提前 5 天 07 时 35 分,在 85 113 样本点处做出风电机组故障预测,实际为风电机组更换部件后部件磨合所致。

上述 4 种模型虽然成功预测出风电机组潜在故障,但是仍然出现了误预测。如果在实际中使用,需要人为对风电机组是否发生故障进行判定。分析原因认为,虽然组合模型相较于基础对比模型,改善了模型对风电机组故障的预测能力,模型具备了更加细致的对异常特征的捕捉能力,但是模型依然还会受到异常噪声数据影响而产生误预测,特别是在 BiLSTM-Attention 模型中,加入注意力机制后虽然在训练集中可以快速关注到重要特征,但同时注意力机制可能忽略了测试集中其他关键特征,导致其误预测次数相较于 BiLSTM 模型有所增加。

综上所述,表 2 列出了 5 种方法的预测对比结果,分析可知,本文所提 Transformer 模型对风电机组的故障预测效果更加理想。

表 2 不同方法结果对比					
Table 2 The results of different methods are compared					
参数	LSTM	CNN-LSTM	BiLSTM	BiLSTM-Attention	Transformer
MSE	0.025	0.037	0.018	0.011	0.011
阈值	0.390	0.390	0.399	0.407	0.433
误预测次数	3	1	1	2	0
故障预测点	79 107	79 107	79 107	79 107	79 107

5 结 论

风电机组的 SCADA 系统通常仅在故障严重时发出报警信号。基于 SCADA 数据的特征参数,采用 Transformer 模型构建风电机组有功功率预测模型,通过分析有功功率实际值与预测值之间的残差变化情况,对风电机组进行故障预测。

利用风电机组 14 个月的 SCADA 数据对所提方法进行验证分析,得到以下结论,Transformer 模型展示了较为理想的故障预测效果,相较于 SCADA 系统可提前发现风电机组存在的潜在故障;Transformer 模型具备故障预测的稳定性,模型可以消除误预测。

可将 Transformer 模型应用于风电机组齿轮箱、发电机等核心关键部件的故障预测,根据不同关键部件选取不同的输入特征值进行模型验证,测试模型的使用效果,进而实现故障预测。

参考文献

- [1] 王一妹,刘辉,宋鹏,等. 基于多阶段递进识别的风电机组异常运行数据清洗方法[J]. 可再生能源, 2020, 38(11): 1470-1476.
WANG Y M, LIU H, SONG P, et al. Data cleansing method for abnormal operation of wind turbine based on multi-stage progressive identification [J]. Renewable Energy, 2020, 38(11): 1470-1476.
- [2] 李森娟,张萍,岳大为,等. 基于支持向量机的风电机组故障预测[J]. 计算机仿真, 2022, 39(5): 84-88.
LI S J, ZHANG P, YUE D W, et al. Fault prediction of wind turbine based on support vector machine[J]. Computer Simulation, 2022, 39(5): 84-88.
- [3] REN H, XIA J, TANG H X, et al. Active learning-based wind turbine failure prediction with consideration of data from different wind farms[J]. Journal of Physics: Conference Series, 2023, 2427(1): 012044.
- [4] LIMA L A M, BLATT A, FUJISE J. Wind turbine failure prediction using SCADA data[C]. Journal of Physics: Conference Series. IOP Publishing, 2020, 1618(2): 022017.
- [5] 张西晨,徐璐. 基于边缘智能的风电机组设备监测系统[J]. 电子测量技术, 2023, 46(2): 52-58.
ZHANG X CH, XU L. Wind turbine equipment monitoring system based on edge intelligence [J]. Electronic Measurement Technology, 2023, 46(2): 52-58.
- [6] 周伟波,潘虹. 基于改进深度学习的海上风电机组齿轮故障预测方法[J]. 供用电, 2022, 39(6): 83-91.
ZHOU W B, PAN H. Gear fault prediction method for offshore wind turbines based on improved deep learning[J]. Power Supply and Consumption, 2022, 39(6): 83-91.
- [7] 何群,尹飞飞,武鑫,等. 基于长短期记忆网络的风电机组齿轮箱故障预测[J]. 计量学报, 2020, 41(10): 1284-1290.
HE Q, YIN F F, WU X, et al. Gearbox fault prediction of wind turbine based on long short term memory network[J]. Journal of Metrology, 2020, 41(10): 1284-1290.
- [8] 马永光,冯勇升. 基于 IICEEMDAN-PCA-GRU 的风电机组齿轮箱故障预警方法研究[J]. 太阳能学报, 2023, 44(4): 67-73.
MA Y G, FENG Y SH. Research on wind turbine gearbox fault warning method based on IICEEMDAN-PCA-GRU[J]. Journal of Solar Energy, 2023, 44(4): 67-73.
- [9] 韩万里,茅大钧,蔡晔,等. 基于数据融合的风电变桨系统故障预警研究[J]. 太阳能学报, 2022, 43(12): 236-241.
HAN W L, MAO D J, CAI Y, et al. Research on fault warning of wind power pitch system based on data fusion [J]. Journal of Solar Energy, 2022, 43(12): 236-241.
- [10] 田雯雯,吕丽霞,冯雪凯,等. 基于改进 AAKR 的风电机组齿轮箱状态监测[J]. 电子测量技术, 2022, 45(15): 158-165.
TIAN W W, LYU L X, FENG X K, et al. Condition monitoring of wind turbine gearbox based on improved AAKR [J]. Electronic Measurement Technology, 2022, 45(15): 158-165.
- [11] CAI L, JANOWICZ K, MAI G CH, et al. Traffic transformer: Capturing the continuity and periodicity of time series for traffic forecasting[J]. Transactions in GIS, 2020, 24(3): 736-755.
- [12] 王译文,黎建军,曲再鹏. 基于 Transformer 的短期血糖预测方法研究[J]. 中国计量大学学报, 2023, 34(3): 372-378.
WANG Y W, LI J J, QU Z P. Research on short term blood glucose prediction method based on transformer[J]. Journal of China University of Metrology, 2023, 34(3): 372-378.
- [13] 田爱宝,魏娇娇,肖军弼. 基于 Transformer 的网络流量预测研究[J]. 信息技术, 2024(4): 156-160.
TIAN AI B, WEI J J, XIAO J B. Research on Transformer based network traffic prediction [J]. Information Technology, 2024(4): 156-160.
- [14] 夏延秋,夏和民,冯欣. 一种基于风功率曲线的 SCADA 数据清洗方法研究[J]. 可再生能源, 2022,

- 40(11): 1499-1504.
- XIA Y Q, XIA H M, FENG X. A study on SCADA data cleaning method based on wind power curve[J]. Renewable Energy, 2022, 40(11): 1499-1504.
- [15] 于群, 霍筱东, 何剑, 等. 基于斯皮尔曼相关系数和系统惯量的中国电网停电事故趋势预测[J]. 中国电机工程学报, 2023, 43(14): 5372-5381.
- YU Q, HUO X D, HE J, et al. Trend prediction of power outage accidents in China's power grid based on Spearman correlation coefficient and system inertia[J]. Chinese Journal of Electrical Engineering, 2023, 43(14): 5372-5381.
- [16] 马良玉, 吕若萌. 用 SSA 优化 CNN-LSTM-SEnet 预测模型实现风电机组故障预警[J]. 电力科学与工程, 2024, 40(6): 1-10.
- MA L Y, LYU R M. The CNN-LSTM-SEnet prediction model was optimized by SSA to realize the fault warning of wind turbine [J]. Electric Power Science and Engineering, 2024, 40(6): 1-10.
- [17] 王颖, 朱大伟, 郑迪, 等. 基于 Bi-LSTM-Attention 的直流配电网故障检测方法[J/OL]. 华北电力大学学报(自然科学版), 1-9 [2024-07-14]. <http://kns.cnki.net/kcms/detail/13.1212.TM.20240423.1129.002.html>.
- WANG Y, ZHU D W, ZHENG D, et al. Fault detection method of DC distribution network based on Bi-LSTM-Attention[J/OL]. Journal of North China Electric Power University(Natural Science Edition), 1-9 [2024-07-14]. <http://kns.cnki.net/kcms/detail/13.1212.TM.20240423.1129.002.html>.
- [18] 许珠路, 王兴芬, 刘亚辉. 融合 CNN-BiLSTM-Attention 的集成学习价格预测[J]. 计算机系统应用, 2023, 32(6): 32-41.
- XU ZH L, WANG X F, LIU Y H. Integrated learning price prediction with CNN-BiLSTM-Attention [J]. Computer System Application, 2023, 32(6): 32-41.
- [19] 杨秋澍. 基于 BiLSTM-Attention 的房颤的检测模型[J]. 信息与电脑(理论版), 2023, 35(1): 131-133.
- YANG Q SH. Detection model of atrial fibrillation based on BiLSTM-Attention [J]. Information and Computers (Theoretical Edition), 2023, 35(1): 131-133.

作者简介

朱彦民, 硕士研究生, 主要研究方向为风电机组状态检测。

李忠虎(通信作者), 硕士研究生, 教授, 主要研究方向为无损检测、机电设备故障诊断。

E-mail: lizhonghu@imust.edu.cn