

基于图正则化堆叠自编码器的风机轴承故障诊断方法

刘展¹, 刘健洵², 包琰洋², 李大字^{2*}

(1. 北京能高普康测控技术有限公司, 北京市 丰台区 100070; 2. 北京化工大学信息科学与技术学院, 北京市 朝阳区 100029)

Bearing Faults Diagnosis Method Based on Stacked Auto-Encoder With Graph Regularization for Wind Turbines

LIU Zhan¹, LIU Jianxun², BAO Yanyang², LI Dazi^{2*}

(1. Beijing Pukang Measurement and Monitoring Tech Co., Ltd., Fengtai District, Beijing 100070, China; 2. College of Information Science and Technology, Beijing University of Chemical Technology, Chaoyang District, Beijing 100029, China)

摘要:【目的】为解决风电机组轴承故障诊断中的故障特征提取效率低、特征表示不够精准以及现有方法难以适应复杂信号需求的问题,提出一种基于图正则化的故障诊断方法,提升了对振动信号的分析能力,从而实现对不同故障类型的准确分类和可靠诊断。【方法】采用基于图正则化自编码器的技术,结合图嵌入思想,指导堆叠监督自编码器进行特征提取。在故障特征提取阶段,首先对诊断信号进行图表示,然后在堆叠自编码器中添加图正则化项,以确保嵌入后的低维特征保持流形结构,从而提取数据深层的复杂几何特征。【结果】所提取的特征能够实现对不同故障类型的准确分类,展现出在故障特征捕捉方面的显著优势。实验结果表明,该方法在实际风场数据的应用中,具有更高的诊断精度和可靠性,有效提高了故障特征的提取效率和分类准确性。【结论】所提方法在风电轴承故障诊断领域表现出显著的有效性和优越性,为实际应用提供了可靠的技术支持。

关键词: 风电机组; 轴承; 故障诊断; 图正则化; 自编码器; 图嵌入; 特征提取; 振动信号

ABSTRACT: [Objectives] In order to solve the problems of low efficiency of fault feature extraction, inaccurate feature representation, and difficulty in adapting existing methods to complex signal requirements in wind turbine bearing fault diagnosis, a fault diagnosis method based on graph regularization was proposed. The method helps to improve the analysis ability of vibration signals, thereby achieving

accurate classification and reliable diagnosis of different fault types. [Methods] The technology based on graph regularization auto-encoder was adopted, combined with the idea of graph embedding, to guide the stack-supervised auto-encoder to carry out feature extraction. In the fault feature extraction stage, the diagnostic signal was first graphically represented, and then graph regularization terms were added to the stacked auto-encoder to ensure that the embedded low-dimensional features maintain the manifold structure, thereby extracting complex geometric features deep in the data. [Results] The extracted features can accurately classify different fault types, showing significant advantages in fault feature capture. Experimental results show that this method has higher diagnosis accuracy and reliability in the application of actual wind farm data, and effectively improves the extraction efficiency and classification accuracy of fault features. [Conclusions] The proposed method has shown significant effectiveness and advantages in the field of wind power bearing fault diagnosis, and provides reliable technical support for practical applications.

KEY WORDS: wind turbine; bearing; fault diagnosis; graph regularization; auto-encoder; graph embedding; feature extraction; vibration signal

0 引言

在“碳达峰”“碳中和”等国家节能减碳战略的能源革命大背景下,风电作为一种绿色能源,是推动“双碳”目标实现的一个关键环节之一^[1-2]。大部分风力发电机部署在海上或者较为偏远的地区,由于环境恶劣,其故障率较高,最常见的故障往往发生在机组的轴承中^[3-7]。

基金项目: 国家自然科学基金项目(62273026); 工信部高技术船舶科研项目(MC-202025-S02)。

Project Supported by National Natural Science Foundation of China (62273026); High-Tech Ship Research Project of Ministry of Industry and Information Technology (MC-202025-S02).

滚动轴承是风电机组中发生故障最为频繁的部件之一。风力发电机轴承大致可分为4类：变桨轴承、偏航轴承、传动系统轴承(主轴和齿轮箱轴承)和发电机轴承^[8]。轴承一般分为4个部分：外圈、保持架、滚动元件和内圈。风机轴承常见故障包括疲劳故障、磨损故障、缺口或凹痕故障和腐蚀故障^[9]。

风力发电机滚动轴承初始故障后机组仍会继续运行。然而，随着异常操作次数增加，轴承损坏引起的外部激励会导致系统发生故障，极端情况下会引起火灾。轴承的运转状态关系着整个机组的运行状态，一旦发生故障将产生高额的维修费用和长时间的停机。因此，对风机轴承进行有效、智能的状态监测和故障诊断，对于保证风机的健康运行具有重要意义^[10]。

随着人工智能技术的发展和计算能力的提高，现代工业生产进入大数据时代。深度学习模型发挥了大数据处理的优势，卷积神经网络(convolutional neural networks, CNN)^[11]、深度自动编码器^[12]、极限学习机^[13]和长短期记忆网络(long short-term memory, LSTM)^[14]被广泛应用于轴承故障诊断领域。然而这些深度学习的方法在训练中未能有效应用振动信号的丰富特征，网络训练的过程中往往存在大量的信息丢失与失真，训练后网络的泛化性较差，难以应用到实际工业过程。

将机器学习应用于特征提取方法，在风机故障诊断中有一定应用。文献[15]利用先进的信号处理技术对振动数据进行处理，计算统计时域和频域特征，然后采用决策树算法进行特征选择。文献[16]提出了一种基于级联空间投影和卷积神经网络模型的故障诊断方法。文献[17]提出了一种结合马尔可夫转移场和卷积神经网络自动学习数据特征的新方法。虽然许多类似的模型在轴承故障诊断中具有较高的识别率，但仍未能充分发挥深度学习在复杂信号特征提取方面的优势，诊断精度会随着网络的加深而降低^[18]。

图分析是一个快速发展的领域，涉及分析和处理大规模的图形数据，具有能够将先验知识与数据融合的优点。将图分析方法与工业领域相结

合是一个十分有前景的方向。本文提出了一种基于图正则化自编码器的风力发电机轴承故障诊断方法。通过将振动信号数据进行图表征，引入拉普拉斯图嵌入的正则化表达式，并和堆叠自编码器结合，提出了基于图正则化的堆叠自编码器，解决了堆叠自编码器中的强映射和过拟合等问题，加快了训练速度，同时避免了训练过程中落入局部最优值。

1 基于图正则化堆叠自编码器的故障特征提取

1.1 自编码器定义

自编码器模型是编码器和解码器的组合(见图1)，编码器根据输入的高维数据生成嵌入特征的映射，解码器则用于重构嵌入特征以匹配原始输入数据，解码器的输出可以近似地恢复编码器的输入。具有多个隐藏层的自编码器被称为堆叠自编码器(stacked auto-encoders, SAE)，可以视为多个自编码器的组合嵌套。




图1 自编码器网络结构

Fig. 1 Autoencoder network architecture

编码网络学习原始数据的有效特征 x 生成嵌入特征 z ，解码网络尝试通过嵌入特征 z 重构生成 $\hat{x}$ ，学习目标是使得重构误差最小化，网络参数优化目标可以描述为

$$f, g = \underset{f, g}{\operatorname{argmin}} L\{x, f[g(x)]\} \quad (1)$$

式中 f 和 g 分别为解码层和编码层网络参数，一般采用均方误差作为损失函数 L ，其公式为

$$L(\theta) = \frac{\beta}{2N} \sum_{i=1}^N \|x_i - \hat{x}_i\|_2^2 \quad (2)$$

式中： N 为样本数量； θ 为网络整体的参数集合； β 为惩罚系数。

作为一种无监督学习技术，SAE的训练过程可使得特征重构误差最小化，有利于特征提取。然而，对于故障分类问题，SAE不能保证提取的

特征与特定任务相关,这是因为其目标函数被设定为尽可能多地保留原始信息。对于故障分类目标而言,其深层嵌入特征没有很强的故障相关性,因此不能保证在不同故障类型下彼此之间是可区分的,这使得后续的分类器很难根据提取的特征区分不同故障类型的样本。针对这一问题,本文提出了带有图正则化的SAE监督学习算法来提取故障特征,利用图嵌入的思想来指导堆叠监督自编码器进行特征提取,以确保嵌入后的低维特征保持流形结构,提取到数据深层的复杂几何特征。

1.2 拉普拉斯图嵌入

拉普拉斯图嵌入(Laplacian eigenmaps, LE)是一种流形学习算法,通过构造图的方式来捕捉数据的流形结构,并通过求解拉普拉斯矩阵的特征向量来实现数据降维和可视化。

LE首先通过高斯核函数构造相似度矩阵 W ,用于描述样本点之间的相似度:

$$W_{i,j} = e^{-\frac{\|x_i - x_j\|^2}{\sigma^2}} \quad (3)$$

式中: x_i 和 x_j 分别表示第 i 和第 j 个样本点的特征向量; σ 是高斯核函数的带宽参数。

LE的核心是拉普拉斯矩阵 L 的计算。拉普拉斯矩阵描述了图的拓扑结构,它是度矩阵 D 和相似度矩阵 W 的差值,即

$$L = D - W \quad (4)$$

式中度矩阵 D 是一个对角矩阵,其对角线元素为每个节点的相似度之和,即

$$D_{i,i} = \sum_{j=1}^N W_{i,j} \quad (5)$$

LE算法的目标是将数据映射到低维空间中,并且保持数据点在高维空间中的局部关系。假设在高维空间 R^D 的数据集 $X = \{x_1, x_2, \dots, x_n\}$,则在低维嵌入空间 R^d 的映射为 $Y = \{y_1, y_2, \dots, y_n\}$ 。

1.3 图正则化

通过在堆叠监督自编码器的损失函数上加入正则化项,使SAE充当LE算法中的映射函数。当模型在训练迭代与更新神经网络权重时,可保证提取到的嵌入特征保持了原有高维空间中的流形特征。

用无向图 G 来表示特征间相互关系的集合, $G=(V,E)$,其中 $V = \{v_1, \dots, v_n\}$ 是有限节点的集合。

$E = \{e_{i,j}\}_{i,j=1}^n$ 表示节点间边的集合,且 $e_{i,j}=(v_i, v_j)$ 是 v_i 和 v_j 的边。故障特征图表征如图2所示,假设 $X=[x_1 \cdots x_n]$ ($x_i \in R^d$)是样本构成的矩阵,其中 n 是样本的数量, d 是特征的维度,则图中的每个节点 v_i 对应着一个特征向量 x_i 。变量 $A \in R^{N \times N}$ 表示图的邻接矩阵,对于2个节点 v_i, v_j ,定义 A_{ij} 为

$$A_{ij} = \begin{cases} 1, & \text{节点 } v_i, v_j \text{ 相连} \\ 0, & \text{节点 } v_i, v_j \text{ 不相连} \end{cases} \quad (6)$$




图2 故障特征图表征

Fig. 2 Graphical representations of fault characteristics

给定一个高维数据集,并将每个数据视为一个节点,则2个节点之间的相似度可以由特定的评估函数生成。如果将SAE算法作为一个降维函数 f ,根据图正则化的思想,函数 f 可以表示为

$$f: w_{ij} \geq w_{pq},$$

$$\text{then } (x_p - x_q)^2 \geq (x_i - x_j)^2, \forall i, j, p, q \quad (7)$$

式中: w_{ij} 、 w_{pq} 分别为连接节点 i 、 j 的边的权重和连接节点 p 、 q 的边的权重; x_i 为节点 i 的数据通过映射函数 f 得到的低维表示。根据式(7)可构造如下正则化表达式:

$$L_{1st} = \alpha_1 \sum_{i,j=1}^N w_{ij} \|x_i - x_j\|_2^2 + \alpha_2 \sum_{i,j=1}^N \frac{1 - w_{ij}}{\|x_i - x_j\|_2^2 + \delta} \quad (8)$$

式中: α_1 和 α_2 是惩罚系数; δ 是接近0的常数; N 是节点数量。

结合式(2)可得到如式(9)所示的带有图正则化的监督自编码器模型:

$$L(\theta) = \frac{\beta}{2N} \sum_{i=1}^N \|x_i - \hat{x}\|_2^2 + \alpha_1 \sum_{i,j=1}^N w_{ij} \|x_i - x_j\|_2^2 + \alpha_2 \sum_{i,j=1}^N \frac{1 - w_{ij}}{\|x_i - x_j\|_2^2 + \delta} \quad (9)$$

该模型能够利用图中节点间的一阶相似度提

取编码器-解码器框架下图的流形结构信息。通过改进自编码器的结构和损失函数,实现分类任务中捕获类内数据和类间数据之间的高维非线性关系,并在最小化原始信息损失的情况下有利于学习任务相关特征。

1.4 信号处理及时频域特征提取

为了分析信号进行故障检测,需要在不损失信号中故障信息的情况下去除原始振动信号中的噪声。本文选用了 Coiflet 小波进行去噪,与其他小波相比更加对称,具有线性相位响应,并且其尺度函数和小波函数都有消失矩,更有利于数据压缩和消除噪声^[19-20]。表 1 展示了使用不同小波得到的均方误差(mean square error, MSE)、信噪比(signal-to-noise ratio, SNR)和峰值信噪比(peak signal-to-noise ratio, PSNR)。可以看出, Coiflet 小波去噪后的信号 MSE 值最小, SNR 和 PSNR 最高,表明对于轴承振动信号去噪, Coiflet 小波的去噪能力优于其他方法。

表 1 不同小波函数的性能比较

Tab. 1 Performance comparison of different wavelet functions

小波函数	MSE	SNR	PSNR
Coiflet	15.463 2	11.944 8	12.513 6
Meyer	16.485 9	11.666 7	12.235 4
Daubechies	17.040 3	11.523 0	12.091 7
Symlet	17.018 2	11.528 7	12.097 4

为了和提出的特征提取算法作对比,采用传统特征提取的方法分别从原始振动信号和处理后的信号中提取了 24 个特征参数^[21]。具体特征参数如表 2 所示,其中 11 个参数是时域统计特征,13 个参数是频域统计特征。当旋转机械发生故障时,时域信号可能会发生变化,其幅度和分布都可能与正常情况下的时域信号不同。此外,频谱及其分布可能会发生变化,这意味着可能会出现新的频率分量,并且频谱收敛性可能会发生变化。参数 p_1 和 p_3-p_5 反映时域的振动幅度和能量,参数 p_2 和 p_6-p_{11} 表示信号在时域中的时间序列分布,参数 p_{12} 表示频域中的振动能量,参数 $p_{13}-p_{15}$ 、 p_{17} 和 $p_{21}-p_{24}$ 描述频谱功率的收敛,参数 p_{16} 和 $p_{18}-p_{20}$ 显示主频率的位置变化。

表 2 特征参数

Tab. 2 Characteristic parameters

时域特征	频域特征
$p_1 = \frac{\sum_{n=1}^N x(n)}{N}$	$p_{12} = \frac{\sum_{k=1}^K s(k)}{K}$
$p_2 = \sqrt{\frac{\sum_{n=1}^N [x(n)-p_1]^2}{N-1}}$	$p_{13} = \frac{\sum_{k=1}^K [s(k)-p_{12}]^2}{K-1}$
$p_3 = (\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N})^2$	$p_{14} = \frac{\sum_{k=1}^K [s(k)-p_{12}]^3}{K(\sqrt{p_{13}})^3}$
$p_4 = \sqrt{\frac{\sum_{n=1}^N [x(n)]^2}{N}}$	$p_{15} = \frac{\sum_{k=1}^K [s(k)-p_{12}]^4}{Kp_{13}^2}$
$p_5 = \max x(n) $	$p_{16} = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$
$p_6 = \frac{\sum_{n=1}^N [x(n)-p_1]^3}{(N-1)p_2^3}$	$p_{17} = \sqrt{\frac{\sum_{k=1}^K (f_k - p_{16})^2 s(k)}{K}}$
$p_7 = \frac{\sum_{n=1}^N [x(n)-p_1]^4}{(N-1)p_2^4}$	$p_{18} = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}}$
$p_8 = \frac{p_5}{p_4}$	$p_{19} = \sqrt{\frac{\sum_{k=1}^K f_k^4 s(k)}{\sum_{k=1}^K f_k^2 s(k)}}$
$p_9 = \frac{p_5}{p_3}$	$p_{20} = \frac{\sum_{k=1}^K f_k^{2s(k)}}{\sqrt{\sum_{k=1}^K s(k)} \sum_{k=1}^K f_k^4(k)}$
$p_{10} = \frac{p_4}{\frac{1}{N} \sum_{n=1}^N x(n) }$	$p_{21} = \frac{p_{17}}{p_{16}}$
$p_{11} = \frac{p_5}{\frac{1}{N} \sum_{n=1}^N x(n) }$	$p_{22} = \frac{\sum_{k=1}^K (f_k - p_{16})^3 s(k)}{Kp_{17}^3}$
	$p_{23} = \frac{\sum_{k=1}^K (f_k - p_{16})^4 s(k)}{Kp_{17}^4}$
	$p_{24} = \frac{\sum_{k=1}^K (f_k - p_{16})^{1/2} s(k)}{K \sqrt{p_{17}}}$

2 实验结果与分析

2.1 数据预处理

本文采用的数据集是来自内蒙古某风电厂的风机振动数据,其中包括主轴、齿轮箱和发电机 3 个不同部位轴承的实际数据,其主要故障都是轴承磨损。主轴包括主轴承径向和主轴承轴向 2 个测点,齿轮箱包括齿轮箱高速轴电机侧径向 1 个测点,发电机包括发电机驱动端轴承和非驱动端轴承 2 个测点。

首先对数据进行去除趋势项以及小波去噪的预处理。采用通用阈值法对信号进行 Coiflet 小波去噪。在小波分解中,对信号的分解是逐层进行的,对每一层的近似分量进行分解,以获得下一

层的近似分量与细节分量，信号被分解为4个层次。采用无偏似然估计的软阈值估计对小波系数进行非线性处理^[22]。预处理前后的齿轮箱轴承时域振动信号对比如图3所示。




图3 齿轮箱轴承数据预处理前后的时域信号对比

Fig. 3 Comparison of time-domain signals before and after preprocessing of gearbox bearing data

每个数据集包含大约12万条采样数据，首先使用汉宁窗对每个数据集进行切片，通过计算可以得到每个数据集中一个周期对应的采样点个数，汉宁窗的长度为相应数据集的一个信号周期的长度。采用带有图正则化的自编码器进行特征提取，将每个切片的数据作为一个节点构造图表示，对于2个节点 v_i, v_j ，定义 A_{ij} 为

$$A_{ij} = \begin{cases} 1, & \text{节点 } v_i, v_j \text{ 属于同一类别} \\ 0, & \text{节点 } v_i, v_j \text{ 属于不同类别} \end{cases} \quad (10)$$

采用4层解码层的自编码器结构，损失函数的参数 $\beta, \alpha_1, \alpha_2$ 分别为0.01, 0.005, 0.05。输入层的神经元个数即为一个切片的长度。将隐藏层得到的特征向量提取出来并用作神经网络的输入来搭建预测模型。此外，利用t-SNE算法将得到的特征进行二维可视化。

图4展示了3个不同位置的轴承故障与正常数据进行特征提取后的可视化结果。故障数据的故障类型都是轴承磨损，每个分图表示不同位置的多个测点在不同时间点经过处理后的数据。可见，具有图正则化的SAE可以看作是具有良好的流形结构保持能力的映射函数。将高维数据很好地映射到低维空间，在低维空间中，同类样本点聚在一起，而不同类的样本点则相距较远，因此故障数据和正常数据在低维空间中被很好地分割开来。

接着采用时频域特征提取的方法进行特征提取，将同一窗口中多个通道所提取出的特征拼接




图4 故障特征可视化结果

Fig. 4 Visualization results of fault characteristics

为一个一维向量，即这个切片信号所包含的时频域特征作为分类器的一条样本。

2.2 故障分类器的训练与验证

在每个风机部位搭建了 2 个神经网络用于故障分类。2 个网络的输入分别是图正则化自编码器提取的特征和传统方法提取的时频特征。每个网络都是双隐层神经网络。训练过程采用批次训练，神经网络的学习率为 0.01，权重衰减设置为 0.01。一个批次包括 32 个样本，训练 5~10 轮后达到稳定。选取相同风场的其他数据集用作模型的验证，这些数据集虽然和训练数据来自同一个风场，但机型、采样频率等相关参数有所不同。在本文的实验中，分别对 3 个不同位置轴承的轴承磨损与内外环破损故障类型进行了诊断，表 3、4 分别展示了对轴承磨损与内外环破损故障类型最终的分类准确率。

表 3 采用不同特征提取方法后的轴承磨损故障类型分类准确率

Tab. 3 Classification accuracy of bearing wear fault types using different feature extraction methods

测点位置	图正则化自编码器	传统时频域特征提取
主轴轴承	0.976	0.908
齿轮箱轴承	0.933	0.879
发电机轴承	0.949	0.913

表 4 采用不同特征提取方法后的内外环破损故障类型分类准确率

Tab. 4 Classification accuracy of inner and outer ring damage fault types using different feature extraction methods

测点位置	图正则化自编码器	传统时频域特征提取
主轴轴承	0.953	0.900
齿轮箱轴承	0.978	0.853
发电机轴承	0.992	0.950

由表 3、4 可以看出，对于不同种类的轴承故障类型，无论是在什么位置的数据，所提出的带有图正则化的自编码器所提取的特征都具有更高的分类准确率。

3 结论

针对风力发电机滚动轴承故障诊断中故障特征不明显、诊断困难等问题，提出了基于图正则化自编码器的故障特征提取方法，得出以下结论：

1) 所提出的方法既能保持流形结构，又能保

持判别结构，训练的分类器具有更高的精度。

2) 该方法还利用去除趋势项和 Coiflet 小波去噪对真实采集的现场数据进行了预处理，使得后续模型的训练和预测更高效。

3) 研究采用了 3 个不同风机部位的轴承数据，并与时频特征提取方法进行了比较，验证了所提出算法的有效性和准确性。

参考文献

[1] BADAL F R, DAS P, SARKER S K, et al. A survey on control issues in renewable energy integration and microgrid[J]. Protection and Control of Modern Power Systems, 2019, 4(1): 8-14.

[2] 姜红丽, 刘羽茜, 冯一铭, 等. 碳达峰、碳中和背景下“十四五”时期发电技术趋势分析[J]. 发电技术, 2022, 43(1): 54-64.

JIANG H L, LIU Y X, FENG Y M, et al. Analysis of power generation technology trend in 14th Five-Year Plan under the background of carbon peak and carbon neutrality[J]. Power Generation Technology, 2022, 43(1): 54-64.

[3] SPINATO F, TAVNER P J, VAN BUSSEL G J W, et al. Reliability of wind turbine subassemblies[J]. IET Renewable Power Generation, 2009, 3(4): 387-395.

[4] 李俊卿, 马亚鹏, 胡晓东, 等. 基于 CBAM-InceptionV2-双流 CNN 的风电机组轴承故障诊断[J]. 智慧电力, 2023, 51(6): 28-33.

LI J Q, MA Y P, HU X D, et al. Wind turbine bearing fault diagnosis based on CBAM-InceptionV2-two-stream CNN[J]. Smart Power, 2023, 51(6): 28-33.

[5] 田德, 陶立壮. 计及齿轮分度圆误差的风电齿轮箱振动特性分析[J]. 可再生能源, 2023, 41(4): 480-486.

TIAN D, TAO L Z. Vibration characteristics research of wind turbine gearbox considering flank pitch error[J]. Renewable Energy Resources, 2023, 41(4): 480-486.

[6] 刘展, 包琰洋, 李大字. 基于重采样降噪与主成分分析的宽卷积深度神经网络风机故障诊断方法[J]. 发电技术, 2023, 44(6): 824-832.

LIU Z, BAO Y Y, LI D Z. Fault diagnosis method of wind turbines based on wide deep convolutional neural network with resampling and principal component analysis[J]. Power Generation Technology, 2023, 44(6): 824-832.

[7] 陈阳, 刘永前, 韩爽, 等. 基于多模态时频图融合的风电机组齿轮箱故障诊断方法[J]. 分布式能源,

- 2023, 8(3): 17-23.
- CHEN Y, LIU Y Q, HAN S, et al. Fault diagnosis method of wind turbine gearbox based on multi-mode time-frequency image fusion[J]. Distributed Energy, 2023, 8(3): 17-23.
- [8] LIU Z, ZHANG L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings[J]. Measurement, 2020, 149: 107002.
- [9] LIU B, LIU B X, DAI Q B. A review of bearing fault diagnosis for wind turbines[J]. IOP Conference Series: Earth and Environmental Science, 2021, 675(1): 012094.
- [10] 金晓航, 孙毅, 单继宏, 等. 风力发电机组故障诊断与预测技术研究综述[J]. 仪器仪表学报, 2017, 38(5): 1041-1053.
- JIN X H, SUN Y, SHAN J H, et al. Fault diagnosis and prognosis for wind turbines: an overview[J]. Chinese Journal of Scientific Instrument, 2017, 38(5): 1041-1053.
- [11] JIN T, YAN C, CHEN C, et al. Light neural network with fewer parameters based on CNN for fault diagnosis of rotating machinery[J]. Measurement, 2021, 181: 109639.
- [12] WANG X, QIN Y, WANG Y, et al. ReLTanh: an activation function with vanishing gradient resistance for SAE-based DNNs and its application to rotating machinery fault diagnosis[J]. Neurocomputing, 2019, 363: 88-98.
- [13] PANG Y, JIA L, ZHANG X, et al. Design and implementation of automatic fault diagnosis system for wind turbine[J]. Computers & Electrical Engineering, 2020, 87: 106754.
- [14] LIU J Q, PAN C L, LEI F, et al. Fault prediction of bearings based on LSTM and statistical process analysis[J]. Reliability Engineering & System Safety, 2021, 214: 107646.
- [15] SHAH A K, YADAV A, MALIK H. EMD and ANN based intelligent model for bearing fault diagnosis[J]. Journal of Intelligent & Fuzzy Systems, 2018, 35(5): 5391-5402.
- [16] ZHAO Y, ZHOU M, WANG L, et al. Bearing fault diagnosis with cascaded space projection and a CNN[J]. Control Theory and Technology, 2022, 20(1): 103-113.
- [17] WANG M, WANG W, ZHANG X, et al. A new fault diagnosis of rolling bearing based on Markov transition field and CNN[J]. Entropy, 2022, 24(6): 751.
- [18] 丁雪, 邓艾东, 李晶, 等. 基于多尺度和注意力机制的滚动轴承故障诊断[J]. 东南大学学报(自然科学版), 2022, 52(1): 172-178.
- DING X, DENG A D, LI J, et al. Fault diagnosis of rolling bearing based on multi-scale and attention mechanism[J]. Journal of Southeast University (Natural Science Edition), 2022, 52(1): 172-178.
- [19] KE Y, YAO C, SONG E, et al. Intelligent fault diagnosis method of common rail injector based on composite hierarchical dispersion entropy and improved least squares support vector machine[J]. Digital Signal Processing, 2021, 114: 103054.
- [20] POTHISARN C, KLOMJIT J, NGAOPITAKKUL A. Comparison of various mother wavelets for fault classification in electrical systems[J]. Applied Sciences, 2020, 10(4): 1203-1210.
- [21] LEI Y, HE Z, ZI Y, et al. Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs[J]. Mechanical Systems and Signal Processing, 2007, 21(5): 2280-2294.
- [22] 李树钰. 改进的小波阈值去噪方法及其在MATLAB中的仿真[J]. 噪声与振动控制, 2010, 30(2): 121-124.
- LI S Y. Improved wavelet threshold denoising method and its simulation using MATALB[J]. Noise and Vibration Control, 2010, 30(2): 121-124.

收稿日期: 2023-12-15。

修回日期: 2024-03-02。

作者简介:



刘展

刘展(1982), 男, 博士, 高级工程师, 主要从事风力发电行业基于工业物联网的核心关键设备服役能力保持与主动安全保障技术研究、产品开发及工业物联网大数据分析服务等相关工作, LiuZhan@bj-pukang.com;



李大字

李大字(1970), 女, 博士, 教授, 主要从事机器学习与人工智能、故障诊断、先进控制、复杂系统建模与优化等研究, 本文通信作者, lidz@mail.buct.edu.cn。

(责任编辑 辛培裕)