

DOI: 10.19783/j.cnki.pspc.250397

基于双分支-交叉注意力融合的风电齿轮箱故障诊断方法

孙抗, 李腾飞, 王浩, 杨明, 赵来军

(河南理工大学电气工程与自动化学院, 河南 焦作 454003)

摘要: 针对风电齿轮箱故障诊断数据存在时序性和单通道模型难以有效提取复合故障特征信息的问题, 提出一种基于改进正交卷积胶囊网络(orthogonal convolutional capsule network, OCCN)和双向长短期记忆神经网络(bi-directional long short-term memory, BiLSTM)融合的故障诊断方法。首先, 对原始信号进行预处理。其次, 将经过预处理操作后的信号输入构建的 OCCN-BiLSTM 双通道模型中, 分别提取复合故障特征的空间特征、时域特征。最后将提取的时空特征通过交叉注意力机制进行特征融合, 输入到全连接层中进行信号的分类, 实现风电齿轮箱智能故障诊断。试验结果表明, 所提诊断方法可有效实现风电齿轮箱智能故障诊断, 其在测试集上的准确率达到 99.53%。

关键词: 故障诊断; 胶囊网络; 并行双通道; 特征融合; 风电齿轮箱

Wind turbine gearbox fault diagnosis method based on dual-branch cross-attention fusion

SUN Kang, LI Tengfei, WANG Hao, YANG Ming, ZHAO Laijun

(School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China)

Abstract: Aiming at the problems that fault diagnosis data of wind turbine gearboxes have time series and the single-channel model is difficult to effectively extract the composite fault feature information, a fault diagnosis method integrating an improved orthogonal convolutional capsule network (OCCN) and a bidirectional long short-term memory neural network (BiLSTM) is proposed. First, the original signals are preprocessed. Then, the preprocessed signals are fed into a constructed OCCN-BiLSTM dual-branch model to extract the spatial features and time domain features of composite faults, respectively. Finally, the extracted spatiotemporal features are fused through a cross-attention mechanism and input into a fully connected layer for signal classification, enabling intelligent fault diagnosis of wind turbine gearboxes. Experimental results show that the proposed diagnosis method can effectively achieve intelligent fault diagnosis for wind turbine gearboxes, with an accuracy of 99.53% on the test set.

This work is supported by the National Natural Science Foundation of China (No. U1804143).

Key words: fault diagnosis; capsule network; parallel dual-channel architecture; feature fusion; wind turbine gearbox

0 引言

日益增长的能源需求、有限的化石燃料以及逐渐严重的环境污染, 都要求人们高度重视可再生能源的发展^[1]。近年来, 风能在全球范围内得到广泛应用^[2]。风电机组常安装在海滩、戈壁等复杂恶劣环境中^[3]。作为风力发电机组的重要部件, 齿轮箱在确保风力发电系统安全、可靠运行方面发挥着举

足轻重的作用^[4-5]。在实际工作中, 齿轮箱由于长期在苛刻的条件下运行, 其关键的齿轮部件容易发生断齿、缺齿, 齿轮磨损等故障^[6]。如不及时进行维护可能会严重影响风力发电机的安全运行, 导致系统停机、重大经济损失甚至致命后果^[7]。因此, 研究风力发电机齿轮箱故障诊断具有重要的现实意义^[8]。

目前, 深度学习算法如卷积神经网络(convolutional neural network, CNN)^[9]、递归神经网络(recurrent neural network, RNN)^[10]、深度置信网络(deep belief networks, DBN)^[11]等由于在特征提取和模式识别方面的巨大进步, 在故障诊断领域得到了

基金项目: 国家自然科学基金项目资助(U1804143); 河南省科技攻关计划项目资助(242102241056)

国内外学者的广泛关注。文献[12]通过增加新的卷积层改进 CNN 模型结构,通过较少样本的学习即可挖掘信号的深层特征,从而实现了对风电轴承的故障诊断。文献[13]将改进的 Inception 模块与 CNN 模型结合实现了框架结构损伤的识别。文献[14]通过引入随机池化和 Leaky 整流线性单元克服传统 CNN 中的训练问题,利用改进的 CNN 和迁移学习,实现了不同工况下转子轴承的故障诊断。上述方法虽然实现了较好的效果,但传统 CNN 网络的池化操作使得模型具有不变性的同时也会忽略特征的空间位置信息,造成部分特征的丢失。

文献[15]提出了一种全新的机器学习架构胶囊网络(capsule network, CapsNet),旨在克服传统 CNN 的局限性,试图弥补 CNN 在空间关系建模上的不足。该模型由多个胶囊组成,多个神经元形成一个胶囊。相比于传统 CNN 输出的标量, CapsNet 选择使用向量作为胶囊层的输出;向量的长度表示对象存在的概率,向量的方向表示对象的参数(如姿势、位置等),同时胶囊之间的距离代表特征的离散程度。通过向量输出, CapsNet 在空间特征提取方面优于传统的 CNN,进而实现更加高效可靠的故障诊断。文献[16]将时空编码模块和多尺度 CapsNet 整合在一起,用于非稳态和噪声环境下的轴承故障识别。文献[17]在 CapsNet 的基础上引入了增强型的动态路由算法,优化了胶囊层的动态结构,有效提高了模型的鲁棒性。上述 CapsNet 虽然在捕捉空间关系方面展示出了优于传统 CNN 的表现,但当多个胶囊输出非常相似时,动态路由机制无法有效地区分不同的特征和信息。文献[18]对胶囊层施加正交性,强制胶囊向量保持正交,有效地改善了传统 CapsNet 的拥挤现象,增强了网络的稳定性和泛化能力。

CapsNet 能够保留特征之间的空间和结构信息,弥补了卷积神经网络对全局信息捕捉的不足,但无法充分利用原始信号的时间相关特性。长短期记忆网络(long short-term memory, LSTM)是一种能够捕捉长序列依赖关系的循环神经网络,擅长处理时序数据的长期依赖关系^[19]。文献[20]提出了一种融合 CNN-LSTM 方法,采用融合 CNN 与 LSTM 相结合的架构,分别对时域和频域特征进行处理,实现了对电能质量干扰的实时分类。文献[21]设计一种基于改进 1DCNN-双向长短期记忆神经网络(bi-directional long short-term memory, BiLSTM)融合的故障诊断方法,采用双通道模型充分提取原始故障振动信号的时空特征,实现了强噪声下的轴承故障诊断。文献[22]开发了 CNN-BiLSTM 网络,利用滑

动窗口对从样本中提取的特征信息和时延信息进行了整合,输入到 CNN-BiLSTM 模型中,有效解决了复杂工况下模型训练和故障诊断的挑战。

在实际问题中,数据往往同时包含局部空间特征和全局时序信息,基于传统 CNN 的诊断模型虽然能够有效提取局部空间特征,但在捕捉特征间的空间关系上存在不足,而 BiLSTM 神经网络虽然能够更全面地捕捉上下文关系,但缺乏对局部空间结构的敏感性^[23]。针对单一模型在复杂任务中难以同时兼顾时序和空间信息的问题,本文提出一种基于改进正交卷积胶囊网络(orthogonal convolutional capsule network, OCCN)-BiLSTM 双通道模型融合的故障诊断方法。该方法通过 OCCN 与 BiLSTM 网络分别提取经过预处理后的振动信号中的空间特征和时域特征,通过引入的交叉注意力机制将提取的时频域特征进行特征融合,最后输入到全连接层中实现复合故障分类。

本文的主要工作如下:

- 1) 提出改进的 OCCN 模型,使用 OCCN 对输入数据的空间特征进行提取。首先输入数据通过卷积层提取局部特征,然后通过 CapsNet 保留特征之间的空间关系,引入正交性约束改善动态路由,避免网络中的“拥挤现象”。
- 2) 使用 BiLSTM 网络从输入数据中提取时序特征,分别从前向和后向两端处理序列数据,从而捕捉到完整的上下文信息。
- 3) 引入交叉注意力机制,将双通道模型提取的数据进行特征融合。通过计算注意力权重使模型关注更加重要的特征,提高模型的泛化能力。

1 相关理论

1.1 快速傅里叶变换

快速傅里叶变换(fast Fourier transform, FFT)是一种高效计算离散傅里叶变换(discrete Fourier transform, DFT)及其逆变换的算法,其核心目标是将时域信号转换为频域表示,通过频谱分析揭示信号中隐含的频率成分及其信息分布特性。

设长度为 N 的时序信号序列为 $\mathbf{x}(n)$,其离散傅里叶变换定义为

$$X(k) = \sum_{n=0}^{N-1} \mathbf{x}(n) W_N^{nk} \quad (1)$$

$$W_N^{nk} = e^{-j\frac{2\pi}{N}nk} \quad (2)$$

式中: $X(k)$ 表示频域中第 k 个频率分量的复数幅值; W_N^{nk} 为旋转因子。

传统 DFT 算法的计算复杂度与 N^2 成正比,当

处理长序列信号时,为了降低计算量,FFT通过分治策略将长序列 $\mathbf{x}(n)$ 分解为两个长度为 $N/2$ 的序列,将复杂度从 $O(N^2)$ 降至 $O(N \log N)$,如式(3)所示。

$$X(k) = \text{DFT}[\mathbf{x}(2n)] + \text{DFT}[\mathbf{x}(2n+1)] = \sum_{n=0}^{N/2-1} \mathbf{x}_1(n) W_{N/2}^{2nk} + W_N^k \sum_{n=0}^{N/2-1} \mathbf{x}_2(n) W_{N/2}^{(2n+1)k} \quad (3)$$

将输入序列按奇偶分组,该方法为按时间抽取的FFT算法。在齿轮箱故障诊断中,振动信号通常呈现非平稳性和时序性,通过FFT能够将原始的一维时域振动信号映射到频域,从而提取与故障相关的关键频率特征。

1.2 一维卷积

一维卷积主要用来处理带有时间序列性质的数据,齿轮箱故障数据是一维振动信号,因此主要使用一维卷积提取输入数据的初级特征。卷积层的作用是将输入信号的局部感受野与卷积核进行卷积。每个卷积核沿着输入数据的单一维度滑动,通过多个卷积核学习到数据的不同特征。卷积的计算公式为

$$\mathbf{y}_i^{l+1}(j) = \mathbf{K}_i^l \times \mathbf{x}^l(j) + \mathbf{b}_i^l \quad (4)$$

式中: \mathbf{y}_i^{l+1} 表示第 l 层的第 i 个卷积核的输出; \mathbf{K}_i^l 表示第 l 层的第 i 个卷积核的权重矩阵; \mathbf{x}^l 表示第 l 层的输入信号; \mathbf{b}_i^l 为偏置向量。

在神经网络中,通过引入激活函数可以使网络获得非线性表示的能力。为了加速模型的收敛,增强模型的特征表示,本文选择整流线性单元(ReLu)函数作为卷积层的激活函数,其计算公式为

$$f(x) = \max(0, x) \quad (5)$$

1.3 OCCN

CapsNet的核心思想是将向量(而非传统神经网络中使用的标量)作为网络的输入和输出,用来减少特征信息的损失,提高模型的特征提取能力。胶囊的长度表示齿轮箱发生特定故障的概率,方向则表示该特征的空间位置信息。CapsNet主要由初始胶囊层和数字胶囊层组成,具体结构如图1所示。

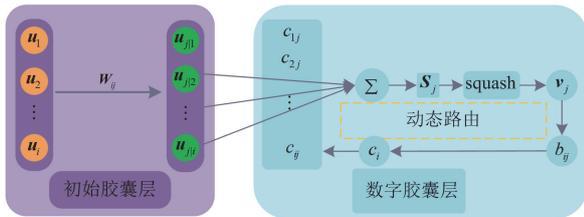


图1 CapsNet 结构图

Fig. 1 Structure of CapsNet

CapsNet的运行流程主要由以下3部分组成。

第1部分通过将初始胶囊 \mathbf{u}_i 与权重矩阵 \mathbf{W}_{ij} 相乘,得到预测胶囊 \mathbf{u}_{ji} 。其计算公式为

$$\mathbf{u}_{ji} = \mathbf{W}_{ij} \mathbf{u}_i \quad (6)$$

第2部分对预测胶囊 \mathbf{u}_{ji} 进行加权求和,得到数字胶囊 \mathbf{S}_j ,并通过耦合系数 c_{ij} 来调整预测胶囊的重要性。其计算公式为

$$\mathbf{S}_j = \sum_i c_{ij} \mathbf{u}_{ji} \quad (7)$$

式中: c_{ij} 是低层胶囊 i 与高层胶囊 j 之间的耦合系数,表示低层胶囊输出对高层胶囊激活的贡献,通过中间变量 b_{ij} 计算得到,如式(8)所示。

$$c_{ij} = \text{soft max}(b_{ij}) = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})} \quad (8)$$

使用softmax函数确保每个 c_{ij} 非负并且求和为1。其中,所有的 b_{ij} 初始值均为0。通过动态路由由算法不断更新调整 c_{ij} 和 b_{ij} 来优化数字胶囊。不断调整初始胶囊层和数字胶囊层的参数,以提高模型的故障诊断性能。

第3部分,数字胶囊会经过squash激活函数进行非线性压缩,得到高层胶囊 j 最终的输出向量 \mathbf{v}_j 。squash函数会确保向量的方向不变,同时将向量的长度压缩到0~1之间。其计算公式为

$$\mathbf{v}_j = \frac{\|\mathbf{S}_j\|^2 \mathbf{S}_j}{1 + \|\mathbf{S}_j\|^2 \|\mathbf{S}_j\|} \quad (9)$$

式中: $\|\mathbf{S}_j\|$ 为数字胶囊 \mathbf{S}_j 的模长; \mathbf{v}_j 为高层胶囊 j 的输出向量,表示该故障类别的预测结果。

动态路由的迭代方法如表1所示,定义迭代次数为 r ,当前输入胶囊为 l 层。

表1 动态路由算法

Table 1 Dynamic routing algorithm

步骤	操作
1	循环(\mathbf{u}_{ji}, r, l)
2	所有 l 层胶囊 i 和 $l+1$ 层胶囊 j : $b_{ij} \leftarrow 0$
3	For r iterations do
4	l 层胶囊 i : $c_{ij} \leftarrow \text{softmax}(b_{ij})$
5	$l+1$ 层胶囊 j : $\mathbf{S}_j \leftarrow \sum_i c_{ij} \mathbf{u}_{ji}$
6	$l+1$ 层胶囊 j : $\mathbf{v}_j \leftarrow \text{squash}(\mathbf{S}_j)$
7	所有 l 层胶囊 i 和 $l+1$ 层胶囊 j : $b_{ij} \leftarrow b_{ij} + \mathbf{u}_{ji} \cdot \mathbf{v}_j$
8	return \mathbf{v}_j

传统的CapsNet通过动态路由算法调整不同层之间的连接权重,使得信息能够有效地传递到正确

的高层胶囊。然而，当多个低层胶囊对同一个高层胶囊有相似的贡献时，传统的动态路由机制使高层胶囊难以有效地区分不同的特征，被称为“拥挤现象”。正交性约束的引入，可以很好地改善 CapsNet 的拥挤现象。通过施加正交性约束，可以使不同胶囊之间的输出向量尽可能地保持正交，确保胶囊之间的特征表示互不干扰，从而避免低层胶囊与高层胶囊之间的冗余信息干扰。

设胶囊 j 和 k 的输出向量分别为 \mathbf{v}_j 、 \mathbf{v}_k ，定义正交性损失函数 L_{orth} 为

$$L_{\text{orth}} = \sum_{j=1} \sum_{k \neq j} \left(\frac{\mathbf{v}_j^T \mathbf{v}_k}{\|\mathbf{v}_j\| \|\mathbf{v}_k\|} \right)^2 \quad (10)$$

该约束项通过最小化不同高层胶囊的输出向量内积，强制不同特征通道在参数空间保持近似正交关系，从而抑制冗余特征的传播。

在正交动态路由中，耦合系数的更新融合了动态路由机制与正交性约束的双重优化目标，除了通过动态路由的迭代进行，还需要根据正交性损失来调整，以确保不同胶囊之间的特征保持独立。耦合系数 c_{ij} 的更新计算公式为

$$c_{ij}^{(t+1)} = c_{ij}^{(t)} + \alpha \cdot \frac{\partial L_{\text{routing}}}{\partial c_{ij}} + \beta \cdot \frac{\partial L_{\text{orth}}}{\partial c_{ij}} \quad (11)$$

式中： α 是路由协议学习率； L_{routing} 是路由损失函数； β 是设置的正交约束学习率。这种分层优化策略既保留了动态路由对特征空间关系的建模能力，又通过正交约束抑制特征混淆，提高了模型的泛化性。

相比于传统的 CapsNet，OCCN 通过引入正交约束，不仅能够更好地保留特征之间的空间关系，还能够有效减少特征之间的冗余，增强特征表示的独立性，从而提升模型的鲁棒性和泛化能力。

1.4 BiLSTM

LSTM 神经网络与传统的循环神经网络相比，在捕捉信号之间的长期依赖关系方面具有独特的优势。然而，LSTM 只有一个单向传播过程，只能获取序列数据的前一信息，无法捕捉后一上下文的信息。BiLSTM 结合了正向和反向两个 LSTM，能够同时捕捉序列中每个元素的上下信息，加强对原始序列的特征提取，从而提高了模型输出的准确性。

BiLSTM 结构如图 2 所示，在前向层进行正向计算，并保存每个时刻前向隐藏层的输出。同时，在后向层进行反向计算，并保存每个时刻后向隐藏层的输出，最后将前向层和后向层的输出合并，得到最终的输出。其计算公式为

$$\vec{h}_t = f(\mathbf{w}_1 x_t + \mathbf{w}_2 \vec{h}_{t-1}) \quad (12)$$

$$\overleftarrow{h}_t = f(\mathbf{w}_3 x_t + \mathbf{w}_4 \overleftarrow{h}_{t+1}) \quad (13)$$

$$\mathbf{y}_t = g(\mathbf{w}_5 \vec{h}_t + \mathbf{w}_6 \overleftarrow{h}_t) \quad (14)$$

式中： x_t 是输入序列该时刻的值； \vec{h}_t 和 \overleftarrow{h}_t 分别是前向和后向 LSTM 的输出； \mathbf{y}_t 是隐藏层的最终输出； $\mathbf{w}_i (i=1,2,\dots,6)$ 为 BiLSTM 正反向计算层的权重值； $f(\cdot)$ 和 $g(\cdot)$ 是相应的激活函数。

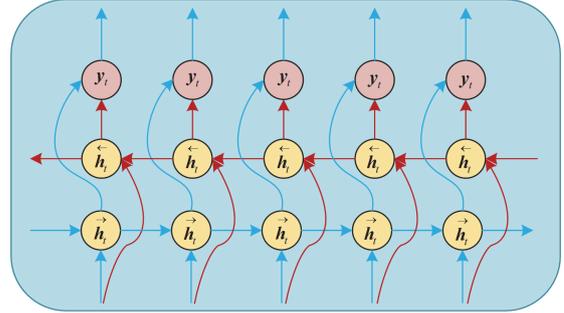


图 2 BiLSTM 结构

Fig. 2 Structure of BiLSTM

1.5 交叉注意力机制

在处理具有复杂时空结构的数据时，仅使用时序特征或空间特征往往无法充分捕捉到数据中的信息，因此，特征融合成为一个至关重要的步骤。交叉注意力机制是自我注意力的一种特殊形式，它将输入张量分为两部分，设空间特征输入为 $\mathbf{X}_s \in \mathbf{R}^{d_n \times d_n}$ ，时序特征输入为 $\mathbf{X}_t \in \mathbf{R}^{d_n \times d_m}$ ， \mathbf{R} 为实数矩阵， d_n 为输入元素数量， d_m 为原始特征维度。其中空间特征输入作为查询集 \mathbf{Q} ，决定输出序列的长度，时序特征输入作为键 \mathbf{K} 与值 \mathbf{V} 。

通过独立的线性投影矩阵，将输入映射至统一的子空间。

$$\mathbf{Q} = \mathbf{X}_s \mathbf{W}_Q \quad (15)$$

$$\mathbf{K} = \mathbf{X}_t \mathbf{W}_K \quad (16)$$

$$\mathbf{V} = \mathbf{X}_t \mathbf{W}_V \quad (17)$$

式中： \mathbf{W}_Q 、 \mathbf{W}_K 、 \mathbf{W}_V 分别为 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 的权重矩阵。

通过缩放点积注意力实现时空特征交互，其计算为

$$\text{CrossAttention}(\mathbf{X}_s, \mathbf{X}_t) = \text{softmax} \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}} \right) \mathbf{V} \quad (18)$$

式中： $\mathbf{Q}\mathbf{K}^T$ 表示空间特征和时序特征在不同位置的相似程度，通过 softmax 函数归一化生成注意力权重。基于注意力权重，与 \mathbf{V} 相乘进行加权求和，生成融合后的时空特征。

多模态学习和注意力机制是当前深度学习研究的热点之一, 交叉注意融合作为多模态融合的重要组成部分, 通过注意力机制在不同模块之间建立联系, 促进特征的交换和融合, 增强了模型处理复杂任务的能力。

2 基于改进 OCCN-BiLSTM 双通道模型融合的故障诊断方法

2.1 网络模型架构

本文构建的OCCN-BiLSTM双通道网络架构如图3所示, 主要包括输入层、OCCN 模块、BiLSTM

模块、交叉注意力模块和分类层。首先, 将采集到的原始信号通过 FFT 转化为频域信号; 其次, 将得到的频域信号与原始时序信号同时输入到并行双通道模型中, 分别利用 OCCN 模块和 BiLSTM 模块对输入的信号提取空间特征和时间特征, 通过交叉注意力机制将提取的空间特征和时间特征进行特征融合, 通过计算注意力权重使模型关注更加重要的特征; 最后全连接层(fully connected layer, FC)负责将输入的融合特征映射到类别维度, 随后归一化指数函数(softmax, SM)层进行故障分类, 得到最终输出结果。

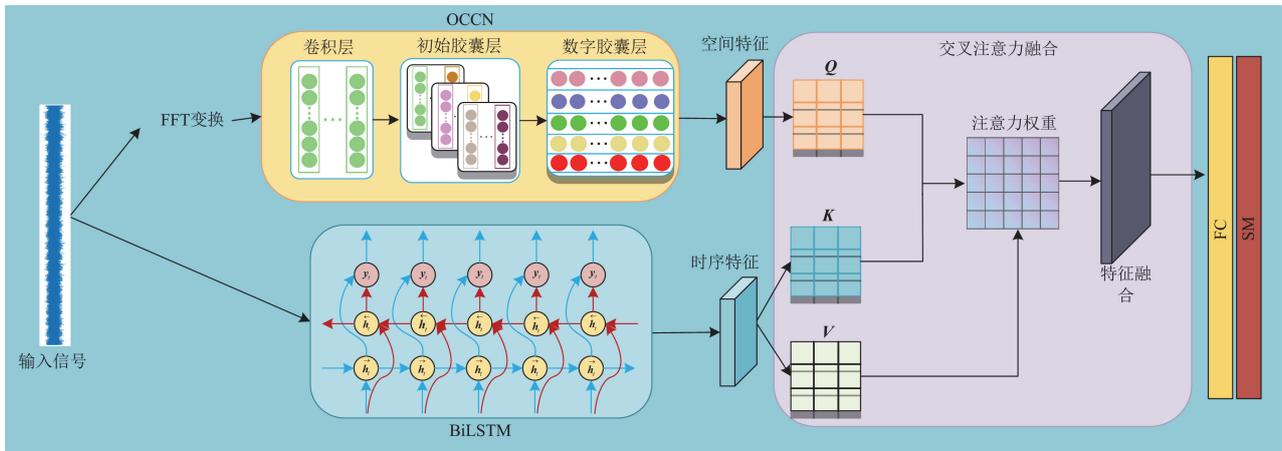


图3 OCCN-BiLSTM 双通道网络架构

Fig. 3 OCCN-BiLSTM dual-channel network architecture

模型的参数设置如表2所示, 为了充分提取特征信息, 卷积核的大小采用从大到小的设计。使用 Relu 函数作为卷积层的激活函数, squash 函数作为胶囊层的激活函数。正交动态路由的迭代次数 r 设置为3次。

表2 模型参数设置

Table 2 Model parameter settings

	核大小	步长	核个数
Conv1	20×1	4	16
Conv2	10×1	4	32
Conv3	5×1	2	16
Conv4	5×1	2	32
初始胶囊层	4	2	20
数字胶囊层	—	—	—

2.2 故障诊断流程

本文提出的基于改进OCCN-BiLSTM双通道模型融合的故障诊断流程如图4所示, 具体诊断步骤如下。

1) 将采集到的原始信号进行预处理, 以7:2:1的比例随机划分为训练集、验证集和测试集;

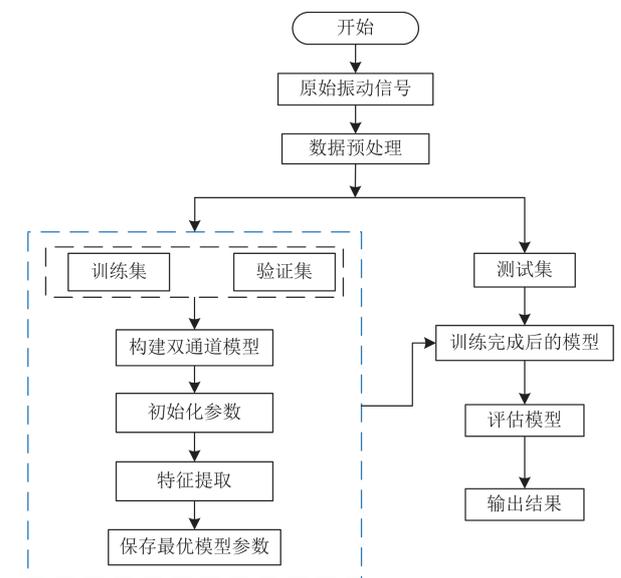


图4 OCCN-BiLSTM 的故障诊断过程

Fig. 4 Fault diagnosis process of OCCN-BiLSTM

2) 构建 OCCN-BiLSTM 双通道模型并初始化参数;

3) 使用训练集进行模型的训练, 通过验证集选择出最优模型, 并保存最优模型参数;

4) 使用测试集进行模型评估, 得出诊断结果。

3 实验与结果分析

3.1 实验数据及数据预处理

为验证本文所提方法的有效性和优越性, 实验采用风力发电机传动系试验台的行星齿轮箱数据集作为实验数据。该试验台由电机、行星齿轮箱、定轴齿轮箱和负载装置等组成, 如图 5 所示。

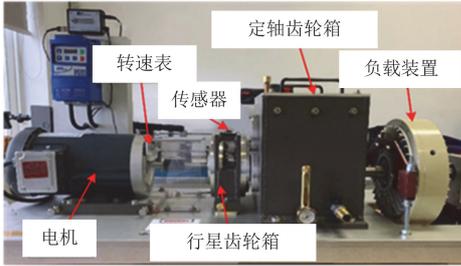


图 5 动力传动试验台

Fig. 5 Power transmission test bench

实验模拟了太阳齿轮的 5 种健康状态: 正常、断齿、齿轮磨损、齿根裂纹和缺齿, 如图 6 所示。振动数据由 Sinocera CA-YD-1181 加速度计收集, 速度脉冲由编码器收集, 所有通道均以 48 kHz 的频率进行采样。在实际应用中, 需要考虑变工况情况, 因此, 在不同的转速条件下, 共模拟了以下 4 种不同的运行条件(转速和负载)。

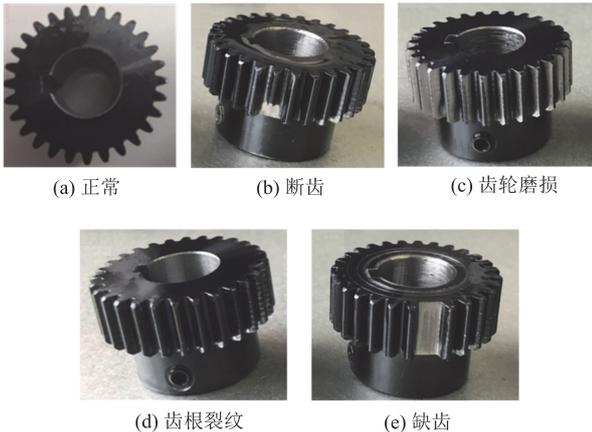


图 6 不同故障类型的齿轮

Fig. 6 Gears with different fault types

A: 20 Hz 和 0 kN; B: 25 Hz 和 200 kN; C: 30 Hz 和 200 kN; D: 35 Hz 和 200 kN, 其中, B、C 和 D 都是在安装负载为 200 kN 不同转速情况下采集。本实验中设置采样窗口长度为 2048, 每个健康状态采

样得到 1000 个样本。样本分布如表 3 所示。

表 3 数据集描述

Table 3 Dataset description

类别	健康状态	样本长度	样本量
1	正常	2048	1000
2	断齿	2048	1000
3	齿轮磨损	2048	1000
4	齿根裂纹	2048	1000
5	缺齿	2048	1000

3.2 泛化实验

为了验证 OCCN-BiLSTM 双通道模型的泛化能力, 选择条件 A 的 5 种健康状态作为训练集和验证集, 而分别采用条件 B、C 和 D 的 5 种健康状态用作测试集, 用来验证模型在不同负载工况条件下的泛化能力。

本实验中, 将采样得到的样本进行分层抽样, 以 7:2:1 的比例随机划分为训练集、验证集和测试集。随后采用 FFT 将原始时序信号转化为频域信号, 得到的频域图如图 7 所示。

实验的运行环境均为 PyCharm, 深度学习框架均为 PyTorch, 处理器为 Intel(R) Core(TM) i7-13700H, GPU 为 GTX4060, 批大小设置为 64, 训练轮次设置为 50, 学习率设置为 0.001, 使用 ADAM 优化器, 3 组实验结果的混淆矩阵如图 8 所示, 图 8(a)、图 8(b)和图 8(c)分别为条件 B、C 和 D 下的测试集混淆矩阵。横轴表示预测的健康状态类别, 纵轴表示实际的健康状态类别。对角红色区域表示预测准确性, 其余浅紫色区域表示错误分类率。从图中可以看出, 所提 OCCN-BiLSTM 双通道模型可以对不同负载工况条件下的振动信号进行准确分类, 证明了所提模型具有较强的泛化能力和鲁棒性。

为了进一步说明本文方法的有效性, 使用 t 分布式随机邻域嵌入(t-SNE)算法, 将 OCCN-BiLSTM 双通道模型的 softmax 层输出的特征图映射到二维空间, 以进行特征可视化, 如图 9 所示。从图中可以看出, OCCN-BiLSTM 模型在 3 种不同的负载工况下对于 5 种齿轮箱的故障类型实现了准确的分类, t-SNE 图中形成了 5 个明显的聚类, 证明了本文所提方法在风电齿轮箱故障诊断中的有效性。

在实际应用中, 风电齿轮箱常工作在复杂环境下, 提取的故障数据往往充斥着噪声, 为了验证所提方法在噪声环境下的适应性, 将不同信噪比的高斯白噪声叠加到原始信号测试集中, 为每种故障类型添加独立随机的噪声序列, 分别进行 3 组实验, 实验结果如表 4 所示。其中信噪比 S_{SNR} 如式(19)所示。

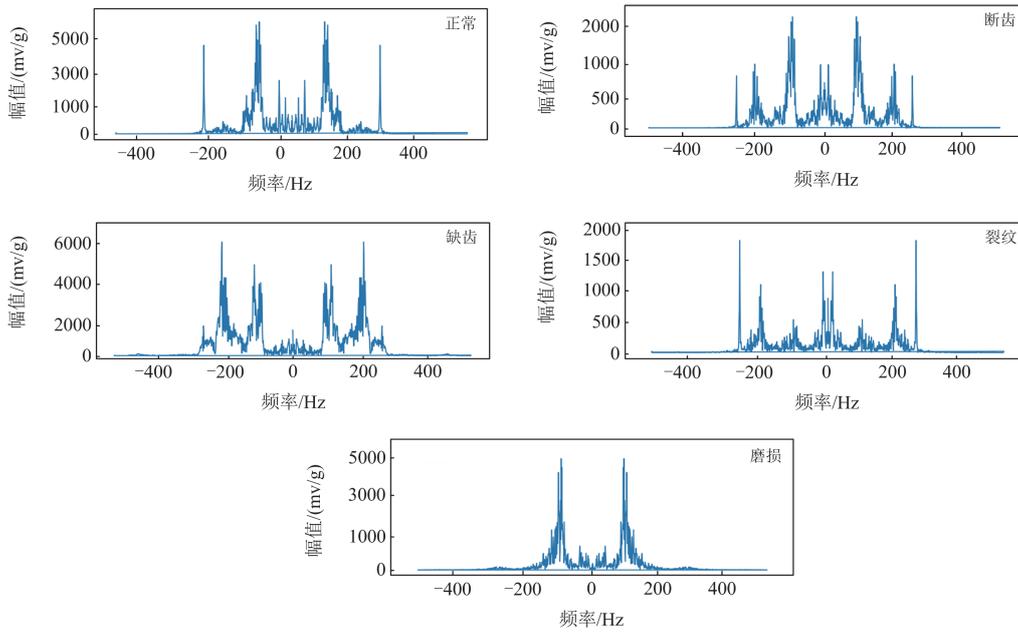


图 7 FFT 输出结果

Fig. 7 FFT output results

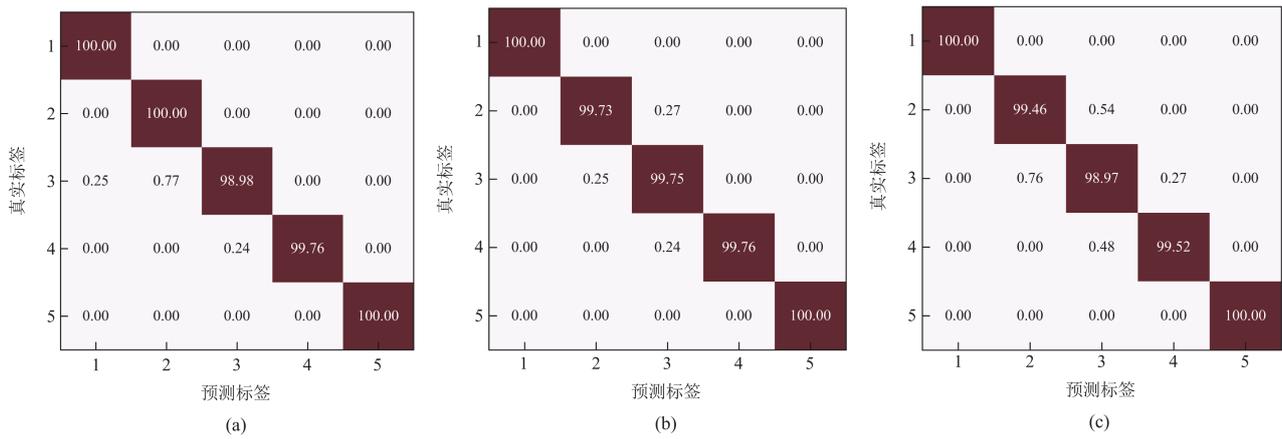


图 8 泛化实验的混淆矩阵

Fig. 8 Confusion matrix of generalization experiment

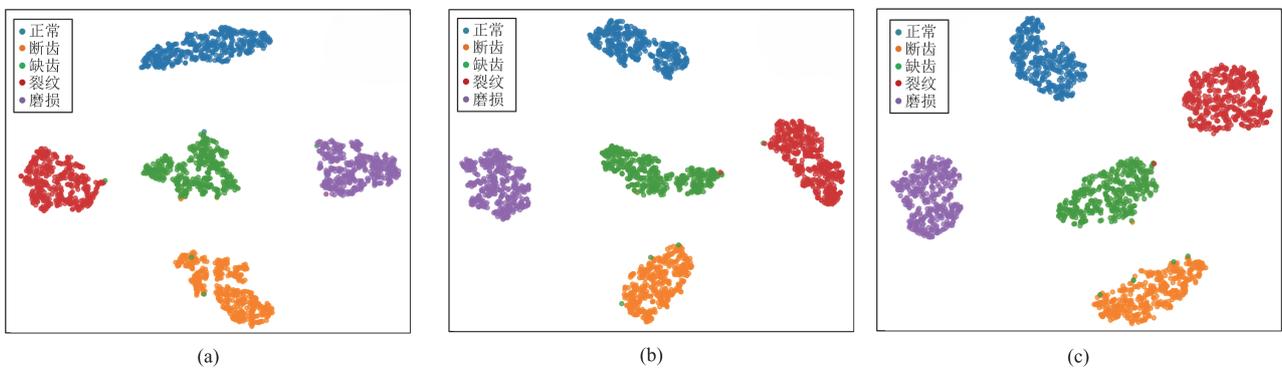


图 9 不同负载下测试集 t-SNE 降维图

Fig. 9 Test set t-SNE dimensionality reduction diagram under different loads

$$S_{\text{SNR}} = 10 \lg \left(\frac{P_s}{P_n} \right) \quad (19)$$

式中： P_s 为信号功率； P_n 为噪声功率。

表 4 不同信噪比下准确率对比

信噪比/dB	准确率/%		
	第 1 组	第 2 组	第 3 组
20	99.49	99.61	99.53
10	98.36	98.23	98.64
0	96.51	97.47	96.63

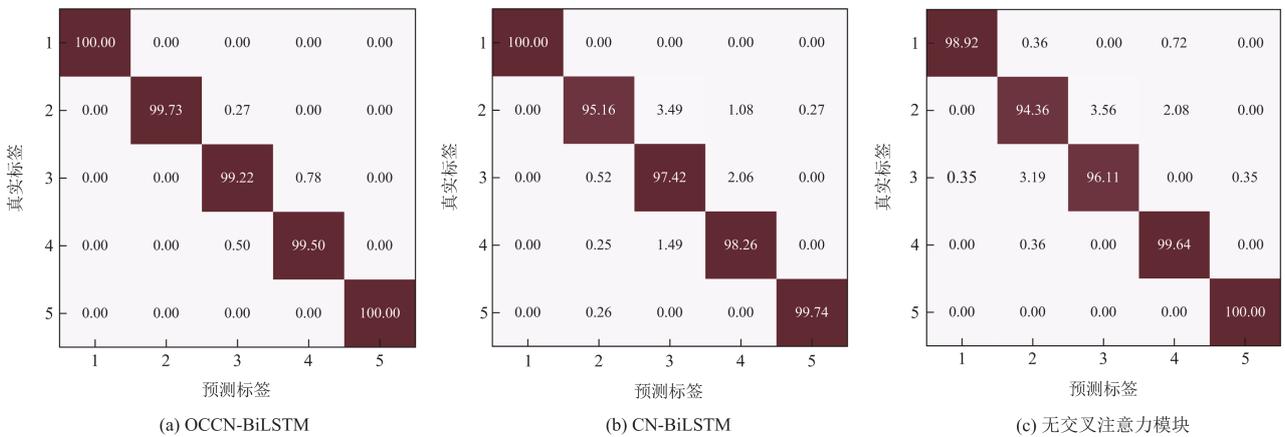


图 10 消融实验结果混淆矩阵

Fig. 10 Confusion matrix of ablation experimental results

图 10(a)为 OCCN-BiLSTM 模型测试集混淆矩阵，图10(b)为 CN-BiLSTM 模型测试集混淆矩阵，图 10(c)为没有采用交叉注意力模块模型测试集混淆矩阵。可以看出，OCCN-BiLSTM 双通道模型在所有类别的精度均优于两种模型，测试集的准确率分别为 99.69%、98.12%和 97.81%。交叉注意力机制通过动态分配权重，使模型更加关注最重要的时空信息，提高模型的分类效果，证明了本文方法的可行性。

动态路由中迭代次数的选择对模型的性能有着显著影响，迭代次数过少会导致模型可能无法有效捕捉到特征间的整体空间关系，迭代次数过多会使网络计算更加复杂，同时可能导致模型过拟合训练数据集。为了选择更合适的迭代次数，本文进行了不同迭代次数 r 下 ($r=1$ 、 $r=3$ 和 $r=5$) 的对比实验，训练次数设置为 35 次。图 11 显示了不同迭代次数下训练集的准确率曲线。

从图中可以看出，迭代次数 $r=1$ 与 $r=3$ 时，二者的收敛速度近乎相近，但 $r=1$ 的准确率有所下

降。当迭代次数为 5 次时，模型的收敛速度较慢，但精度提升并不大，因此本文设置迭代次数为 3。

3.3 消融实验

为了验证 OCCN-BiLSTM 双通道模型的有效性，将其与没有采用正交约束的 CN-BiLSTM 和删除交叉注意力机制模块的模型进行消融实验。本实验选择采用 20 Hz、0 kN 的转速和负载条件下的数据作为模型的训练集与测试集，其余参数设置与泛化能力测试实验一致。实验结果混淆矩阵如图 10 所示。

降。当迭代次数为 5 次时，模型的收敛速度较慢，但精度提升并不大，因此本文设置迭代次数为 3。

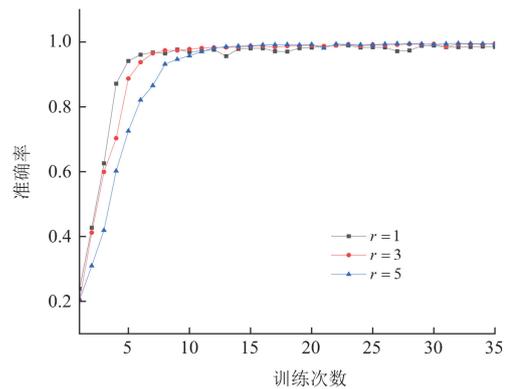


图 11 不同迭代次数下准确率曲线

Fig. 11 Accuracy curves at different iterations

3.4 对比实验

为了验证 OCCN-BiLSTM 模型相对于浅层机器学习模型和传统单通道模型的优越性，将其与随机森林 (random forest, RF)^[24]、支持向量机 (support

vector machines, SVM)^[25]、1D-CNN^[26]、CapsNet 和 CNN-LSTM 等模型进行对比实验。本实验仍旧选择采用 20 Hz 和 0 kN 的转速和负载条件下的数据作为模型的训练集与测试集, 用训练集对 6 种网络进行充分训练, 用测试集对网络的效果进行评估。每种诊断模型进行 3 次实验, 实验结果如表 5 所示, 对比结果如图 12 所示。

表 5 不同模型的诊断精度

Table 5 Diagnostic accuracy of different models

模型	准确率/%			
	第 1 次	第 2 次	第 3 次	平均值
RF	94.13	93.77	95.12	94.34
SVM	85.39	82.46	84.90	84.25
1D-CNN	96.43	96.82	95.75	96.34
CapsNet	96.41	97.62	97.24	97.09
CNN-LSTM	97.37	97.62	96.84	97.28
OCCN-BiLSTM	99.69	99.58	99.32	99.53

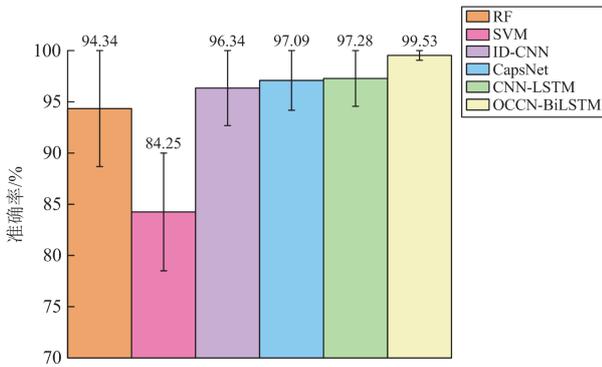


图 12 各个模型的诊断结果对比

Fig. 12 Comparison of diagnostic results of various models

由结果可知, RF、SVM 等浅层机器学习模型无法取得良好的诊断精度, 这是由于 SVM 等方法使用人工手动选择和提取特征作为信息, 泛化能力有限, 鲁棒性较差。1D-CNN、CapsNet 等单通道模型虽然取得了良好的诊断精度, 但在多尺度特征提取方面存在局限性, 难以应对噪声的干扰。相比于 CNN-LSTM 模型, 本文提出的 OCCN-BiLSTM 模型取得了更高的准确率, 这表明 OCCN-BiLSTM 模型可以有效提取齿轮箱的复合故障特征, 准确实现端到端的故障诊断, 验证了本文所提方法的优越性。

表 6 对比了 1D-CNN、CapsNet 等单通道模型与 OCCN-BiLSTM 模型在训练时间、参数数量、FLOPs 和显存占用方面的表现, 训练轮次设置为 100。可以看到 OCCN-BiLSTM 模型在多项性能上展现出综合优势。

表 6 不同网络性能对比

Table 6 Performance comparison of different networks

模型	训练时间/s	参数数量/M	FLOPs/M	显存占用/MB
1D-CNN	309	1.51	314.21	139.58
CapsNet	724	0.75	634.36	250.28
OCCN-BiLSTM	667	0.95	583.74	300.35

由表 6 可知, 由于双通道模型的并行计算特性, 在显著提升精度的同时, 本文所提 OCCN-BiLSTM 模型的训练时间并未增加太多。通过多尺度特征融合机制, 有效平衡了模型参数数量与计算复杂度, 从而在多项性能上展现出综合优势, 证明了本文所提方法的可行性。

为了验证 OCCN-BiLSTM 模型的独特性, 本文采用 FFT-2DCNN、CNN-LSTM 和高效通道注意力胶囊网络(efficient channel attention capsule network, ECA-CN)这 3 种诊断模型进行结构对比, 如表 7 所示。

表 7 结构对比表

Table 7 Structural comparison table

模型	模型架构	特征处理机制	准确率/%
FFT-2DCNN	FFT 预处理 +	频域图像化	95.62
	2DCNN	特征学习	
CNN-LSTM	融合 CNN-LSTM	频域特征与时域特征	97.28
ECA-CN	ECA 机制 +	不同通道特征	98.74
	CapsNet	权重分配	
OCCN-BiLSTM	OCCN + BiLSTM	时空特征融合	99.53

由表 7 可知, FFT-2DCNN 通过 FFT 图像化处理故障信号, 输入到 2DCNN 进行特征学习, 但忽略了原始信号时序特性; CNN-LSTM 分别提取空间和时域特征, 但池化操作会造成部分特征的丢失; ECA-CN 通过 ECA 注意力机制为不同特征赋予权重, 使模型更关注重要特征, 但在振动数据的时域特征方面仍然存在不足; 而本文提出的 OCCN-BiLSTM 模型创新性地融合了 OCCN 与 BiLSTM, 通过 CapsNet 提取信号的空间特征, 并在动态路由中添加正交约束, 解决了传统 CapsNet 特征混淆的问题, 使用 BiLSTM 网络从输入数据中提取时序特征, 分别从前向和后向两端处理序列数据, 使模型更加关注全局上下文信息。

4 结论

相较于传统单通道模型难以有效提取复合故障特征信息的局限性, 本文提出一种基于改进 OCCN-BiLSTM 双通道模型的齿轮箱智能故障诊断方法。实验采用风力发电机传动系试验台的行星齿轮箱

数据集验证了该方法的有效性和优越性，主要结论如下。

1) 风电齿轮箱运行结构复杂，采用的 OCCN-BiLSTM 双通道模型可以有效提取齿轮箱的复合故障特征。

2) 通过在动态路由中引入正交约束，有效改善了 CapsNet 的拥挤现象，解决了特征混淆问题。

3) 使用交叉注意力进行特征融合，通过计算注意力权重使模型关注更加重要的特征，提高了模型的泛化能力。

4) 实验结果表明，在不同的负载工况条件下，本文所提方法均显示出更具竞争力的故障诊断性能，具有较强的泛化能力。

5) 双通道模型因其结构特点通常伴随着较为复杂的计算，后续将采用深度卷积、分层卷积，胶囊剪枝和注意力路由等方法进一步探讨模型轻量化的可行方案。

参考文献

- [1] 郭雪丽, 胡志勇, 王爽, 等. 考虑大规模风光分层接入的配电网多层协调无功优化方法[J]. 电力系统保护与控制, 2024, 52(12): 113-122.
GUO Xueli, HU Zhiyong, WANG Shuang, et al. A multi-layer coordinated reactive power optimization method for a distribution network considering large-scale distributed wind-photovoltaic hierarchical access[J]. Power System Protection and Control, 2024, 52(12): 113-122.
- [2] 何方, 张琦立, 魏书荣, 等. 考虑并网灵活性的大规模海上风电场集群接入系统规划研究[J]. 智慧电力, 2024, 52(9): 33-40.
HE Fang, ZHANG Qili, WEI Shurong, et al. Planning of large-scale offshore wind farm cluster access system considering grid-connected flexibility[J]. Smart Power, 2024, 52(9): 33-40.
- [3] DING X, XU J, WANG J, et al. Fault diagnosis of wind turbine generator bearings using fast spectral correlation[J]. Wind Engineering, 2022, 46(3): 724-736.
- [4] 和林芳, 王道涵, 田淼, 等. 基于 IBCAN 的风力发电机轴承故障诊断方法研究[J]. 太阳能学报, 2025, 46(1): 97-104.
HE Linfang, WANG Daohan, TIAN Miao, et al. Research on fault diagnosis method of wind turbine bearing based on IBCAN[J]. Acta Energetica Solaris Sinica, 2025, 46(1): 97-104.
- [5] 刘展, 刘健洵, 包琰洋, 等. 基于图正则化堆叠自编码器的风机轴承故障诊断方法[J]. 发电技术, 2024, 45(6): 1146-1152.
LIU Zhan, LIU Jianxun, BAO Yanyang, et al. Bearing faults diagnosis method based on stacked auto-encoder with graph regularization for wind turbines[J]. Power Generation Technology, 2024, 45(6): 1146-1152.
- [6] 刘军, 安柏任, 张维博, 等. 大型风力发电机组健康状态评价综述[J]. 电力系统保护与控制, 2023, 51(1): 176-187.
LIU Jun, AN Bairen, ZHANG Weibo, et al. Review of health status evaluation of large wind turbines[J]. Power System Protection and Control, 2023, 51(1): 176-187.
- [7] 吴忠强, 侯林成. 基于 Hamilton 多智能体系统的风力发电机组协同控制[J]. 电机与控制学报, 2023, 27(10): 193-202.
WU Zhongqiang, HOU Lincheng. Cooperation control of wind turbines based on Hamilton multi-agent system[J]. Electric Machines and Control, 2023, 27(10): 193-202.
- [8] 赵洪山, 林诗雨, 孙承妍, 等. 考虑多时间尺度信息的风力发电机滚动轴承故障预测[J]. 中国电机工程学报, 2024, 44(22): 8908-8920.
ZHAO Hongshan, LIN Shiyu, SUN Chengyan, et al. Fault prediction of wind turbine rolling bearing considering multi-time scale information[J]. Proceedings of the CSEE, 2024, 44(22): 8908-8920.
- [9] 李俊卿, 苑浩, 黄涛, 等. 基于 PSA 引导双分支神经网络特征融合的同步电机故障诊断[J]. 智慧电力, 2024, 52(12): 51-58.
LI Junqing, YUAN Hao, HUANG Tao, et al. Fault diagnosis of synchronous motor based on PSA guided double branch neural network feature fusion[J]. Smart Power, 2024, 52(12): 51-58.
- [10] 陈媛, 段文献, 何怡刚, 等. 带降噪自编码器和门控递归混合神经网络的电池健康状态估算[J]. 电工技术学报, 2024, 39(24): 7933-7949.
CHEN Yuan, DUAN Wenxian, HE Yigang, et al. State of health estimation of lithium ion battery based on denoising autoencoder-gated recurrent unit[J]. Transactions of China Electrotechnical Society, 2024, 39(24): 7933-7949.
- [11] YANG J, BAO W, LIU Y, et al. Class metric regularized deep belief network with sparse representation for fault diagnosis[J]. International Journal of Intelligent Systems, 2022, 37(9): 5996-6022.
- [12] 常淼, 沈艳霞. 基于改进卷积神经网络的风电轴承故障诊断策略[J]. 电力系统保护与控制, 2021, 49(6): 131-137.
CHANG Miao, SHEN Yanxia. Fault diagnosis strategy of a wind power bearing based on an improved convolutional neural network[J]. Power System Protection and Control, 2021, 49(6): 131-137.

- [13] 刘景良, 吕毓霖, 郑文婷, 等. 基于双重注意力机制-改进 Inception 模块的 CNN 模型识别框架结构损伤[J]. 振动与冲击, 2024, 43(23): 321-328, 336.
LIU Jingliang, LÜ Yulin, ZHENG Wenting, et al. Damage identification of frame structure based on CNN model with dual-attention mechanism and improved Inception module[J]. Journal of Vibration and Shock, 2024, 43(23): 321-328, 336.
- [14] SHAO H, XIA M, HAN G, et al. Intelligent fault diagnosis of rotor-bearing system under varying working conditions with modified transfer convolutional neural network and thermal images[J]. IEEE Transactions on Industrial Informatics, 2020, 17(5): 3488-3496.
- [15] AHMED S F, ALAM M S B, HASSAN M, et al. Deep learning modelling techniques: current progress, applications, advantages, and challenges[J]. Artificial Intelligence Review, 2023, 56(11): 13521-13617.
- [16] WANG Y, CHEN L. A multi-scale spatial-temporal capsule network based on sequence encoding for bearing fault diagnosis[J]. Complex & Intelligent Systems, 2024, 10(5): 6189-6212.
- [17] CHEN H, WANG X, YANG Z. Fast robust capsule network with dynamic pruning and multiscale mutual information maximization for compound-fault diagnosis[J]. IEEE/ASME Transactions on Mechatronics, 2022, 28(2): 838-847.
- [18] XUE Y. Orthogonal capsule networks with positional information preservation and lightweight feature learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 36(7): 13345-13357.
- [19] 王义国, 林峰, 李琦, 等. 基于 TCN-LSTM 模型的电网电能质量扰动分类研究[J]. 电力系统保护与控制, 2024, 52(17): 161-167.
WANG Yiguo, LIN Feng, LI Qi, et al. Classification of power quality disturbances in a power grid based on the TCN-LSTM model[J]. Power System Protection and Control, 2024, 52(17): 161-167.
- [20] CEN S, KIM D O, LIM C G. A fused CNN-LSTM model using FFT with application to real-time power quality disturbances recognition[J]. Energy Science & Engineering, 2023, 11(7): 2267-2280.
- [21] 董永峰, 孙跃华, 高立超, 等. 基于改进一维卷积和双向长短期记忆神经网络的故障诊断方法[J]. 计算机应用, 2022, 42(4): 1207-1215.
DONG Yongfeng, SUN Yuehua, GAO Lichao, et al. Fault diagnosis method based on improved one-dimensional convolutional and bidirectional long short-term memory neural networks[J]. Journal of Computer Applications, 2022, 42(4): 1207-1215.
- [22] HUANG T, ZHANG Q, TANG X, et al. A novel fault diagnosis method based on CNN and LSTM and its application in fault diagnosis for complex systems[J]. Artificial Intelligence Review, 2022, 55(2): 1289-1315.
- [23] 刘杰, 从兰美, 夏远洋, 等. 基于 DBO-VMD 和 IWOA-BILSTM 神经网络组合模型的短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(8): 123-133.
LIU Jie, CONG Lanmei, XIA Yuanyang, et al. Short-term power load prediction based on DBO-VMD and an IWOA-BILSTM neural network combination model[J]. Power System Protection and Control, 2024, 52(8): 123-133.
- [24] 江永鑫, 陈丽安, 郭梦倩, 等. 基于改进 CEEMD 和 RF 的低压串联故障电弧识别方法[J]. 电力系统保护与控制, 2024, 52(1): 97-108.
JIANG Yongxin, CHEN Li'an, GUO Mengqian, et al. Identification method of low voltage series fault arc based on improved CEEMD decomposition and RF[J]. Power System Protection and Control, 2024, 52(1): 97-108.
- [25] POURSAEED A H, NAMDARI F. Online transient stability assessment implementing the weighted least-square support vector machine with the consideration of protection relays[J]. Protection and Control of Modern Power Systems, 2024, 10(1): 1-17.
- [26] 何小龙, 高红均, 黄媛, 等. 基于一维卷积和图神经网络的配电网故障区段定位方法[J]. 电力系统保护与控制, 2024, 52(17): 27-39.
HE Xiaolong, GAO Hongjun, HUANG Yuan, et al. Fault section location for a distribution network based on one-dimensional convolution and graph neural networks[J]. Power System Protection and Control, 2024, 52(17): 27-39.

收稿日期: 2025-04-13; 修回日期: 2025-07-20

作者简介:

孙抗(1982—), 男, 博士, 教授, 研究方向为电力装备智能故障诊断; E-mail: sunkang@hpu.edu.cn

李腾飞(1999—), 男, 通信作者, 硕士研究生, 研究方向为电力装备智能故障诊断。E-mail: 1824786392@qq.com

(编辑 周金梅)