

基于时频双域融合的风电机组高速轴承故障诊断

刘 杰, 李世新, 杨 娜, 郭美茹

(沈阳工业大学机械工程学院, 沈阳 110870)

摘 要: 针对旋转机械设备故障诊断中特征提取不充分、特征融合机制欠缺以及复杂工况下模型诊断能力不足等问题, 提出一种基于双域特征融合的 FFT-CNN-Informer 故障诊断方法。该方法构建了并行的时域-频域特征提取架构, 利用快速傅里叶变换(FFT)获取频域特征信息, 设计多尺度卷积神经网络(CNN)提取局部时域特征, 并引入概率稀疏自注意力机制捕获长程依赖关系, 实现了对振动信号的多维度特征提取。同时, 引入残差学习和自适应特征融合机制, 增强了模型对不同工况下故障特征的提取能力。在凯斯西储大学轴承数据集上的实验结果表明了该方法的优越性。在风电机组轴承数据集上进行实验, 诊断准确率相较于基础的 Transformer、LSTM 模型分别提高了 6.73 和 9.77 个百分点, 消融实验进一步证实了双域特征提取架构和自适应特征融合机制的必要性, 验证了该方法在实际风电场应用中的有效性和鲁棒性。

关键词: 风电机组; 故障诊断; 深度学习; 频域分析; 轴承; 数据融合

中图分类号: TM614

文献标志码: A

0 引 言

风电机组是可再生能源发电系统中的关键设备, 其轴承作为关键部件, 运行状态直接影响整个设备的安全性和可靠性。特别是在风力发电等大型工业设备中, 轴承故障可能导致整个系统的停机甚至灾难性事故, 造成巨大的经济损失。及时准确的轴承故障诊断具有重要的工程价值和意义。随着工业设备运行环境日益复杂化, 轴承振动信号呈现出非线性、非平稳等特点, 传统诊断方法在特征提取和故障识别方面面临着重大挑战, 这促使故障诊断技术不断革新^[1]。

近年来, 轴承故障诊断技术经历了从传统信号处理到深度学习的重要演进。传统的故障诊断方法主要依赖于信号处理技术, 如希尔伯特变换^[2]、小波变换^[3]、经验模态分解^[4]等。上述方法在理想工况下展现出良好的诊断性能, 但在复杂的工业环境中往往难以准确提取故障特征。随着深度学习技术的快速迭代和算法革新, 基于深度学习的智能故障诊断方法在解决复杂工况下的故障诊断问题方面展现出显著优势和应用潜力^[5]。

在深度学习的方法中, 卷积神经网络(convolutional neural networks, CNN)凭借其出色的特征提取能力, 在轴承故障诊断中得到广泛应用^[6]。刘洋等^[7]构建了一种融合注意力机制的一维卷积架构, 用于滚动轴承的故障诊断, 通过卷积与池化操作提取特征, 引入注意力机制进行加权, 经过特征融合后进行故障分类; 邵海东等^[8]提出一种基于卷积神经网络的对抗指导的无监督多域适配网络, 提升了协同故障诊

断的准确率; 文献[9]提出一种基于深度残差神经网络和数据融合的旋转机械故障诊断方法, 该方法通过短时傅里叶变换(short time Fourier transform, STFT)层对原始信号的时域和频域特征进行初步提取, 而后利用深度残差网络和融合嵌入层, 将时域、频域和空间域特征融合为高质量的低维特征, 诊断精度有很大提升; 文献[10]设计了一种深层残差一维卷积神经网络用于轴承故障诊断, 通过残差连接优化了深层特征提取能力, 显著提升了诊断精度。以上方法均将轴承振动信号输入卷积网络进行特征提取时, 传统单一卷积核结构在复杂工况下表现出特征提取能力受限、特征冗余度高等问题, 难以应对实际环境中的多源干扰^[11]。

为克服 CNN 的局限性, 研究者们引入基于注意力机制的 Transformer 架构, 它的核心思想是通过注意力机制来捕捉全局的依赖关系, 这使得它在处理长序列时比传统循环神经网络更有效^[12]。在此基础上, 文献[13]提出一种基于贝叶斯变分学习的概率 Transformer 模型, 用于可信的旋转机械故障诊断, 通过引入概率注意力机制, 实现了不确定性的量化与分解, 提高了模型的可解释性和可信度; 文献[14]提出一种创新的时频 Transformer 模型, 通过设计新型分词器和编码器模块, 实现振动信号时频域特征的高效提取与表示; 韩淞宇等^[15]提出一种名为 Convformer-NSE 的创新框架。该框架通过结合稀疏改进型多重自注意力机制和新型 Senet 结构, 实现了全局和局部特征的有效融合, 展现出优越的故障诊断性能。但由于 Transformer 的特性, 在高噪声环境背景下, 模型在特征提取和决策中会受到阻碍, 难以精确捕捉关键信息并

进行判断^[16]。

针对上述问题,文献[17]提出的 Informer 模型通过引入 Prob Sparse 自注意力机制和蒸馏采样策略,为轴承振动信号的长序列特征建模提供高效解决方案。然而,现有研究仍存在以下不足:单一域特征提取难以充分表征复杂工况下的故障模式;时域或频域的独立分析均存在信息损失;特征融合机制缺乏针对性设计,简单的特征拼接或加权策略难以有效捕捉时频域特征间的互补关系;在含噪声、变工况等复杂环境下,模型的鲁棒性和泛化能力有待提升。为此,本文提出基于快速傅里叶变换(fast Fourier transform, FFT)与双域特征融合的 FFT-CNN-Informer 故障诊断方法。该方法通过构建并行时频域特征提取架构,结合 CNN 的局部特征提取能力与 Informer 的全局序列建模优势,并引入自适应特征融合机制,旨在解决风电机组轴承在复杂运行环境下的精准故障诊断问题。

1 方法基本原理

1.1 FFT

FFT 是一种高效的频谱分析算法,其核心思想是将 N 点离散傅里叶变换递归分解为较小规模的子变换。在轴承故障诊断中,FFT 通过将时域振动信号映射至频域空间,揭示信号的频谱特征分布。对于长度为 N 的离散时间序列,其傅里叶变换的数学表达为:

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

$$W_N = e^{-j2\pi/N} \quad (2)$$

式中: $x(n)$ ——时域离散序列; N ——序列长度; k ——频率索引, $k=0,1,\dots,N-1$; $F(k)$ ——频域表示; W_N ——旋转因子; j ——虚数单位。

在轴承故障诊断中,FFT 能够有效识别故障特征频率,揭示调制特征和谐波成分,为后续的深度特征学习提供频域基础。

1.2 卷积神经网络

卷积神经网络作为深度学习的重要分支,通过局部连接、权值共享和多层特征提取等机制,在特征学习方面展现出强大性能。CNN 的核心在于卷积层,通过可学习的卷积核对输入数据进行特征提取,配合池化层进行特征降维和信息压缩。在本研究中,卷积神经网络采用多层级联结构,通过局部连接和权值共享机制实现特征的层次化提取。每层卷积运算可表示为:

$$y_l = f(W_l x_l + b_l) \quad (3)$$

式中: y_l ——第 l 层的输出特征图; W_l ——第 l 层的卷积核参数; x_l ——第 l 层的输入; b_l ——偏置项; $f(\cdot)$ ——非线性激活函数。

为提升网络的非线性表达能力,采用 GELU 激活函数:

$$\text{GELU}(z) = z \cdot \frac{1}{2} \left[1 + \text{erf} \left(\frac{z}{\sqrt{2}} \right) \right] \quad (4)$$

式中: z ——输入值; $\text{erf}(\cdot)$ ——误差函数。

网络中引入批归一化操作以提升训练稳定性:

$$y = \gamma \cdot \left(\frac{x - \mu}{\sqrt{\sigma^2 + \epsilon}} \right) + \beta \quad (5)$$

式中: γ ——可学习的缩放参数; β ——可学习的偏移参数; μ ——批次数据的均值; σ ——批次数据的标准差; ϵ ——防止分母为零的小常数。

为缓解深层网络的梯度消失问题,设计了残差连接结构:

$$H(h) = F(h) + h \quad (6)$$

式中: $H(h)$ ——残差块的输出; $F(h)$ ——残差映射函数; h ——输入特征。通过建立身份映射,有效缓解了深层网络的梯度消失问题。

1.3 多尺度卷积特征提取

多尺度卷积特征提取技术通过在不同尺度上进行特征学习,能捕获信号的多层次特征^[18]。该方法采用不同感受野大小的卷积核,实现对输入信号的多尺度分析。较小的卷积核关注局部细节特征,较大的卷积核则能获取更广范围的上下文信息。多尺度特征的融合可提供更全面的特征表示,增强模型对不同尺度模式的识别能力。多尺度特征提取采用并行的卷积结构,通过不同尺度的感受野捕获信号的多尺度特征:

$$Y_i = \phi(W_i X + b_i) \quad (7)$$

$$Y_{ms} = [Y_1, Y_2, \dots, Y_n] \quad (8)$$

式中: Y_i ——第 i 个尺度的特征图; W_i ——第 i 个尺度的卷积核参数; b_i ——偏置项; ϕ ——激活函数; X ——输入特征; Y_{ms} ——融合后的多尺度特征; $[\cdot]$ ——拼接操作; n ——并行尺度数量。

1.4 Informer 模型

Informer 模型是一种创新的序列建模架构,它突破了传统 Transformer 在处理长序列时的计算瓶颈。网络中的特征蒸馏操作通过渐进式下采样方式压缩序列长度,在保留重要信息的同时降低了计算复杂度。多头稀疏自注意力机制使得模型能从不同的表示子空间学习特征,增强了特征提取的多样性。Informer 模型结构如图 1 所示。

Informer 模型的多头稀疏注意机制是对传统注意力机制的优化,通过引入概率采样策略,有效降低了计算复杂度。其基本注意力计算表达式为:

$$\text{Attention}_{(Q,K,V)} = \text{soft max} \left(\frac{\bar{Q} K^T}{\sqrt{D_k}} \right) \cdot V \quad (9)$$

式中: Q ——查询矩阵; K ——键矩阵; V ——值矩阵; $\bar{Q}$ ——




图1 Informer模型结构

Fig. 1 Architecture of Informer model

通过 Q 的概率稀疏获得的矩阵; D_k ——查询向量和关键向量的维数; $\text{soft max}(\cdot)$ ——归一化激活函数。

假设 q_i, k_i, v_i 为 Q, K, V 的第 i 行, 则第 i 个 Q 的注意力值为:

$$A(q_i, K, V) = \sum_j \frac{k(q_i, k_j)}{\sum_k k(q_i, k_k)} v_j = E_{p(k|q_i)}[V_j] \quad (10)$$

第 i 个 Q 的稀疏性的计算表达式为:

$$M(q_i, K) = \ln \sum_{j=1}^{L_k} e^{\frac{q_i k_j}{\sqrt{d}}} - \frac{1}{L_k} \sum_{j=1}^{L_k} \frac{q_i k_j}{\sqrt{d}} \quad (11)$$

式中: $k(q_i, k_j)$ ——查询向量和键向量的相似度函数; L_k ——键序列的长度; $\sqrt{d}$ ——特征维度的平方根。

蒸馏层采用一维卷积与步长为 2 的池化操作级联构成, 该机制通过压缩冗余信息减少网络参数规模, 同时强化关键特征权重, 从而在后续层中生成更为紧凑的特征表示。第 j 层~第 $j+1$ 层在 t 时刻的蒸馏过程表示为:

$$\mu = \text{Conv1d}[X'_j]_{AB} \quad (12)$$

$$X_{j+1} = \text{MaxPool}(\text{ELU}(\mu)) \quad (13)$$

式中: MaxPool ——最大池化操作; ELU ——指数线性单元激活函数; Conv1d ——一维卷积操作; X'_j ——第 j 层的输入特征; $[\cdot]_{AB}$ ——在 AB 维度上的操作标记; X_{j+1} ——第 $j+1$ 层输出特征。

2 模型结构设计

2.1 双域多尺度卷积神经网络

所提的轴承故障诊断方法在理论上继承了卷积神经网络在局部特征提取方面的优势, 同时整合了 Informer 在处理长序列数据方面的创新。模型的双域特征提取是一种基于深度学习的多维特征融合架构, 该架构通过构建两个并行的特征提取通道, 实现了时域和频域信息的协同分析, 模型诊断框架如图 2 所示。模型编程的基本环境为: Intel® Core™ i9-14900HX CPU; NVIDIA GeForce RTX 4080 Laptop GPU; Python 3.12; PyTorch 2.41。




图2 FFT-CNN-Informer模型故障诊断框架

Fig. 2 Fault diagnosis framework of FFT-CNN-Informer model

2.2 基于 FFT-CNN-Informer 的轴承故障诊断

提出的 FFT-CNN-Informer 模型构建了时域和频域的双域并行架构, 其中时域分支直接处理原始振动信号, 通过 3 层残差卷积神经网络(卷积核数分别为 32、64、128)提取局部

时序模式; 频域分支首先对输入信号进行 FFT 处理获取幅值谱(512 个频点), 随后通过 3 层卷积网络(卷积核数分别为 16、32、64)提取频域特征。两个分支采用相同的网络拓扑结构(卷积层数、池化策略、激活函数), 但针对频域输入维度减

半的特点,频域分支的卷积核数量相应减半,以保持特征提取的参数效率。每层卷积后均采用批归一化和 GELU 激活函数,并通过最大池化进行下采样,最终时域分支输出 128 维特征向量,频域分支输出 64 维特征向量。

在特征融合阶段,时域和频域特征分别输入到独立的 Informer 编码器进行序列建模。两个编码器采用相同的结构参数(单层编码器,2 个注意力头,前馈网络隐藏层维度为 64),确保时域和频域特征在统一的表征框架下进行建模。经过 Informer 编码器和自适应平均池化后,时域和频域特征向量通过拼接操作融合为 192 维的联合特征表示。联合特征随后通过 3 层全连接分类器(隐藏层维度依次为 128、64,输出类别数量)实现故障诊断。时域分支支持获取原始时间序列的瞬态冲击特性和局部时序演化模式,频域分支支持获取故障特征频率及其谐波分布,两个分支的特征融合实现了时序动态过程与频谱信息量的优势互补。模型的输入输出参数配置如表 1 所示,其中 B 代表批处理大小,表示每次训练时处理的样本数量。

表 1 模型输出参数

Table 1 Model output parameters

网络层	输出尺寸	连接
时频域分支		
Input(Time)	$(B, 1, 1024)$	
TimeConv-Block1	$(B, 32, 512)$	Input
TimeConv-Block2	$(B, 64, 256)$	TimeConv-Block1
TimeConv-Block3	$(B, 128, 128)$	TimeConv-Block2
Time-Informer	$(B, 128, 128)$	TimeConv-Block3
Time-GAP	$(B, 128)$	Time-Informer
时域分支		
FFT Transform	$(B, 512)$	Input
Input(Frequency)	$(B, 1, 512)$	FFT Transform
FreqConv-Block1	$(B, 16, 256)$	Input(Frequency)
FreqConv-Block2	$(B, 32, 128)$	FreqConv-Block1
FreqConv-Block3	$(B, 64, 64)$	FreqConv-Block2
Freq-Informer	$(B, 64, 64)$	FreqConv-Block3
Freq-GAP	$(B, 64)$	Freq-Informer
特征融合与分类		
Concatenate	$(B, 192)$	Time-GAP+ Freq-GAP
FC-Layer1	$(B, 128)$	Concatenate
FC-Layer2	$(B, 64)$	FC-Layer1
Output Layer	$(B, \text{类别数量})$	FC-Layer2

3 实例分析

3.1 数据集介绍

本研究在凯斯西储大学轴承数据中心公开的标准轴承数据集^[19]上进行。采用 12 kHz 采样频率下的驱动端轴承数据,共有 4 种不同的轴承故障状态。数据来源于轴承在 0~3 hp(0~2205 W)负载条件下工作时采集到的振动数据,振动信号如图 3 所示。共涵盖 10 种故障,如表 2 所示,在同种故障条件下,编号后缀代表损伤深度,07 代表 0.1778 mm 深度;14 代表 0.3556 mm 深度;21 代表 0.5334 mm 深度。




图 3 轴承振动信号

Fig. 3 Bearing vibration signal

表 2 滚动轴承故障类型

Table 2 Rolling bearing fault types

标签	代号	故障类型	故障深度/mm	故障程度
0	N	正常	0	无
1	IR07	内圈故障	0.1778	轻度
2	OR07	外圈故障	0.1778	轻度
3	RE07	滚动体故障	0.1778	轻度
4	IR14	内圈故障	0.3556	中度
5	OR14	外圈故障	0.3556	中度
6	RE14	滚动体故障	0.3556	中度
7	IR21	内圈故障	0.5334	重度
8	OR21	外圈故障	0.5334	重度
9	RE21	滚动体故障	0.5334	重度

3.2 数据集处理

为确保数据集的代表性,每类故障状态均通过滑动窗口截取 1024 个采样点作为一个样本,窗口重叠率设置为 30%。经过滑动窗口处理后,将 10 种故障类型样本按 7:2:1 的比


例分配至训练集、验证集及测试集,具体样本分布见表3。

为验证数据集的频域判别能力和所选信号长度的合理性,


表3 数据集划分样本分布

Table 3 Sample distribution of dataset partitioning


故障代号	类型标签	训练样本/个	验证样本/个	测试样本/个
正常	0	112	32	16
内圈故障	1	112	32	16
外圈故障	2	112	32	16
滚动体故障	3	112	32	16
内圈故障	4	112	32	16
外圈故障	5	112	32	16
滚动体故障	6	112	32	16
内圈故障	7	112	32	16
外圈故障	8	112	32	16
滚动体故障	9	112	32	16




a. N




c. OR07




e. IR14




g. RE14




b. IR07



d. RE07



f. OR14



h. IR21

以 0 hp 负载条件下的数据为例,对不同健康状态的振动信号进行时频域特征分析。图4展示了1024个采样点数据经过FFT的时频域对比结果。

从频谱图可见,正常状态频谱能量分布相对均匀且幅值较低,而故障状态在特定频率处呈现明显的能量集中和峰值突起,这些特征频率与轴承的故障特征频率相对应,为故障诊断提供了可靠的依据。

3.3 参数选择

为了验证 FFT-CNN-Informer 模型选择不同学习率在轴承故障诊断任务中的影响,分别尝试设置初始学习率值为 1×10^{-4} , 1×10^{-3} , 1×10^{-2} , 训练过程中的损失值曲线如图5所示。

由训练过程中损失值下降的曲线分析,初始学习率为 1×10^{-3} 的曲线有更好的效果,因此初始学习率的值设定为 1×10^{-3} 。

3.4 结果及分析

将训练集与验证集输入到网络中进行训练,后将训练出的权重对测试集进行结果测试,在测试集上准确率达到100%,训练过程曲线如图6所示,测试集预测结果置信度分布如图7所示。




图4 时频对比可视化分析

Fig. 4 Visualization of time-frequency comparison analysis




图5 不同初始学习率下的损失值曲线

Fig. 5 Loss curves under different initial learning rates




图6 训练曲线

Fig. 6 Training curves





图7 测试集预测置信度分布

Fig. 7 Distribution of prediction confidence on test set

从训练过程曲线可看出,模型具有极佳的性能,在训练10轮准确率就接近100%。而从置信度分布直方图可观察到,模型的预测结果高度集中在0.990~1.000区间,平均置信度达到0.999,这反映出模型在进行故障分类时具有极高的判别能力和稳定性。

3.5 t -SNE降维结果

为直观评估所提模型的特征学习效果,引入 t -分布随机邻近嵌入方法(t -distributed stochastic neighbor embedding, t -SNE)对网络提取的高维特征进行降维可视化。经过 t -SNE降维处理的结果如图8所示。

图8 t -SNE可视化分析Fig. 8 t -SNE visualization analysis

通过对比原始数据分布和模型提取的特征分布可清晰地观察到,原始数据在三维空间中呈现出明显的类间重叠现象,不同故障类型的样本边界模糊。而经过模型处理后的特征分布展现出显著的聚类效果,同类样本聚集程度高,类间边界清晰,充分证实了所提模型具有优异的特征提取和故障模式区分能力。

3.6 变负载故障诊断实验

为验证模型对轴承损伤程度识别的跨工况泛化性能,构建了变负载条件下的迁移诊断实验场景。实验用单一负载训练、其他负载测试的跨负载迁移诊断(leave-one-out)策略,即在每次测试中选择一种负载工况(0 hp、1 hp、2 hp 或 3 hp)下的数据作为测试集,而将其他负载工况下的数据用于模型训练。图 9 展示了模型在不同负载转移场景下的识别准确率。




图9 不同负载下的识别准确率柱状图

Fig. 9 Bar chart of recognition accuracy under different loads

由图 9 可知,所提模型在相邻负载工况间展现出较为不错的诊断性能,随着负载差异的增大,诊断准确率呈现一定程度的下降趋势,而在高负载工况(3 hp)训练时,表现出良好的向低负载迁移能力。

为进一步分析负载变化对故障特征的影响,表 4 统计了各故障类型在不同负载下的振动均方根值(root mean square, RMS)值^[20],以及从最低负载到最高负载的极差变化率。

表 4 各故障类型在不同负载下的 RMS 值

Table 4 RMS values of each fault type under different loads

故障 标签	RMS 值/g				极差变 化率/%
	0 hp	1 hp	2 hp	3 hp	
N	0.0738	0.0664	0.0643	0.0659	-10.7
IR07	0.2915	0.2929	0.2995	0.3136	7.6
OR07	0.1392	0.1391	0.1473	0.1536	10.3
RE07	0.6695	0.5919	0.5702	0.5804	-13.3
IR14	0.1978	0.1655	0.1631	0.1808	-8.6
OR14	0.1527	0.1409	0.1435	0.1337	-12.5
RE14	0.1007	0.0936	0.0968	0.0947	-5.9
IR21	0.5254	0.4418	0.4889	0.4487	-14.6
OR21	0.1356	0.1291	0.1073	0.1180	-13.0
RE21	0.5832	0.5614	0.5700	0.5590	-4.1

从表中数据可看出,正常状态下,RMS 值从 0 hp 的 0.0738g 降至 2 hp 的 0.0643g,表明负载增加时轴承运行更加平稳;而故障状态下,不同故障类型的 RMS 值随负载变化呈不同的趋势,例如 IRE07 滚动体故障在 0 hp 时 RMS 最高(0.6695g),随负载增加逐渐降低至 3 hp 的 0.5804g,而 RE07 外圈故障则呈相反趋势,从 0 hp 的 0.1392g 增加至 3 hp 的 0.1536g。这种负载相关的幅值漂移现象在所有故障类型中普遍存在,导致基于振动幅值特征的诊断模型在跨负载场景下面临分布偏移问题,进一步加剧了诊断难度。所提 FFT-CNN-Informer 双域模型通过同时提取时域和频域特征,尤其是频域分支能捕捉负载不变的故障特征频率信息,在一定程度上缓解了幅值漂移对诊断性能的影响,使得模型在训练时对变负载工程的诊断仍保持较好的性能。

4 风电机组高速轴承故障诊断

4.1 数据集介绍

为验证模型在实际工程背景故障诊断中的有效性,使用美国电力监测系统的真实轴承全寿命周期数据^[21],轴承故障如图 10 所示,故障类型为内圈故障。数据为在商用 2.2 MW 风力机上收集的 50 d 振动数据。每天以高采样率进行一次原始采集,每次 6 s(采样频率约为 100 kHz)。从故障图像可清晰观察到轴承内圈出现了典型的疲劳剥落损伤。




图 10 风电机组轴承故障

Fig. 10 Wind turbine bearing fault diagram

4.2 数据状态划分

为了系统评估轴承退化过程并建立有效的健康状态监测机制,需对采集的振动数据进行合理的状态划分。设备健康指数是一个取值范围为 0~1 的无量纲化参数,以 I_h 表示,用于表征设备的运行状态^[22]。 I_h 值越接近 1,表明设备运行状况越好,其中 1 表示设备处于最佳运行状态,0 则表示设备已完全失效。

为消除量纲差异对分析结果的影响,对第一主成分 KPCA1 进行了离差标准化处理,将结果映射到[0, 1]之间。设第一核主元 KPCA1 为 $Z = \{z_1, z_2, \dots, z_n\}$,其中各元素代表高速轴承的健康指数,即 $I_h(t)$ 。则标准化过程可表示为:

$$I_h(t) = 1 - \frac{z_i - \min_{1 \leq j \leq n} \{z_j\}}{\max_{1 \leq j \leq n} \{z_j\} - \min_{1 \leq j \leq n} \{z_j\}} \quad (14)$$

式中: $\max$ ——表示序列 Z 中的最大值; $\min$ ——表示序列 Z 中的最小值, 经过转换后得到的健康指数序列为 $I_h(t) = \{I_{h1}, I_{h2}, \dots, I_{hn}\}$, 详细分级标准见表 5。

表 5 轴承健康指数等级划分

Table 5 Bearing health index classification

健康状况等级	I_h 取值范围	健康状况描述
健康	$1 \geq I_h \geq 0.9$	健康状况非常好
比较健康	$0.9 > I_h \geq 0.8$	健康状况良好
亚健康	$0.8 > I_h \geq 0.7$	出现异常征兆
轻微故障	$0.7 > I_h \geq 0.5$	出现轻微故障现象
故障	$0.5 > I_h \geq 0.1$	出现严重故障现象

根据表 5 中的健康指数分级标准, 对轴承的健康状态进行了时序划分: 3 月 7—11 日轴承处于健康状态、3 月 12—31 日表现为比较健康状态、4 月 1—7 日进入亚健康状态、4 月 8—16 日开始出现轻微故障、4 月 17—28 日发展至故障状态, 共有 5 种故障类型, 如图 11 所示。




图 11 健康指数曲线

Fig. 11 Health index curves

如图 12 所示, 通过对振动信号的时域分析可观察到, 从健康状态到故障状态的转变过程中, 信号的幅值和波形特征都发生了显著变化。




图 12 轴承振动信号

Fig. 12 Bearing vibration signal

不同运行阶段轴承振动数据的特征参数如表 6 所示, 数据显示, 随着轴承状态的恶化, 振动信号的标准差逐渐增大, 最大值和最小值的极差也随之扩大。

表 6 不同类型的振动数据特征

Table 6 Characteristics of different types of vibration data

故障类型	均值	标准差	最大值	最小值
健康	0.24755	2.10349	11.28767	-10.84617
比较健康	0.24212	2.09379	13.55943	-12.87993
亚健康	0.21088	2.19401	14.68064	-14.66339
轻微故障	0.24396	2.39166	17.56335	-18.14127
故障	0.18932	2.53430	22.96916	-21.65893

4.3 数据集处理

每类故障状态均通过截取 1024 个采样点作为一个样本, 将处理好的样本按 7:2:1 的比例分配至训练、验证及测试集, 具体样本分布见表 7。

表 7 数据集划分样本分布

Table 7 Sample distribution of dataset partitioning

故障类型	类型标签	训练样本/个	验证样本/个	测试样本/个
健康	0	2864	817	404
比较健康	1	11459	3253	1628
亚健康	2	3953	1175	591
轻微故障	3	5169	1449	735
故障	4	5150	1476	727

4.4 模型测试

将划分后的数据输入到所提模型中进行训练, 后对测试集进行测试, 所得测试精度结果如图 13 混淆矩阵所示。从




图 13 混淆矩阵图

Fig. 13 Confusion matrix diagram

混淆矩阵的对角线元素可观察到,模型对各类健康状态均表现出优异的识别能力。

从图 13 可得出,模型对各类状态的识别准确率均达到 94% 以上,整体混淆矩阵呈现出强对角线特征,证实了所提模型在轴承故障诊断中具有优异的分类性能。

4.5 消融实验

为验证模型中不同模块的必要性,通过设计消融实验,对比 FFT-CNN-Informer、FFT-Informer、CNN-Informer、Informer、FFT-CNN 与 CNN 模型的训练过程。训练过程如图 14 所示,消融实验结果如表 8 所示。




图 14 不同模型的训练曲线

Fig. 14 Training curves of different models

从图 14 可看出所提模型表现出最优的收敛特性,相比之下,CNN-Informer 模型虽然也展现出不错的学习能力,但收敛速度略慢于所提模型。而单一结构的 CNN 和 FFT-CNN 模型表现出相对较弱的特征提取能力,其训练曲线在整个过程中始终处于较低水平,且波动较大。

表 8 消融实验结果

Table 8 Ablation experimental results

模型	准确率/%
所提模型	97.15
FFT-Informer	91.63
CNN-Informer	92.77
Informer	91.05
FFT-CNN	87.68
CNN	87.01

消融实验结果清晰地展示了各模型架构在轴承故障诊断任务上的性能差异。对比 Informer 与 CNN-Informer 模型,在引入 CNN 后,CNN-Informer 模型准确率提升了 1.72 个百分点,验证了 CNN 在提取局部特征方面的优势。CNN 通过多尺度卷积核能有效捕获振动信号中的局部冲击模式和瞬

态特征,为 Informer 提供了更具判别性的特征表示。同时,对比 FFT-CNN 与所提模型,引入 Informer 后准确率大幅提升 9.47 个百分点,这充分说明了 Informer 在建模长程时序依赖关系方面的关键作用。Informer 通过概率稀疏自注意力机制能够捕获振动信号随时间演化的全局模式,弥补了 CNN 仅关注局部特征的局限性。

完整的 FFT-CNN-Informer 模型相比于任何单一模块或部分组合都取得了显著的性能提升,验证了双域特征提取、局部特征学习与全局依赖建模三者协同作用的重要性。CNN 对 FFT 后的频域特征和原始时域特征进行初步的多尺度处理,提取出具有判别性的局部模式;Informer 进一步在此基础上建模长程时序依赖,捕获故障演化的全局规律;特征融合机制则有效整合了这些多维度信息,最终实现了优异的诊断性能。

4.6 对比实验

为验证所提模型的诊断性能,采用相同的数据预处理方式、数据划分比例和训练超参数设置,输入信号长度统一设置为 1024 个采样点,对比了 FFT-CNN-Transformer、CNN-Transformer、Transformer、CNN-LSTM、LSTM 模型的准确率。在 100 轮训练的情况下,在测试集的准确率如表 9 所示。

表 9 对比实验结果

Table 9 Contrast experimental results

模型	准确率/%
所提模型	97.15
FFT-CNN-Transformer	94.49
CNN-Transformer	92.10
Transformer	90.42
CNN-LSTM	92.05
LSTM	87.38

对比实验结果显示所提模型在轴承故障诊断任务中以 97.15% 的准确率位居第一,FFT-CNN-Transformer 模型达到 94.49% 的准确率,位居第二。CNN-Transformer 和 CNN-LSTM 两种混合架构的性能相当,准确率均约在 92%,而单一的 LSTM 模型表现最差,仅为 87.38%,这进一步验证了多特征融合架构在提升模型性能方面的重要性。

4.7 鲁棒性分析

为全面评估所提出的 FFT-CNN-Informer 模型在实际工程应用中的可靠性和适应性,本节从训练样本比例、噪声干扰和小样本学习 3 个维度对模型的鲁棒性进行深入分析。

4.7.1 不同训练集比例下的性能分析

在模型训练中,训练集的大小是影响模型性能的重要因素。为研究模型对训练样本数量的敏感性,设置不同的训练

集与测试集比例,训练样本按 10% 的比例递增,在其他超参数保持不变的前提下,仅变更数据集划分比例,结果如图 15 所示。




图 15 不同训练集与测试集比例下的准确率

Fig. 15 Accuracy under different training-test split ratios

从图 15 可看出,当训练集与测试集比例为 9:1 时,模型准确率达到 98.4%。随着训练样本比例的逐步降低,模型性能呈平缓下降的趋势,即使在训练集仅占 10% 的极端情况下,准确率仍能保持在 87.82% 的可接受水平。这表明所提出的模型具有良好的样本利用效率,即使在训练数据有限的情况下,仍能保持较高的诊断精度。

4.7.2 噪声鲁棒性分析

在实际工业环境中,振动信号不可避免地会受到各种噪声的干扰,如环境噪声、传感器噪声和电磁干扰等。为验证模型在噪声环境下的诊断能力,通过向原始信号添加不同信噪比(signal to noise ratio, SNR)的高斯白噪声来模拟实际工况,设置 SNR 分别为 20 dB、15 dB、10 dB 和 5 dB,对应 4 种不同程度的噪声干扰场景,诊断结果如图 16 所示。




图 16 噪声鲁棒性结果

Fig. 16 Noise robustness results

从图 16 可看出,在同等噪声环境下,所提模型展现出良好的抗噪性能。随着噪声强度的加大,所提模型准确率虽有下降,但仍处在较高的准确率,而对比方法的性能均有大幅下降的趋势。这些结果充分验证了所提模型在复杂噪声环境下的鲁棒性和实用性。

4.7.3 不平衡小样本场景鲁棒性分析

在实际故障诊断应用中,特别是对于新投入运行的设备或罕见故障类型,往往难以获取大量标注样本。为评估模型在不平衡小样本场景下的诊断能力,对 5 类训练样本数量分别设置为 200、150、100、50 和 20 个,验证和测试样本中 5 类样本的数量均设置为 50 以评估模型应对不平衡小样本挑战下的性能,结果如图 17 所示。




图 17 不平衡小样本场景鲁棒性结果


Fig. 17 Robustness results for imbalanced small-sample scenarios

从图 17 可看出,模型在小样本条件下仍能保持较高的诊断性能。模型准确率仍达到 68.7%,显著优于传统深度学习学习方法在小样本场景下的表现。这得益于所提模型中 Informer 编码器的稀疏自注意力机制能够有效捕获样本间的关键特征关系,以及时频双域特征融合策略提供的丰富特征表示。


4.8 t-SNE降维结果

为了更好的展示所提模型的分类效果,利用 t 分布随邻域嵌入对模型分类效果进行可视化分析,原始数据分布与训练后数据分布如图 18 所示。

从可视化结果可观察到经过模型训练后,不同状态的数据点形成了相对独立的聚类簇,类间边界清晰。特别是健康状态和故障状态的数据点被显著分离,表明模型成功学习到了区分性特征。



a. 原始数据分布



b. 训练后数据分布

图 18 t-SNE 可视化分析

Fig. 18 t-SNE visualization analysis

5 结 论

5.1 主要结论

针对轴承故障诊断问题,提出一种基于 FFT 和 CNN-Informer 的轴承故障诊断方法,该方法具有较强的特征提取和表达能力。通过实验证明了所提模型的优越性,可得出以下主要结论:

1) 构建的 FFT-CNN-Informer 模型融合了时域原始振动信号与 FFT 后的频域特征,通过双域特征提取机制实现了对轴承故障特征的全面捕捉。CNN 分支通过多尺度卷积核提取振动信号的局部冲击特征和细节信息,Informer 分支通过概率稀疏自注意力机制捕获信号的全局时序演化规律和长程依赖关系,两者优势互补,弥补了单一方法的不足。消融实验表明,相较于单独使用 CNN 或 Informer,融合架构能显著提升诊断准确率,可深度挖掘轴承振动信息,相较于其他方法构建的轴承故障诊断模型具有更高的准确率。

2) 在两个实验验证中,所提模型展现出优异的诊断性能。在风电机组高速轴承数据集的实验中,相较于 FFT-CNN-Transformer、CNN-Transformer、Transformer、CNN-LSTM 和 LSTM 等对照方法,诊断准确率分别提升了 2.66、5.05、6.73、5.10 和 9.77 个百分点。通过对实际工程背景下的旋转机械进行故障诊断,证明了研究方法是一种可靠的故障诊断方法。

5.2 研究局限性与未来展望

尽管提出的模型在轴承故障诊断中取得了较好的效果,但仍存在以下局限性:

1) 样本不均衡问题:本研究中假设各类故障样本分布相对均衡,但在实际工业场景中,健康状态样本通常占据绝大多数,而故障样本尤其是严重故障样本较为稀缺。这种样本不均衡会导致模型对少数类故障的识别能力下降,可能出现误诊或漏诊。未来工作考虑引入样本重采样、代价敏感学习或生成对抗网络等技术,以提升模型在不均衡数据集上的泛化性能。

2) 分布外故障的泛化能力:所构建的模型主要针对训练集中已知的故障类型进行诊断,对于未曾见过的新型故障模式的识别能力有限。未来工作考虑引入开集识别、迁移学习或元学习等方法,增强模型对分布外样本的适应能力。

[参考文献]

- [1] 李俊卿, 胡晓东, 王罗, 等. 考虑数据不足和基于合作博弈模型融合的风电机组轴承故障诊断方法[J]. 太阳能学报, 2024, 45(1): 234-241.
LI J Q, HU X D, WANG L, et al. Bearing fault diagnosis method for wind turbine considering insufficient data and based on cooperative game model fusion[J]. Acta energiae solaris sinica, 2024, 45(1): 234-241.
- [2] JARAMILLO F, GUTIÉRREZ J M, ORCHARD M, et al. A Bayesian approach for fatigue damage diagnosis and prognosis of wind turbine blades[J]. Mechanical systems and signal processing, 2022, 174: 109067.
- [3] PICHKA S V V S N, MEGANAA G, GEETHA RAJASEKHARAN S, et al. Multi-component fault classification of a wind turbine gearbox using integrated condition monitoring and hybrid ensemble method approach[J]. Applied acoustics, 2022, 195: 108814.
- [4] ANTONIADOU I, MANSON G, STASZEWSKI W J, et al. A time-frequency analysis approach for condition monitoring of a wind turbine gearbox under varying load conditions[J]. Mechanical systems and signal processing, 2015, 64/65: 188-216.
- [5] ZHOU F N, YANG S, HE Y F, et al. Fault diagnosis based on deep learning by extracting inherent common feature of multi-source heterogeneous data[J]. Proceedings of the Institution of Mechanical engineers, part I: journal of systems and control engineering, 2021, 235(10): 1858-1872.
- [6] 李俊, 刘永葆, 余又红. 卷积神经网络和峭度在轴承故障诊断中的应用[J]. 航空动力学报, 2019, 34(11): 2423-2431.
LI J, LIU Y B, YU Y H. Application of convolutional neural network and kurtosis in fault diagnosis of rolling bearing[J]. Journal of aerospace power, 2019, 34(11): 2423-2431.
- [7] 刘洋, 程强, 史曜炜, 等. 基于注意力模块及 1D-CNN 的滚动轴承故障诊断[J]. 太阳能学报, 2022, 43(3): 462-468.
LIU Y, CHENG Q, SHI Y W, et al. Fault diagnosis of rolling bearings based on attention module and 1D-CNN[J]. Acta energiae solaris sinica, 2022, 43(3): 462-468.
- [8] 邵海东, 陈星恺, 曹鸿儒, 等. 内对抗指导无监督多域适配网络的轴承协同故障诊断[J]. 中国科学(技术科

- 学), 2023, 53(7): 1229-1240.
- SHAO H D, CHEN X K, CAO H R, et al. Internal adversarial guided unsupervised multi-domain adaptation network for collaborative fault diagnosis of bearing [J]. *Scientia sinica (technologica)*, 2023, 53(7): 1229-1240.
- [9] PENG B S, XIA H, LYU X Z, et al. An intelligent fault diagnosis method for rotating machinery based on data fusion and deep residual neural network [J]. *Applied intelligence*, 2022, 52(3): 3051-3065.
- [10] 赵敬娇, 赵志宏, 杨绍普. 基于残差连接和1D-CNN的滚动轴承故障诊断研究[J]. *振动与冲击*, 2021, 40(10): 1-6.
- ZHAO J J, ZHAO Z H, YANG S P. Rolling bearing fault diagnosis based on residual connection and 1D-CNN [J]. *Journal of vibration and shock*, 2021, 40(10): 1-6.
- [11] ZHAO K Y, SUN R T, LI L, et al. An improved evidence fusion algorithm in multi-sensor systems [J]. *Applied intelligence*, 2021, 51(11): 7614-7624.
- [12] HAN K, WANG Y H, CHEN H T, et al. A survey on vision transformer [J]. *IEEE transactions on pattern analysis and machine intelligence*, 2023, 45(1): 87-110.
- [13] XIAO Y M, SHAO H D, FENG M J, et al. Towards trustworthy rotating machinery fault diagnosis via attention uncertainty in transformer [J]. *Journal of manufacturing systems*, 2023, 70: 186-201.
- [14] DING Y F, JIA M P, MIAO Q H, et al. A novel time-frequency Transformer based on self-attention mechanism and its application in fault diagnosis of rolling bearings [J]. *Mechanical systems and signal processing*, 2022, 168: 108616.
- [15] HAN S Y, SHAO H D, CHENG J S, et al. Convformer-NSE: a novel end-to-end gearbox fault diagnosis framework under heavy noise using joint global and local information [J]. *IEEE/ASME transactions on mechatronics*, 2023, 28(1): 340-349.
- [16] WANG R, ZHANG S J, LIU S Q, et al. A bearing fault diagnosis method for high-noise and unbalanced dataset [J]. *Smart and resilient transportation*, 2023, 5(1): 28-45.
- [17] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: beyond efficient transformer for long sequence time-series forecasting [J]. *Proceedings of the AAAI conference on artificial intelligence*, 2021, 35(12): 11106-11115.
- [18] 赵小强, 张亚洲. 利用改进卷积神经网络的滚动轴承变工况故障诊断方法[J]. *西安交通大学学报*, 2021, 55(12): 108-118.
- ZHAO X Q, ZHANG Y Z. Improved CNN-based fault diagnosis method for rolling bearings under variable working conditions [J]. *Journal of Xi'an Jiaotong University*, 2021, 55(12): 108-118.
- [19] Case Western Reserve University Bearing Data Center. Seeded fault test data [EB/OL]. <http://csegroups.case.edu/bearingdatacenter>.
- [20] MOSHREFZADEH A. Condition monitoring and intelligent diagnosis of rolling element bearings under constant/variable load and speed conditions [J]. *Mechanical systems and signal processing*, 2021, 149: 107153.
- [21] SAIDI L, BEN ALI J, BECHHOEFER E, et al. Wind turbine high-speed shaft bearings health prognosis through a spectral Kurtosis-derived indices and SVR [J]. *Applied acoustics*, 2017, 120: 1-8.
- [22] 李振恩, 张新燕, 胡威, 等. 基于健康指数的风电机组高速轴轴承状态评估与预测[J]. *太阳能学报*, 2021, 42(10): 290-297.
- LI Z E, ZHANG X Y, HU W, et al. State assessment and prediction of wind turbine high speed shaft bearing based on health index [J]. *Acta energiae solaris sinica*, 2021, 42(10): 290-297.

FAULT DIAGNOSIS OF WIND TURBINE HIGH-SPEED BEARINGS BASED ON TIME-FREQUENCY DUAL-DOMAIN FUSION

Liu Jie, Li Shixin, Yang Na, Guo Meiru

(School of Mechanical Engineering, Shenyang University of Technology, Shenyang 110870, China)

Abstract: To address the challenges of insufficient feature extraction, inadequate feature fusion mechanisms, and limited diagnostic capability under complex operating conditions in rotating machinery fault diagnosis, a novel FFT-CNN-Informer fault diagnosis method based on dual-domain feature fusion is proposed. A parallel time-frequency domain feature extraction architecture is constructed. Specifically, Fast Fourier Transform (FFT) is employed to extract frequency-domain features, a multi-scale Convolutional Neural Network (CNN) is designed to capture local temporal features, and a Probabilistic Sparse Self-Attention mechanism is introduced to capture long-range dependencies, enabling multi-dimensional feature extraction of vibration signals. Furthermore, residual learning and an adaptive feature fusion mechanism are incorporated to enhance the ability to extract fault features under varying operating conditions. Experimental results on the Case Western Reserve University bearing dataset demonstrate the superiority of the proposed method. On wind turbine bearing datasets, the proposed method outperforms baseline Transformer and LSTM models by 6.73% and 9.77% in diagnostic accuracy, respectively. Ablation studies further validate the necessity of the dual-domain feature extraction architecture and the adaptive feature fusion mechanism, confirming the effectiveness and robustness of the method in practical wind farm applications.

Keywords: wind turbines; fault diagnosis; deep learning; frequency domain analysis fusion; bearing; data fusion