



基于双域抗噪编码与门控循环Transformer的轴承故障诊断

蒋鹏 姚立忠 秦鹏杰

Bearing Fault Diagnosis Based on Dual-domain Anti-noise Coding and Gated Recurrent Transformer

JIANG Peng, YAO Li-Zhong, QIN Peng-Jie

在线阅读 View online: <https://doi.org/10.16383/j.aas.c250650>

您可能感兴趣的其他文章

基于两阶段域泛化学习框架的轴承故障诊断方法

A Two-stage Domain Generalization Learning Framework for Fault Diagnosis of Bearings

自动化学报. 2024, 50(11): 2271–2285 <https://doi.org/10.16383/j.aas.c230716>

基于参数优化 VMD 和样本熵的滚动轴承故障诊断

Rolling Bearing Fault Diagnosis Based on Parameter Optimization VMD and Sample Entropy

自动化学报. 2022, 48(3): 808–819 <https://doi.org/10.16383/j.aas.c190345>

基于不同故障传播路径差异化的故障诊断方法

Fault Propagation Path-aware Network: A Fault Diagnosis Method

自动化学报. 2025, 51(1): 161–173 <https://doi.org/10.16383/j.aas.c240151>

故障诊断与容错控制的一个新框架

A New Framework for Fault Diagnosis and Fault Tolerant Control

自动化学报. 2021, 47(5): 1035–1042 <https://doi.org/10.16383/j.aas.c190004>

基于改进结构保持数据降维方法的故障诊断研究

Research on Fault Diagnosis of Data Dimension Reduction Based on Improved Structure Preserving Algorithm

自动化学报. 2021, 47(2): 338–348 <https://doi.org/10.16383/j.aas.c180138>

基于注意力机制和循环域三元损失的域自适应目标检测

Domain Adaptive Object Detection Based on Attention Mechanism and Cycle Domain Triplet Loss

自动化学报. 2024, 50(11): 2188–2203 <https://doi.org/10.16383/j.aas.c220938>

基于双域抗噪编码与门控循环 Transformer 的轴承故障诊断

蒋 鹏¹ 姚立忠¹ 秦鹏杰²

摘 要 针对强噪声非平稳环境下滚动轴承故障信号关键特征易被淹没而导致诊断性能下降的难题, 提出一种双域抗噪编码与协同注意力混合解码模型. 首先, 该模型构建一个双域抗噪编码器, 其时域残差收缩分支可自适应学习阈值以抑制干扰, 同时波域可微分小波卷积分支用以捕获多尺度频率结构, 二者共同实现鲁棒的多域特征表示; 其次, 模型设计双域协同注意力模块, 通过双向交互与门控调节实现时域、波域特征的动态协同与自适应融合, 进而提升高噪声下的特征融合能力; 最后, 开发门控循环 Transformer 解码器组件, 将 Transformer 自注意力机制与 GRU 循环门控机制深度融合, 在统一的特征空间内同步实现全局建模与局部时序依赖提取的高效平衡. 基于凯斯西储大学与帕德博恩大学轴承数据集的实验表明, 该模型在标准工况下准确率达到 100%, 且在强噪声下仍保持高准确率, 充分体现了其优越的抗噪性与鲁棒性.

关键词 故障诊断; 双域特征提取; 协同注意力机制; 门控循环 Transformer

引用格式 蒋鹏, 姚立忠, 秦鹏杰. 基于双域抗噪编码与门控循环 Transformer 的轴承故障诊断. 自动化学报, 2026, 52(7): 1372–1386

DOI 10.16383/j.aas.c250650 **CSTR** 32138.14.j.aas.c250650

Bearing Fault Diagnosis Based on Dual-domain Anti-noise Coding and Gated Recurrent Transformer

JIANG Peng¹ YAO Li-Zhong¹ QIN Peng-Jie²

Abstract To address the challenge where key features of rolling bearing fault signals are easily masked in strong noise and non-stationary environments, leading to degraded diagnostic performance, this paper proposes a dual-domain anti-noise encoder with co-attention hybrid decoder. First, the model constructs a dual-domain anti-noise encoder: Its time-domain residual shrinkage branch adaptively learns thresholds to suppress interference, while the wavelet-domain differentiable wavelet convolution branch captures multi-scale frequency structures, jointly achieving a robust multi-domain feature representation. Second, a dual-domain co-attention module is designed to realize dynamic coordination and adaptive fusion of time-domain and wavelet-domain features via bidirectional interaction and gated regulation, enhancing feature fusion capability under high noise. Finally, a gated recurrent Transformer decoder component is developed, deeply integrating the Transformer's self-attention mechanism with the GRU's recurrent gated mechanism. This achieves an efficient balance between global modeling and local temporal dependency extraction within a unified feature space. Experiments on the Case Western Reserve University and Paderborn University bearing dataset demonstrate that the proposed model achieves 100% accuracy under standard conditions and maintains high accuracy even under strong noise, validating its superior anti-noise performance and robustness.

Keywords fault diagnosis; dual-domain feature extraction; co-attention mechanism; gated recurrent Transformer

Citation Jiang Peng, Yao Li-Zhong, Qin Peng-Jie. Bearing fault diagnosis based on dual-domain anti-noise coding and gated recurrent Transformer. *Acta Automatica Sinica*, 2026, 52(7): 1372–1386

收稿日期 2025-11-17 录用日期 2026-03-19

Manuscript received November 17, 2025; accepted March 19, 2026

国家自然科学基金 (62573076, 62403453), 重庆市教委科学技术研究重点项目 (KJZD-K202400513), 重庆市自然科学基金 (CSTB2023NSCQ-MSX0537) 资助

Supported by National Natural Science Foundation of China (62573076, 62403453), Key Science and Technology Research Program of Chongqing Municipal Education Commission (KJZD-K202400513), and Natural Science Foundation of Chongqing (CSTB2023NSCQ-MSX0537)

本文责任编辑 罗彪

Recommended by Associate Editor LUO Biao

1. 重庆师范大学物理与光电工程学院 重庆 401331 2. 深圳大学人工智能学院 深圳 518060

滚动轴承是旋转机械系统的关键部件, 其运行状态直接决定机械设备的安全性及可靠性^[1-2]. 在航空航天、轨道交通及制造业等关键工业领域, 轴承失效常引发严重的连锁损坏与经济损失^[3-5]. 因此, 准确识别轴承运行状态并实现早期故障诊断, 一直是工业生产与智能制造领域的重要研究课题^[6-7].

传统的故障诊断方法遵循“特征提取–机器学习分类”的范式. 该过程首先利用时域、频域或时频

1. College of Physics and Optoelectronic Engineering, Chongqing Normal University, Chongqing 401331 2. School of Artificial Intelligence, Shenzhen University, Shenzhen 518060

域技术 (如小波变换^[8]、经验模态分解^[9-11]、变分模态分解^[12]等) 从轴承振动信号中提取故障特征; 随后, 将这些特征输入 K 最近邻^[13]、支持向量机^[14]或核极限学习机^[15]等浅层机器学习模型中进行故障识别, 并常辅以智能优化算法^[16-18]来提升泛化能力. 然而, 传统方法存在两大局限: 一是关键特征的选取高度依赖专家先验知识, 过程繁琐且耗时; 二是浅层模型的特征表达能力有限, 在噪声干扰和时变工况等复杂条件下性能不佳. 因此, 故障诊断领域正转向数据驱动的智能方法.

深度学习模型凭借其强大的端到端特征学习能力, 能够自动地从原始振动信号中提取并表征故障模式, 极大地推动了故障诊断技术的进步^[19-21]. 例如, 基于深度一维卷积神经网络的方法^[22]及一维与二维联合卷积结构^[23], 均在原始信号的自适应特征学习上取得了显著成效. 尽管卷积神经网络取得了成功, 但其固有的局限性依然明显. 首先, 卷积操作的固定感受野使其难以捕捉不同频率分量的动态变化; 其次, 实际工业场景中主要表现为复杂的环境噪声干扰及非平稳工况, 这种高强度的背景噪声往往会淹没故障冲击特征, 导致常规深度学习模型的特征提取能力失效, 鲁棒性普遍下降, 诊断精度亦随之降低.

为应对上述挑战, 提升模型在复杂工况下的特征鲁棒性, 研究者们从多个方向展开探索. 一方面, 针对单一尺度卷积核难以捕捉丰富特征的问题, Shao 等^[24]提出多尺度深度卷积神经网络 (MSD_CNN), 通过构建多尺度级联卷积核来并行提取不同分辨率的特征, 并引入数据增强策略以应对强噪声环境; Chang 等^[25]则尝试在 ResNet 中引入卷积注意力模块来优化特征权重. 然而, 上述改进仍主要局限于时域特征的提取, 缺乏对频域物理信息的显式建模, 且在极端噪声下仅靠数据增强或局部线性映射难以完全消除干扰特征的影响. 另一方面, 为突破单域学习的局限性, 多视图特征融合成为新的研究方向^[26-28]. 通过融合时域、频域或小波域的互补信息, 模型对非平稳信号的表达能力得以增强^[29]. 然而, 大多数融合方法在特征提取后仅进行简单的拼接或平均, 这属于静态融合策略, 缺乏有效的域间信息交互与自适应调节机制. 特别是在高噪声环境下, 固定的融合权重易引入冗余噪声, 甚至削弱关键特征. 因此, 如何实现跨域特征流的动态协同, 是当前多域诊断研究的关键挑战之一^[30-31].

与此同时, 滚动轴承的振动信号本质上是复杂的时序数据. 独立于上述基于 CNN 的特征提取研究, 另一类方法侧重于利用时序模型捕获其动态依

赖关系. 传统循环神经网络难以捕捉长距离依赖, 作为其改进结构, LSTM^[32]与 GRU 引入门控机制, 通过在细胞状态传输中构建类残差的加法路径, 使得梯度能够在长时间步中维持稳定, 从而有效缓解梯度消失问题. 然而, 此类串行循环架构在处理超长序列时, 仍难以在计算效率与全局时序特征提取之间取得平衡. Transformer 架构的兴起^[33]为全局依赖建模带来新思路, 但纯 Transformer 结构缺乏循环记忆与门控机制, 对局部动态变化的敏感性不足. Li 等^[34]提出 Dconformer 模型, 通过并行集成多尺度 CNN 与 Transformer 分支, 实现兼顾局部特征与全局依赖. 尽管该模型结合了两者优先, 但其去噪与特征提取分支相对独立, 且在处理长序列时计算复杂度较高, 缺乏针对非平稳信号局部时变特性的动态门控记忆机制.

针对上述多域特征融合不充分与时序建模抗噪性差的双重挑战, 本文提出一种双域抗噪编码与协同注意力混合解码 (dual-domain anti-noise encoder with co-attention hybrid decoder, DDAE-CAHD Net) 的轴承故障诊断模型. 该模型在结构上实现了抗噪特征学习与跨域动态融合的统一. 在编码阶段, 模型构建了双域抗噪编码器 (dual-domain anti-noise encoder, DDAE), 该编码器并行集成时域残差收缩分支与可微分小波卷积分支, 在时域和波域中同步提取自适应抗噪特征. 随后, 在融合阶段, 设计双流协同注意力模块, 利用双向注意力与门控调节策略, 实现跨域特征流的动态协同与自适应权重分配. 最后, 在解码阶段, 提出门控循环 Transformer (gated recurrent Transformer, GRT) 解码器, 其在单一单元内深度融合了 Transformer 的全局建模能力与 GRU 的时序记忆机制. 此设计既保持了全局依赖建模优势, 也强化了对局部时序变化的敏感性. 该模型通过端到端的联合优化, 实现了从多域特征提取到协同时序建模的统一学习, 显著提升了在高噪声和非平稳环境下的诊断鲁棒性.

1 方法

滚动轴承的振动信号天然蕴含着时域的瞬态冲击特性与波域的频率分布特征. 然而, 在复杂工业工况下, 高频噪声易掩盖时域模式, 同时负载扰动亦会导致频率结构漂移. 传统的单域学习模型 (如 CNN 或 Transformer) 由于缺乏跨域协同机制, 难以在结构层面同时实现高效的噪声抑制与多域信息协同表达.

为此, 本文提出一种“双域自适应特征提取与

协同门控循环 Transformer”模型 (DDAE-CAHD Net). 该模型针对传统方法在强噪声下特征表达退化、时序建模割裂及域间融合缺乏动态性的核心痛点, 构建一种双通道多域编码与协同时序解码的深度结构. 此设计旨在使模型在特征层、时序层和信息流层分别具备卓越的抗噪性、记忆性与协同性.

该模型的整体结构如图 1 所示, 其核心架构由三大关键组件构成: DDAE、跨域协同注意力融合 (co-attention fusion, CAF) 模块与 GRT 解码器. 在数据流层面, 输入信号首先并行送入 DDAE 的两个分支 (时域收缩分支和波域卷积分支), 以同步提取抗噪时域特征与多尺度波域特征. 随后, CAF 模块通过计算两域间的相互依赖关系与动态权重, 实现跨域特征流的双向交互与门控融合. 最后, 融合后的特征序列被送入 GRT 解码器, 该解码器通过深度耦合循环门控与全局自注意力, 实现了全局依赖与局部时序动态的统一建模. 最终, 输出层采用全连接与 Softmax 结构, 生成轴承健康状态的类别预测. 上面所提各个模块在下文中依次进行介绍.

1.1 双域抗噪编码器

传统 CNN 依赖固定的卷积核在时域中提取局部特征. 然而, 当信号存在噪声时, 其卷积输出中的噪声分量易与故障特征频带重叠, 进而导致特征表达能力退化. 此外, 仅依赖单一时域特征难以捕捉信号的多尺度频率结构. 因此, 本文构建一个并行的双分支架构, 即时域收缩分支和波域卷积分支. 该设计旨在时域抑噪的同时, 提取丰富的频域模式

特征, 从而实现双域优势互补.

1) 时域收缩分支

受残差收缩网络思想的启发, 本文设计时域收缩分支. 该架构的核心思想是在残差学习路径中深度嵌入一个自适应软阈值模块, 如图 2 所示. 该模块的工作流程如下: 首先, 模块需要获取每个特征通道的全局信息, 即动态感知其整体响应. 这一步通过式 (1) 的全局平均池化来实现, 将输入特征 F_c 压缩为全局统计信息 s . 其中, L 为该一维特征序列长度.

$$s = \frac{1}{L} \sum_{i=1}^L F_c(i) \quad (1)$$

获得全局信息 s 后, 该模块通过式 (2) 所示的“瓶颈”结构来计算一组可学习的门控系数 θ . 其中, W_1 和 W_2 分别为两个全连接层的权重矩阵; δ 表示 ReLU 激活函数; σ 表示 Sigmoid 激活函数. 输出的门控系数 (0 到 1 之间) 代表了每个通道的重要性或信噪比.

$$\theta = \sigma(W_2 \delta(W_1 s)) \quad (2)$$

进而, 该模块会据此自动生成最优阈值 τ , 这与使用固定阈值的方式不同. 如式 (3) 所示, 这个自适应阈值 τ 是由上一步得到的门控系数 θ 与该通道特征的平均幅度 $\text{Mean}(|F_c|)$ 逐元素相乘得到的. 其中, 符号“ $\odot$ ”表示逐元素相乘.

$$\tau = \theta \odot \text{Mean}(|F_c|) \quad (3)$$

最后, 模块利用为每个通道定制的阈值 τ , 自适




图 1 模型总体框架示意图

Fig.1 Schematic diagram of the overall framework of the model




图 2 时域收缩分支结构图

Fig. 2 Structure diagram of the time-domain shrinkage branch

应地收缩那些由噪声主导的特征响应. 这个操作由式 (4) 所示的软阈值函数完成, 它将小于 τ 的特征归零, 并对大于 τ 的特征进行收缩, 得到最终去噪后的特征 F_t .

$$F_t = \text{sign}(F_c) \odot \max(|F_c| - \tau, 0) \quad (4)$$

通过式 (1) ~ (4) 的这一完整流程, 该分支能够自动地学习噪声水平、智能地生成阈值并精确地执行去噪, 最终在端到端的学习中具备了强大的抗噪能力与特征辨识力.

2) 波域卷积分支

考虑到单一的时域分支难以全面捕获振动信号中丰富的多尺度频率特征, 因此本文设计了波域卷积分支, 如图 3 所示. 该分支引入可微分离散小波

变换 (differentiable discrete wavelet transform, DWT) 操作, 其核心思想是将信号分解为多尺度的时频表征, 从而捕获时域分支所忽略的、具有高辨识度的频率信息, 具体的工作流程如下.

首先, 模块对输入信号 X 进行多尺度分解, 这一步通过式 (5) 所示的 DWT 操作来实现, 即利用低通滤波器 $g_{\downarrow 2}$ 与高通滤波器 $l_{\downarrow 2}$ 分别生成低频近似分量 cA 与高频细节分量 cD .

$$\begin{cases} cA = X * g_{\downarrow 2} \\ cD = X * l_{\downarrow 2} \end{cases} \quad (5)$$

其中, g, l 分别为低通与高通小波滤波器; $*$ 表示卷积; $\downarrow 2$ 表示下采样操作.




图 3 波域卷积分支结构图

Fig. 3 Structure diagram of the wavelet-domain convolution branch

获得低频与高频分量后, 模块通过式 (6) 所示的两个独立卷积通道 Conv1D 对其进行并行的深度特征提取, 分别得到特征表征 F_a 和 F_d .

$$\begin{cases} F_a = \text{Conv1D}(cA) \\ F_d = \text{Conv1D}(cD) \end{cases} \quad (6)$$

进而, 该分支采用自适应加权策略对上述特征进行融合, 以获得最终的多尺度波域特征 F_w . 如式 (7) 所示, 该特征融合是由一个在训练过程中可学习的权重系数 $\alpha \in [0, 1]$ 与两个通道的特征 F_a 、 F_d 进行加权求和得到的.

$$F_w = \alpha F_a + (1 - \alpha) F_d \quad (7)$$

通过式 (5) ~ (7) 的这一完整流程, 该分支能够借助多层小波分解实现对信号频域特征的层次化表达, 并在保持可微性的同时实现了多尺度自适应的特征融合.

1.2 跨域协同注意力融合模块

尽管双域特征各自具备强判别性, 但二者的信息分布不同, 若直接拼接会造成特征空间冲突. 为此, 本文提出双流协同注意力模块. 该架构的核心思想是在时域与波域之间建立动态的交互依赖关系, 并利用门控机制来控制双向信息流动的比例, 从而使融合过程具备自适应性与协同性, 如图 4 所示. 具体的工作流程如下:

首先, 模块需要利用时域特征 F_t 和波域特征 F_w 进行双向的交互查询, 以捕获彼此的上下文信息. 这一步通过式 (8) 所示的缩放点积注意力机制来完成, 即分别以对方的特征作为“键” (K) 和“值” (V), 计算出时域对波域的注意力图 A_t 和波域对时域的注意力图 A_w .

$$\begin{cases} A_t = \text{Softmax} \left(\frac{(F_t W_Q^{co})(F_w W_K^{co})^T}{\sqrt{d}} \right) F_w W_V^{co} \\ A_w = \text{Softmax} \left(\frac{(F_w W_Q'^{co})(F_t W_K'^{co})^T}{\sqrt{d}} \right) F_t W_V'^{co} \end{cases} \quad (8)$$

其中, W_Q^{co} 、 W_K^{co} 、 W_V^{co} 以及 $W_Q'^{co}$ 、 $W_K'^{co}$ 、 $W_V'^{co}$ 均为模型在训练过程中可学习的注意力映射矩阵. 具体而言, W_Q^{co} 用于提取时域特征的查询表示, 而 W_K^{co} 和 W_V^{co} 用于提取波域特征的键和值表示; 同理, $W_Q'^{co}$ 、 $W_K'^{co}$ 和 $W_V'^{co}$ 则实现了相反方向的特征空间投影. 此外, d 为特征通道的维度, 作为缩放点积注意力机制的缩放因子, 用于平滑 Softmax 函数的梯度.

获得交互注意力图 A_t 和 A_w 后, 模块通过式 (9) 所示的门控机制来计算自适应的融合比例. 如式 (9) 所示, 该门控系数 G_t 和 G_w 是由各自的原始特征 (F_t 、 F_w) 与交互特征 (A_t 、 A_w) 进行拼接 ($[\cdot; \cdot]$) 后, 经全连接层 (W_g 、 W_g') 与 Sigmoid 激活函数 σ 得到的.

$$\begin{cases} G_t = \sigma(W_g[F_t; A_t]) \\ G_w = \sigma(W_g'[F_w; A_w]) \end{cases} \quad (9)$$

进而, 模块利用该门控系数, 通过式 (10) 所示的残差融合方式, 对原始特征和交互特征进行加权求和. 这个操作实现了对原始信息的保留和对交互信息的动态补充, 最终得到增强后的时域特征 $\hat{F}_t$ 和波域特征 $\hat{F}_w$.

$$\begin{cases} \hat{F}_t = (1 - G_t) \odot F_t + G_t \odot A_t \\ \hat{F}_w = (1 - G_w) \odot F_w + G_w \odot A_w \end{cases} \quad (10)$$

最后, 模块将两个域中已充分交互并增强的特征 $\hat{F}_t$ 和 $\hat{F}_w$ 进行逐元素相加, 得到最终的融合特征




图 4 跨域协同注意力融合结构图

Fig.4 Structure diagram of the cross-domain co-attention fusion

F_{fusion} , 这个操作如式 (11) 所示.

$$F_{fusion} = \hat{F}_t + \hat{F}_w \quad (11)$$

通过式 (8) ~ (11) 的这一完整流程, 该机制使模型能够在不同噪声水平与工况条件下, 动态地分配时域与波域特征的权重, 实现跨域协同增强.

1.3 门控循环 Transformer 解码器

传统 Transformer 虽在全球依赖建模方面表现优异, 但其设计缺乏循环记忆机制, 导致对局部时序动态不敏感. 考虑到 GRU 虽能捕获时间相关性, 却在长程依赖中存在信息衰减, 为此本文设计门控循环 Transformer 解码器, 结构示意参见图 5.




图 5 门控循环 Transformer 示意图

Fig.5 Schematic diagram of the gated recurrent Transformer

该架构的核心思想是在单一模块中深度融合 Transformer 的全局注意力与 GRU 的门控记忆机制, 使模型能够同时建模短期局部动态和长期全局依赖, 具体实现流程如下.

首先, 模块需要对输入的融合特征序列 $F_{fusion} = [f_1, f_2, \dots, f_L]$ 进行全局上下文建模. 这一步通过式 (12) 所示的自注意力层来实现, 即计算查询 (Q)、键 (K) 和值 (V), 输出融合了全局上下文信息的特征 H_t .

$$H_t = \text{Softmax} \left(\frac{Q_t K^T}{\sqrt{d}} \right) V \quad (12)$$

其中, $Q_t = f_t W_Q^{grt}$; $K = F_{fusion} W_K^{grt}$; $V = F_{fusion} \times W_V^{grt}$. f_t 表示输入的融合特征序列 F_{fusion} 在第 t 个时间步的特征向量; W_Q^{grt} 、 W_K^{grt} 和 W_V^{grt} 分别表示在门控循环 Transformer 的自注意力机制中, 用于将输入特征线性投影至查询、键和值特征空间的可学习权重矩阵.

获得全局上下文特征 H_t 后, 模块通过式 (13) 和式 (14) 所示的 GRU 门控循环单元, 结合上一时刻的隐藏状态 h_{t-1} 来更新当前状态. 如式 (13) 所示, 该模块首先计算更新门 z_t 和重置门 r_t .

$$\begin{cases} z_t = \sigma(W_z[H_t; h_{t-1}]) \\ r_t = \sigma(W_r[H_t; h_{t-1}]) \end{cases} \quad (13)$$

其中, W_z 与 W_r 分别表示门控循环单元中的更新门和重置门的可学习权重矩阵.

进而, 模块利用这些门控信号来计算当前的隐藏状态 h_t . 这个操作由式 (14) 所示的计算 (候选状态 $\tilde{h}_t$) 与更新 (最终状态 h_t) 完成, 使得当前时刻的隐藏状态 h_t 既依赖于当前的全局注意力 H_t , 也保留了历史状态 h_{t-1} 的信息.

$$\begin{cases} \tilde{h}_t = \tanh(W_h[H_t; r_t \odot h_{t-1}]) \\ h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \end{cases} \quad (14)$$

其中, W_h 表示门控循环单元中用于计算候选状态的可学习权重矩阵.

随后, 模块需要将所有时间步的输出 h_t 聚合为最终的特征表示 z , 这个操作通过式 (15) 所示的全局平均池化来完成.

$$z = \frac{1}{L} \sum_{t=1}^L h_t \quad (15)$$

最后, 将该聚合特征 z 输入式 (16) 所示的 Softmax 分类器中, 得到最终的故障分类概率 $\hat{y}$.

$$\hat{y} = \text{Softmax}(W_c z + b_c) \quad (16)$$

其中, W_c 和 b_c 分别表示 Softmax 分类器的可学习权重矩阵和偏置向量.

通过式 (12) ~ (16) 的这一完整流程, 该解码器实现了动态的时序记忆, 使模型能够在捕获全局依赖的同时, 根据历史状态自适应地更新当前特征.

1.4 网络训练与优化策略

模型以交叉熵作为目标函数, 其表达式为:

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^c y_{i,j} \ln(\hat{y}_{i,j}) \quad (17)$$

其中, $y_{i,j}$ 表示第 i 个样本属于第 j 个故障类别的

真实标签指示函数; N 为参与计算的样本总数; c 为故障类型的总类别数; $\hat{y}_{i,j}$ 则是模型预测该样本属于第 j 类的概率值。

优化器采用 Adam, 学习率采用分段衰减策略以防止过拟合。模型端到端训练, 编码器、融合模块与解码器参数同步更新, 确保自适应抗噪特征与时序记忆特征的联合最优。

2 实验与分析

为验证本文所提 DDAE-CAHD Net 模型在滚动轴承故障诊断, 特别是在强噪声环境下的有效性和鲁棒性, 本节基于凯斯西储大学 (CWRU) 轴承数据集与帕德博恩大学 (PU) 轴承数据集进行一系列实验, 包括标准工况下的模型性能验证以及重点评估抗噪性能的消融实验和对比实验。

实验硬件环境为 Intel Core i5-9300K CPU 和 NVIDIA GeForce RTX 1650 4 GB GPU, 软件环境为 Windows11 操作系统, 基于 PyTorch 框架 (Python 3.8.18, CUDA 12.9) 搭建模型。

在模型训练阶段, 批处理大小设置为 64, 训练周期设置为 100, 优化器选用 Adam, 初始学习率设置为 0.000 1, 并采用交叉熵作为损失函数。模型的详细结构参数设置如表 1 所示。每种方法都进行 11 次训练和测试, 并取模型准确率排名的中位数, 以避免单次训练和测试产生过高或过低的误差, 确保研究结果的准确性和可靠性。

表 1 模型参数
Table 1 Model parameters

层名称	滤波 器数	卷积核大 小/步长	单元数	输入 大小	输出 大小	激活 函数
卷积层 1	50	20/2	—	1×2000	50×991	tanh
小波变换 1	—	—	—	50×991	100×495	—
卷积层 2	30	10/2	—	100×495	30×243	tanh
小波变换 2	—	—	—	30×243	60×121	—
卷积层 3	50	6/1	—	60×121	50×116	tanh
自适应池化 1	—	—	—	50×116	1×128	—
残差收缩块 1	64	7/2	—	1×2000	64×1000	ReLU
残差收缩块 2	128	7/2	—	64×1000	128×500	ReLU
残差收缩块 3	128	7/1	—	128×500	128×500	ReLU
自适应池化 2	—	—	—	128×500	1×128	—
协同注意力	—	—	4	2×1×128	1×128	—
门控循环	—	—	4	1×128	1×128	—
Transformer 1	—	—	4	1×128	1×128	—
门控循环	—	—	4	1×128	1×128	—
Transformer 2	—	—	4	1×128	1×128	—
全局池化	—	—	10	1×128	1×128	—
Dropout 层	—	—	—	1×128	1×128	—
全连接层	—	—	—	1×128	1×10	Softmax

为模拟真实的工业工况, 并评估模型在数据归一化后的抗噪性能, 本实验在原始信号中引入不同信噪比 (signal-to-noise ratio, SNR) 的高斯白噪声。信噪比的定义如式 (18) 所示:

$$\text{SNR} = 10 \lg \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \tag{18}$$

式中, P_{signal} 和 P_{noise} 分别代表原始信号的功率和所添加噪声的功率。

为直观展示强噪声环境对轴承振动信号的显著影响, 并验证本文模拟工业真实工况的有效性, 图 6 呈现了四种典型健康状态 (内圈故障、外圈故障、滚动体故障及正常状态) 在原始条件下与添加高斯白噪声 (信噪比为 -10 dB) 后的时域及频域波形对比。由图可见, 在原始信号中, 各类故障通常表现出显著的周期性冲击特征或特定的频率峰值。然而, 在引入强噪声干扰后, 时域波形中的周期性冲击近乎被完全淹没, 信号呈现出无序的随机波动状态; 同时, 频域中的关键故障特征频率亦被大幅掩盖, 致使通过目视观察或常规频谱分析难以有效辨识。这种显著的特征淹没现象有力地证实了在复杂强噪声工况下, 开发具备深度抗噪与鲁棒特征提取能力的诊断模型的必要性。

2.1 凯斯西储大学数据集的故障识别

2.1.1 轴承数据集说明

本实验采用国际通用的凯斯西储大学 (CWRU) 轴承数据集^[35]进行模型验证。该数据集实验台主要由 2 马力的电动机、功率计、扭矩传感器和电子控制装置组成。

实验轴承型号为 SKF6205, 通过电火花加工技术在滚动体、内圈和外圈制造了三种不同直径 (0.178 mm、0.356 mm 和 0.533 mm) 的缺陷, 加上正常状态, 共构成了 10 种轴承健康状态。

本实验使用驱动端加速度计采集的数据, 采样频率为 12 kHz; 电机负载为 3 马力, 转速为 1 730 转/分钟。每种健康状态选取 240 个样本, 每个样本由 2 000 个连续采样点构成。数据集按照 6:2:2 的比例划分为训练集、验证集和测试集。详细的故障样本信息如表 2 所示。

2.1.2 模型性能验证

首先, 在无噪声的标准 CWRU 数据集上对所提 DDAE-CAHD Net 模型进行训练与测试, 其分类结果及训练过程分别如图 7 和图 8 所示。图 7 展示了模型在测试集上的混淆矩阵, 矩阵对角线上的数值表明, 模型对全部 10 种健康状态 (标签 0 ~ 9)




图 6 原始信号与 -10 dB 信噪比下的信号对比 ((a) 内圈故障; (b) 外圈故障; (c) 滚动体故障; (d) 正常状态)

Fig.6 Signal comparison (original vs -10 dB SNR) ((a) Inner race fault; (b) Outer race fault; (c) Rolling element fault; (d) Normal state)

表 2 故障样本信息

Table 2 Fault sample information

轴承状态	标签	故障尺寸 (mm)	样本数 (个)	数据长度	负载区
滚动体故障	0	0.178	240	2000	—
滚动体故障	1	0.356	240	2000	—
滚动体故障	2	0.533	240	2000	—
内圈故障	3	0.178	240	2000	—
内圈故障	4	0.356	240	2000	—
内圈故障	5	0.533	240	2000	—
正常状态	6	—	240	2000	—
外圈故障	7	0.178	240	2000	6:00
外圈故障	8	0.356	240	2000	6:00
外圈故障	9	0.533	240	2000	6:00

均实现了 100% 的正确分类, 且非对角线元素均为 0. 这证实了在标准工况下, 所提模型对不同类型及不同程度的轴承故障具备卓越的识别与区分能力. 由图 8 可知, 模型收敛迅速, 训练准确率与验证准确率在约 10 个迭代次数后均快速逼近 100%, 且训练全程未出现过拟合现象.

为进一步验证模型在特征提取层面的有效性, 图 9 对比了原始数据与经 DDAE-CAHD Net 解码器输出层提取特征的 t-SNE 可视化分布. 如图 9(a) 所示, 原始信号在降维空间中高度重叠, 各类样本严重混杂、难以区分. 相比之下, 如图 9(b) 所示, 经




图 7 混淆矩阵

Fig.7 Confusion matrix

过本文模型处理后, 10 种故障类型的特征呈现出显著的“类内高聚合、类间高分离”特性, 各类别间形成界限清晰的独立簇.

为避免仅凭视觉观察的主观性, 本文引入类间距离、类内距离、分离度及轮廓系数四个指标, 对原始特征与模型学习特征进行定量评价, 结果如表 3 所示. 由表 3 可知, 原始信号的类内距离高达 35.84, 分离度仅为 0.24, 且轮廓系数为负值 (-0.19), 这从




图 8 模型训练准确率和损失值曲线

Fig.8 Model training accuracy and loss curves

量化角度解释了图 9(a) 中各类别相互交叠的原因. 经 DDAE-CAHD Net 特征提取后, 学习特征的类内距离大幅降低至 1.60 (降幅约 95.5%), 类间距离则增至 16.73, 促使整体分离度显著提升至 10.48. 此外, 轮廓系数提升至 0.86 (接近理想值 1), 表明同类样本高度凝聚且异类样本分离良好. 上述量化指标的显著改善充分证明了本文模型能够将原本线性不可分的原始信号映射至高判别力的特征空间, 从特征层面保障了模型的高诊断精度.

2.1.3 消融实验分析

为深入验证本文所提模型中关键组件的有效性 与必要性, 特别是 DDAE、CAF 模块以及 GRT 解码器在恶劣噪声环境下的具体作用, 本节在信噪比为 -10 dB 的强噪声环境下进行消融实验, 并且构建了如下 9 组变体模型以逐步验证架构设计的合理性.

1) A0: 仅使用时域卷积网络配合全局平均池化, 作为基准对照.

2) A1-T: 仅保留 DDAE 中的时域收缩分支, 验证深度残差收缩网络的抗噪能力.

3) A1-W: 仅保留 DDAE 中的波域卷积分支, 验证频域特征提取的贡献.

4) A2: 同时使用时域和波域分支, 但在特征提取后仅进行简单的拼接, 不包含注意力交互.

5) A3-T2W: 引入单向跨域注意力机制, 仅使用时域特征来校准小波域特征, 不包含门控.

6) A3-W2T: 引入单向跨域注意力机制, 仅使用小波域特征来校准时域特征, 不包含门控.

7) A3-BI: 引入双向跨域注意力机制, 时域与小波域特征相互校准, 但采用直接残差相加而非自适应门控融合.

8) A4: 引入完整的带门控机制的双向协同注意力融合.

9) A5: 完整模型, 包含上述所有模块及门控循环 Transformer 解码器.

如表 4 所示, 消融实验的结果清晰揭示了模型性能随关键组件逐步引入而稳步提升的演进趋势, 充分验证了 DDAE-CAHD Net 架构设计的合理性. 具体而言, 基线模型 A0 在强噪声环境下准确率仅为 61.37%, 暴露了单一时域卷积网络在极端干扰下特征提取能力的局限. 引入深度残差收缩网络 (A1-T) 和小波分支 (A1-W) 后, 准确率分别显著提升至 80.43%




图 9 原始数据与模型处理后数据的可视化

Fig.9 Visualization of raw data and model-processed data

表 3 特征评价指标
Table 3 Feature evaluation metrics

特征类型	类间距离	类内距离	分离度	轮廓系数
原始特征	8.62	35.84	0.24	-0.19
学习特征	16.73	1.60	10.48	0.86

表 4 消融实验准确率对比 (%)
Table 4 Accuracy comparison in ablation experiment (%)

模型	准确率
A0	61.37
A1-T	80.43
A1-W	78.92
A2	88.19
A3-T2W	92.24
A3-W2T	91.62
A3-BI	93.60
A4	95.51
A5	96.80

和 78.92%; 而结合二者的 A2 模型进一步将准确率推高至 88.19%, 初步证实了时域降噪与频域特征挖掘之间存在显著的互补优势. 在此基础上, 跨域交互机制的引入实现了性能的再次跃升, 优于 A2 模型对双域特征的简单拼接. 其中, 双向交互模型 A3-BI 以 93.60% 的准确率超越了单向交互变体 (A3-T2W 的 92.24% 与 A3-W2T 的 91.62%), 有力证明了时频双向校准策略能有效增强特征的鲁棒性. 随后, A4 模型通过引入自适应门控机制动态过滤交互中的冲突与冗余信息, 将准确率进一步提升至 95.51%. 最终, 完整模型 A5 集成了门控循环 Transformer 解码器, 利用其结合 GRU 循环特性与 Transformer 全局注意力的长距离时序建模能力, 取得了 96.80% 的最高准确率, 确凿证明了各模块协同工作对于实现高精度故障诊断的必要性.

2.1.4 对比实验分析

为验证 DDAE-CAHD Net 模型的有效性, 本实验将其与 1D-CNN、ResNet、Dconformer 以及

MSD_CNN 等深度学习模型进行对比, 并基于 CWRU 数据集测试各模型在不同噪声环境下的诊断性能.

由表 5 可知, 随着信噪比从 -10 dB 逐步提升至 4 dB, 各对比模型的识别准确率整体呈上升趋势, 表明噪声强度的降低能普遍改善特征的可分性. 然而, 不同模型在强噪声条件下的性能差异十分显著, 尤其在 -10 dB 与 -8 dB 等极端噪声环境中, 这种差距被明显放大. 具体而言, 1D-CNN 与 ResNet 在强噪声下性能退化最为严重, 在 -10 dB 时准确率分别仅为 61.37% 和 72.48%. 这表明仅依赖单一时域卷积或常规残差表征时, 故障冲击信息极易被噪声淹没, 导致判别能力不足. Dconformer 与 MSD_CNN 虽引入了更强的全局建模或多尺度特征提取机制, 在中/高信噪比下表现较优, 但在极强噪声下仍存在性能瓶颈. 例如在 -10 dB 时, 二者的准确率分别为 79.94% 与 86.37%, 仍难以保证稳定可靠的诊断结果.

相比之下, DDAE-CAHD Net 在全信噪比范围内均保持领先, 且其优势主要体现在强噪声工况下的鲁棒性提升上. 在 -10 dB 时, 本文方法准确率高达 96.80%, 相较于 MSD_CNN、Dconformer、ResNet 与 1D-CNN 分别提升 10.43、16.86、24.32 与 35.43 个百分点; 在 -8 dB 时, 本文方法仍达到 98.75%, 相比 MSD_CNN 与 Dconformer 分别提升 8.43 与 11.54 个百分点. 随着噪声减弱至 -4 dB 及以上, 各模型准确率逐渐趋于饱和, 但 DDAE-CAHD Net 仍保持最优或并列最优, 在 0 dB 与 4 dB 条件下均达到 100.00%. 这充分体现了本文方法在低噪声场景下不牺牲精度、在高噪声场景下显著增强抗干扰能力的特性. 从准确率随噪声变化的稳定性来看, DDAE-CAHD Net 从 -10 dB 到 4 dB 的准确率极差仅为 3.20% (96.80%→100.00%), 而 MSD_CNN、Dconformer、ResNet 与 1D-CNN 的波动幅度分别为 12.80%、19.12%、22.37% 与 22.43%. 这进一步说明本文方法对噪声水平变化不敏感, 具有更稳定的跨工况泛化表现, 更符合真实

表 5 对比实验结果
Table 5 Comparative experiment results

模型	参数量	训练时间 (s)	-10 dB	-8 dB	-4 dB	0 dB	4 dB
1D-CNN	117 722	43.51	61.37%	70.23%	78.72%	82.11%	83.80%
ResNet	111 402	52.07	72.48%	80.66%	91.35%	93.92%	94.85%
Dconformer	706 371	213.00	79.94%	87.21%	97.88%	98.84%	99.06%
MSD_CNN	303 837	90.82	86.37%	90.32%	98.44%	99.03%	99.17%
DDAE-CAHD Net	1 104 890	234.93	96.80%	98.75%	99.58%	100.00%	100.00%

工业场景中噪声强度未知或动态变化的应用需求。

此外,表 5 还列出了模型复杂度与训练开销的对比结果。DDAE-CAHD Net 的参数量为 1 104 890,训练时间为 234.93 s,虽高于轻量级的 1D-CNN 与 ResNet,也略高于 Dconformer 与 MSD_CNN,但这一复杂度的增加带来了强噪声段显著的性能收益。特别是相对于训练时间较为接近的 Dconformer,本文方法在 -10 dB 下获得 16.86 个百分点的准确率提升,说明其在“训练代价-鲁棒性收益”的权衡上更具优势。综合上述结果可认为,DDAE-CAHD Net 通过对噪声抑制与判别特征增强的协同建模,能够在强噪声下有效保留故障敏感信息,并提升跨域特征互补效果,从而显著提升了低信噪比工况下的诊断准确率与整体鲁棒性。

2.1.5 小样本实验分析

为深入探究模型在数据受限场景下的泛化性能,并验证其对大规模训练样本的依赖程度,本节设计一组不同训练集占比的梯度对比实验。实验将数据集的划分比例(训练集:验证集:测试集)从样本极为稀缺的 1:2:2 逐步调整至标准的 6:2:2,以模拟工业场景中从“小样本”到“足量样本”的变化过程,实验结果如图 10 所示。




图 10 实验结果对比
Fig.10 Comparison of experimental results

观察准确率曲线可知,尽管所有模型的性能均随训练样本量的减少而呈现下降趋势,但各模型对数据的敏感度差异显著。在最为严苛的 1:2:2 划分工况下(即仅利用 20% 的样本进行训练),基础模型如 1D-CNN 的特征提取能力出现严重退化,准确率大幅跌至 62% 左右;ResNet 与 Dconformer 亦表现出明显的性能瓶颈。相比之下,本文提出的 DDAE-CAHD Net 在此极端小样本条件下仍展现出极高的鲁棒性,保持了超过 96% 的诊断准确率。

随着训练比例逐步增加至 6:2:2,该模型的性能平稳提升并趋于饱和(达到 100%)。DDAE-CAHD Net 在低资源条件下的优异表现,主要归功于双域

抗噪编码器的结构优势:纯数据驱动模型通常需要海量数据来拟合特征分布,而本模型引入了归纳偏置机制,其波域分支利用小波变换提供了频率先验知识,配合时域分支的自适应阈值降噪,使其能够在有限样本下快速锁定关键故障特征。这种设计显著降低了模型对标注数据规模的依赖,使其更适应故障样本稀缺的实际工业环境。

2.2 帕德博恩大学数据集的故障识别

2.2.1 轴承数据集说明

帕德博恩大学(PU)轴承数据集涵盖人工损伤与真实损伤两种类型。为更贴近实际工业场景,本研究选用由加速寿命试验台产生的真实损伤数据作为研究对象。该试验台主要由驱动电机和测试轴承座组成。尽管原始数据集包含不同转速、负载扭矩和径向力等多种工况设置,但是为控制变量,本实验选取同一工况下的振动信号作为模型输入。在数据预处理阶段,为便于建模与对比分析,本文采用滑动窗口技术构建数据集。针对每种健康或故障状态,分别截取 500 个样本,每个样本包含 2 000 个采样点,共构建了包含 6 类状态的数据集。随后,将数据集按 6:2:2 的比例随机划分为训练集、验证集和测试集。各类别的故障类型与损伤详情如表 6 所示,具体涵盖:健康状态、外圈疲劳点蚀(单一损伤,1 级)、外圈塑性变形压痕(单一损伤,1 级)、内/外圈塑性变形压痕(多重损伤,2 级)以及内圈疲劳点蚀(单一损伤,1 级/3 级)。

表 6 故障样本信息
Table 6 Fault sample information

类别	状态描述	故障位置	损伤组合	损伤程度	样本数	数据长度
1	健康	—	—	—	500	2000
2	疲劳:点蚀	外圈	单一损伤	1	500	2000
3	塑性变形:压痕	外圈	单一损伤	1	500	2000
4	塑性变形:压痕	内圈/外圈	多重损伤	2	500	2000
5	疲劳:点蚀	内圈	单一损伤	3	500	2000
6	疲劳:点蚀	内圈	单一损伤	1	500	2000

2.2.2 模型性能验证

为评估模型在真实加速寿命试验数据上的适应性,本文在帕德博恩数据集上进行了同样的训练与测试流程。图 11 ~ 图 13 展示了该模型在处理真实损伤信号时的量化指标与定性表征。

尽管真实损伤信号往往伴随着复杂的环境噪声与不规则的冲击模式,但是 DDAE-CAHD Net 依然展现出优异的收敛特性与分类性能。如图 12 所




图 11 混淆矩阵

Fig.11 Confusion matrix

示, 得益于双域编码器对干扰信息的有效抑制, 模型损失值在训练初期呈垂直下降趋势, 并在迭代周期内迅速稳定至全精度水平. 这一高效的学习过程直接映射在图 11 的测试结果中: 模型对单一损伤 (如外圈疲劳点蚀) 及多重损伤 (如内/外圈塑性变形压痕) 均达到了 100% 的识别准确率, 未出现任何跨类别的混淆现象.

这种优越的性能根源于模型对数据分布的重构能力. 如图 13(a) 所示, 由于真实损伤机理的复杂性, 原始数据在低维流形中不仅重叠严重, 且缺乏清晰的拓扑结构. 然而, 经过所提模型的深度特征映射后 (图 13(b)), 六种轴承状态被转化为界限分明、聚类紧凑的特征簇. 这一可视化的特征变换过程, 直观地证实了模型中的协同注意力机制与门控单元能够有效捕捉隐藏在复杂非平稳信号中的关键故障模态, 从而在真实工况下实现高鲁棒性的故障




图 12 模型训练准确率和损失值曲线

Fig.12 Model training accuracy and loss curves

诊断.

2.2.3 对比实验分析

为进一步验证 DDAE-CAHD Net 模型在真实轴承损伤及复杂噪声环境下的泛化性能与鲁棒性, 本节在帕德博恩数据集上, 将该模型与 1D-CNN、ResNet、Dconformer 及 MSD_CNN 等主流深度学习模型进行对比实验. 各模型在 -10 dB 至 4 dB 五种不同信噪比环境下的诊断准确率如表 7 所示. 实验结果表明, 尽管所有模型的识别准确率均随信噪


(a) 原始数据分布
(a) Raw data distribution(b) 分类模型输出
(b) Classification model output

图 13 原始数据与模型处理后数据的可视化

Fig.13 Visualization of raw data and model-processed data

比的提升而呈上升趋势,但 DDAE-CAHD Net 在全工况范围内仍展现出显著的性能优势,尤其在强噪声干扰下表现出极佳的鲁棒性. 具体而言,在 -10 dB 的极低信噪比工况下,传统深度学习模型 1D-CNN 和 ResNet 的准确率分别降至 61.29% 和 69.58%. 这表明,在真实损伤信号与高强度背景噪声混叠的复杂场景中,浅层特征提取机制难以有效捕获关键故障特征. 即便是性能较优的 MSD_CNN 模型,其在 -10 dB 环境下的准确率也仅为 81.77%. 相比之下,本文提出的 DDAE-CAHD Net 在此极端条件下仍保持了 93.96% 的高诊断精度,相较于 1D-CNN 和 MSD_CNN 分别提升 32.67 和 12.19 个百分点. 这一显著优势有力证明了双域抗噪编码器对干扰信息的有效抑制能力,以及跨域协同注意力机制在低信噪比环境下对微弱故障特征的精准提取能力.

表 7 对比实验结果 (%)
Table 7 Comparative experiment results (%)

模型	-10 dB	-8 dB	-4 dB	0 dB	4 dB
1D-CNN	61.29	69.80	82.27	89.75	89.99
ResNet	69.58	76.92	87.09	92.01	92.19
Dconformer	77.37	80.81	88.93	94.79	95.00
MSD_CNN	81.77	85.25	92.71	97.59	97.64
DDAE-CAHD Net	93.96	95.06	98.57	99.31	99.40

此外,随着信噪比提升至 -4 dB 及以上,DDAE-CAHD Net 的优势进一步扩大,展现出优异的收敛性与泛化能力. 在 -4 dB 的较强噪声环境中,所提模型的准确率已攀升至 98.57%,远超过同期的 Dconformer (88.93%) 与 ResNet (87.09%);而在 4 dB 的高信噪比条件下,该模型更是达到了 99.40%,实现了近乎完全准确的分类效果. 与包含人工植入故障的 CWRU 数据集不同,PU 数据集涵盖真实的疲劳点蚀与塑性变形压痕,其特征分布更为复杂且具有非平稳性. 实验数据表明,在 -10 dB 至 4 dB 的宽噪声范围内,DDAE-CAHD Net 的准确率波动幅度控制在 6% 以内,且始终保持在 93% 以上的高水平. 这充分表明,门控循环 Transformer 解码器在处理具有长时序依赖与真实复杂损伤特征的振动信号时,能有效克服环境噪声与工况波动的影响,具备在实际工业场景中实现可靠故障诊断的潜力.

3 结束语

针对强噪声干扰下滚动轴承微弱故障特征难以提取及非平稳工况下特征模态不稳定的难题,本文提出一种基于双域抗噪编码与门控循环 Trans-

former 的诊断模型,并经实验验证了其有效性. 本研究的主要贡献在于构建了双域抗噪编码器,通过并行集成时域残差收缩网络与波域可微分小波卷积,实现了含噪信号的自适应软阈值去噪与多尺度频率解耦,从根本上提升了特征的抗噪性;同时,设计的双域协同注意力机制利用门控交互策略动态调节时域与波域的特征权重,模拟专家诊断中多视图综合判断的过程,有效克服了非平稳工况下的特征失效问题;此外,提出的门控循环 Transformer 解码器在统一特征空间内实现了全局依赖建模与局部时序记忆的深度融合. 实验结果表明,该模型在 -10 dB 的极强噪声环境下仍能保持卓越的诊断精度,展现出优于现有主流深度学习方法的鲁棒性.

尽管本文提出的模型在抗噪性能上取得显著进展,但在实际工业部署层面仍面临挑战,这也指明了未来的研究方向. 一方面,针对当前模型参数量相对较大、难以适应边缘端资源受限环境的问题,未来工作将致力于模型的轻量化研究,探索利用模型剪枝与量化技术压缩模型体积,以实现算法在嵌入式振动传感器节点中的实时运行;另一方面,考虑到实际工业场景中故障样本稀缺且工况多变,后续研究将结合元学习或域适应技术,重点解决跨工况、小样本条件下的模型泛化问题,降低对大规模标注数据的依赖,进一步提升模型在复杂工业现场的实用价值.

参考文献

1 Xin G, Zhong Q T, Jin Y Q, Li Z, Chen Y F, Li Y F, et al. Autonomous bearing fault diagnosis based on fault-induced envelope spectrum and moving peaks-over-threshold approach. *IEEE Transactions on Instrumentation and Measurement*, 2024, **73**: Article No. 3516712

2 Soomro A A, Muhammad M B, Mokhtar A A, Saad M H M, Lashari N, Hussain M, et al. Insights into modern machine learning approaches for bearing fault classification: A systematic literature review. *Results in Engineering*, 2024, **23**: Article No. 102700

3 Ma Z P, Fu L, Dun G, Tan D P, Xu F, Zhang L B. A robust domain distribution alignment discriminative network driven by physical samples for rotor-bearing fault diagnosis. *Knowledge-Based Systems*, 2024, **300**: Article No. 112216

4 Sanjrani A N, Huang H Z, Shah S A, Hussain F, Punhal M, Narejo A, et al. High-speed train wheel set bearing analysis: Practical approach to maintenance between end of life and useful life extension assessment. *Results in Engineering*, 2025, **25**: Article No. 103696

5 Ayman A, Onsy A, Attallah O, Brooks H, Morsi I. Feature learning for bearing prognostics: A comprehensive review of machine/deep learning methods, challenges, and opportunities. *Measurement*, 2025, **245**: Article No. 116589

6 Li X, Ma Z Q, Yuan Z H, Mu T M, Du G X, Liang Y, et al. A review on convolutional neural network in rolling bearing fault diagnosis. *Measurement Science and Technology*, 2024, **35**(7): Article No. 072002

7 Chen X H, Yang R, Xue Y H, Huang M J, Ferrero R, Wang Z

- D. Deep transfer learning for bearing fault diagnosis: A systematic review since 2016. *IEEE Transactions on Instrumentation and Measurement*, 2023, **72**: Article No. 3508221
- 8 Yang Rui, Li Hong-Kun, He Chang-Bo, Wang Feng-Tao. Rolling element bearing incipient fault feature extraction based on optimal wavelet scales cyclic spectrum. *Journal of Mechanical Engineering*, 2018, **54**(17): 208–217
(杨蕊, 李宏坤, 贺长波, 王奉涛. 利用最优小波尺度循环谱的滚动轴承早期故障特征提取. 机械工程学报, 2018, **54**(17): 208–217)
- 9 Wang F T, Deng G, Liu C X, Su W S, Han Q K, Li H K. A deep feature extraction method for bearing fault diagnosis based on empirical mode decomposition and kernel function. *Advances in Mechanical Engineering*, 2018, **10**(9): 1–12
- 10 Zhang W B, Zhou J Z. Fault diagnosis for rolling element bearings based on feature space reconstruction and multiscale permutation entropy. *Entropy*, 2019, **21**(5): Article No. 519
- 11 Cheng Y, Wang Z W, Chen B Y, Zhang W H, Huang G H. An improved complementary ensemble empirical mode decomposition with adaptive noise and its application to rolling element bearing fault diagnosis. *ISA Transactions*, 2019, **91**: 218–234
- 12 Liu Jian-Chang, Quan He, Yu Xia, He Kan, Li Zhen-Hua. Rolling bearing fault diagnosis based on parameter optimization VMD and sample entropy. *Acta Automatica Sinica*, 2022, **48**(3): 808–819
(刘建昌, 权贺, 于霞, 何侃, 李镇华. 基于参数优化 VMD 和样本熵的滚动轴承故障诊断. 自动化学报, 2022, **48**(3): 808–819)
- 13 Dong S J, He K, Tang B P. The fault diagnosis method of rolling bearing under variable working conditions based on deep transfer learning. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2020, **42**(11): Article No. 585
- 14 Zhang X L, Han P, Xu L, Zhang F, Wang Y P, Gao L. Research on bearing fault diagnosis of wind turbine gearbox based on 1DCNN-PSO-SVM. *IEEE Access*, 2020, **8**: 192248–192258
- 15 Hu Ai-Jun, Zhang Jun-Hua, Liu Sui-Xian, Xu Sha. Intelligent identification method using kernel extreme learning machine for rolling bearing multi-working condition multi-feature automatic selection. *Journal of Vibration and Shock*, 2020, **39**(23): 182–189
(胡爱军, 张军华, 刘随贤, 许莎. 滚动轴承多工况故障的特征自动选择核极限学习机智能识别方法. 振动与冲击, 2020, **39**(23): 182–189)
- 16 Jin T T, Cheng Q, Chen H, Wang S Y, Guo J Y, Chen C H. Fault diagnosis of rotating machines based on EEMD-MPE and GA-BP. *The International Journal of Advanced Manufacturing Technology*, 2023, **124**(11): 3911–3922
- 17 He C, Wu T, Gu R W, Jin Z Y, Ma R J, Qu H Y. Rolling bearing fault diagnosis based on composite multiscale permutation entropy and reverse cognitive fruit fly optimization algorithm—Extreme learning machine. *Measurement*, 2021, **173**: Article No. 108636
- 18 Wang Jin-Hua, Hu Jia-Wei, Cao Jie, Huang Tao. Multi-fault diagnosis of rolling bearing based on adaptive variational modal decomposition and integrated extreme learning machine. *Journal of Jilin University (Engineering and Technology Edition)*, 2022, **52**(2): 318–328
(王进花, 胡佳伟, 曹洁, 黄涛. 基于自适应变分模态分解和集成极限学习机的滚动轴承多故障诊断. 吉林大学学报(工学版), 2022, **52**(2): 318–328)
- 19 Wang H, Liu Z L, Peng D D, Qin Y. Understanding and learning discriminant features based on multiattention 1DCNN for wheelset bearing fault diagnosis. *IEEE Transactions on Industrial Informatics*, 2020, **16**(9): 5735–5745
- 20 Shao Hai-Dong, Li Wei, Liu Yi, Yang Bin. Fault diagnosis of rotor-bearing system under time-varying speeds by using dual-threshold attention-embedded GAN and small samples. *Journal of Mechanical Engineering*, 2023, **59**(12): 215–224
(邵海东, 李伟, 刘翊, 杨斌. 时变转速下基于双阈值注意力生成对抗网络和小样本的转子-轴承系统故障诊断. 机械工程学报, 2023, **59**(12): 215–224)
- 21 Rehman A U, Jiao W D, Jiang Y H, Wei J N, Sohaib M, Sun J F, et al. Deep learning in industrial machinery: A critical review of bearing fault classification methods. *Applied Soft Computing*, 2025, **171**: Article No. 112785
- 22 Peng D D, Liu Z L, Wang H, Qin Y, Jia L M. A novel deeper one-dimensional CNN with residual learning for fault diagnosis of wheelset bearings in high-speed trains. *IEEE Access*, 2019, **7**: 10278–10293
- 23 Du W L, Hu P J, Wang H C, Gong X Y, Wang S Y. Fault diagnosis of rotating machinery based on 1D-2D joint convolution neural network. *IEEE Transactions on Industrial Electronics*, 2023, **70**(5): 5277–5285
- 24 Shao Z H, Li W Q, Xiang H, Yang S X, Weng Z Q. Fault diagnosis method and application based on multi-scale neural network and data enhancement for strong noise. *Journal of Vibration Engineering & Technologies*, 2024, **12**(1): 295–308
- 25 Chang M, Yao D C, Yang J W. Intelligent fault diagnosis of rolling bearings using efficient and lightweight ResNet networks based on an attention mechanism. *IEEE Sensors Journal*, 2023, **23**(9): 9136–9145
- 26 Yu X, Wang Y J, Liang Z T, Shao H D, Yu K, Yu W L. An adaptive domain adaptation method for rolling bearings' fault diagnosis fusing deep convolution and self-attention networks. *IEEE Transactions on Instrumentation and Measurement*, 2023, **72**: Article No. 3509814
- 27 Lu Y X, Zhu D C, Zhao D W, Zhu D, Sun D, Gao Q W. A novel bearing fault diagnosis algorithm based on adaptive weighted multiview learning. *IEEE Transactions on Instrumentation and Measurement*, 2023, **72**: Article No. 3521813
- 28 Zhang X H, Wang H, Wang C Z, Liu M, Xu G W. Time-segment-wise feature fusion Transformer for multi-modal fault diagnosis. *Engineering Applications of Artificial Intelligence*, 2024, **138**: Article No. 109358
- 29 Sun D Y, Li Y B, Liu Z, Jia S X, Noman K. Physics-inspired multimodal machine learning for adaptive correlation fusion based rotating machinery fault diagnosis. *Information Fusion*, 2024, **108**: Article No. 102394
- 30 You K S, Wang P Z, Huang P, Gu Y K. A sound-vibration physical-information fusion constraint-guided deep learning method for rolling bearing fault diagnosis. *Reliability Engineering & System Safety*, 2025, **253**: Article No. 110556
- 31 Chen Shi-Qian, Peng Zhi-Ke, Zhou Peng. Review of signal decomposition theory and its applications in machine fault diagnosis. *Journal of Mechanical Engineering*, 2020, **56**(17): 91–107
(陈是钊, 彭志科, 周鹏. 信号分解及其在机械故障诊断中的应用研究综述. 机械工程学报, 2020, **56**(17): 91–107)
- 32 Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, **9**(8): 1735–1780
- 33 Ding Y F, Jia M P, Miao Q H, Cao Y D. A novel time-frequency Transformer based on self-attention mechanism and its application in fault diagnosis of rolling bearings. *Mechanical Systems and Signal Processing*, 2022, **168**: Article No. 108616
- 34 Li S, Ji J C, Xu Y D, Feng K, Zhang K, Feng J C, et al. Dconformer: A denoising convolutional Transformer with joint learning strategy for intelligent diagnosis of bearing faults. *Mechanical Systems and Signal Processing*, 2024, **210**: Article No. 111142
- 35 Li X, Zhang W, Ding Q. A robust intelligent fault diagnosis method for rolling element bearings based on deep distance metric learning. *Neurocomputing*, 2018, **310**: 77–95



蒋 鹏 重庆师范大学物理与光电工程学院硕士研究生. 主要研究方向为大数据驱动的智能故障诊断.

E-mail: jiangpeng202511@163.com

(JIANG Peng Master student at the College of Physics and Optoelectronic Engineering, Chongqing

Normal University. His main research interest is big data-driven intelligent fault diagnosis.)



姚立忠 重庆师范大学物理与光电工程学院教授. 主要研究方向为智能建模与优化, 大数据驱动的智能故障诊断. 本文通信作者.

E-mail: lizhong_yao@cqnu.edu.cn

(YAO Li-Zhong Professor at the College of Physics and Optoelec-

tronic Engineering, Chongqing Normal University. His research interests include intelligent modeling and optimization and big data-driven intelligent fault diagnosis. Corresponding author of this paper.)



秦鹏杰 深圳大学人工智能学院副研究员. 主要研究方向为机器人与智能系统, 大数据驱动的智能故障诊断.

E-mail: qinpengjie1215@163.com

(QIN Peng-Jie Associate researcher at the School of Artificial Intelligence, Shenzhen University. His re-

search interests include robotics and intelligent systems and big data-driven intelligent fault diagnosis.)