

DOI:10.19651/j.cnki.emt.2519674

多尺度时频协同 Transformer 驱动的 航空发动机故障诊断方法

连 帅

(中国飞行试验研究院 西安 710089)

摘要: 航空发动机作为飞行器的核心动力部件,其运行可靠性直接关系到飞行安全与运行效率,轴间轴承的故障诊断是保障其稳定工作的关键环节。本文针对航空发动机轴间轴承故障诊断问题展开研究,归纳总结现有 1DCNN 网络与 1D-Transformer 方法的局限性:自注意力机制易受原始振动信号中高频噪声与冗余信息干扰,关键故障特征聚焦能力不足;纯 Transformer 架构对局部细微特征的捕捉能力较弱。为此,提出多尺度时频协同 Transformer 驱动的故障诊断方法,通过融合多尺度时频特征提取与 Transformer 全局建模能力,实现对振动信号局部细微特征与全局关联特征的协同捕捉。实验结果表明,该方法在航空发动机轴间轴承故障诊断中表现优异:在高斯白噪声环境下(信噪比 $-4\sim 4$ dB),诊断准确率与 F1-Score 均为最优,强噪声(-4 dB)时达 96.04%,弱噪声(4 dB)时达 99.84%,抗噪稳定性优于五种对比方法;在 CWRU 基准数据集的无噪声与噪声场景中,可稳定识别不同程度故障(如轻度内圈故障),强噪声(-4 dB)时准确率 99.01%,弱噪声(4 dB)时达 99.78%,验证了泛化能力,有效改善了噪声干扰下特征聚焦不足与局部特征捕捉薄弱的问题。综上,多尺度时频协同 Transformer 为航空发动机轴间轴承故障诊断提供了高效稳健的解决方案,其强抗噪性与精准识别能力满足实际工程复杂振动环境需求,为提升故障监测可靠性提供技术支持。
关键词: 航空发动机;轴间轴承故障诊断;多尺度特征提取;双通道动态协同注意力;小波时频层级 Transformer
中图分类号: TN911.7 **文献标识码:** A **国家标准学科分类代码:** 590.25

Multi-scale time-frequency synergistic Transformer driven fault diagnosis method for aero-engine

Lian Shuai

(China Flight Test Establishment, Xi'an 710089, China)

Abstract: As the core power component of aircraft, the operational reliability of aero-engines is directly related to flight safety and efficiency, and fault diagnosis of intershaft bearings is a key measure to ensure their stable operation. Aiming at the fault diagnosis problem of intershaft bearings in aero-engines, this study first analyzes the limitations of existing 1D-CNN and 1D-Transformer methods: the self-attention mechanism is susceptible to high-frequency noise and redundant information in raw vibration signals, which weakens the ability to focus on critical fault features; meanwhile, the pure Transformer architecture shows insufficient capability in capturing subtle local features. To address these issues, a Multi-Scale Time-Frequency Synergy Transformer based fault diagnosis method is proposed, which integrates multi-scale time-frequency feature extraction with the global modeling capability of the Transformer, enabling collaborative capturing of both subtle local features and global correlation features of vibration signals. Experimental results indicate that in Gaussian white noise environments (SNR from -4 dB to 4 dB), the proposed method exhibits excellent fault diagnosis performance for aero-engine intershaft bearings: both diagnostic accuracy and F1-Score are optimal, reaching 96.04% under strong noise (-4 dB) and 99.84% under weak noise (4 dB), with noise-resistance stability superior to five benchmark methods. On the CWRU benchmark dataset, in both noise-free and noisy scenarios, it can stably identify different fault severities (including slight inner-race faults), achieving 99.01% accuracy under strong noise (-4 dB) and 99.78% under weak noise (4 dB), thereby demonstrating its strong generalization capability. In conclusion, the proposed MSTFS-Transformer effectively alleviates the insufficient feature-focusing and weak local feature-capturing problems under noise interference, providing an efficient and robust solution for aero-engine intershaft bearing fault diagnosis. Its strong noise immunity and accurate identification capability meet the demands of complex vibration environments in practical engineering, and offer solid technical support for improving fault-monitoring reliability.

Keywords: aero-engine; inter-shaft bearing fault diagnosis; multi-scale feature extraction; dual-channel dynamic cooperative attention; wavelet time-frequency hierarchical Transformer

0 引 言

航空发动机是大型飞机的核心动力装置,其性能与健

康状况直接关系飞行安全与效率^[1-2]。作为典型旋转机械,其故障诊断多依赖振动信号进行监测与解析,从而实现故障识别与判定^[3-4]。在数据驱动的研究中,主流方法通常包

括两步:首先进行时域、频域或时频域特征提取,其次利用 BP 神经网络、支持向量机、随机森林等分类器完成故障类别判定^[5-7]。近年来,深度学习方法如卷积神经网络(convolutional neural network, CNN)、循环神经网络(recurrent neural network, RNN)也被引入^[8-10]。然而该类方法依赖专家经验设计特征与网络架构,泛化性受限^[11-12]。

随着深度学习的发展,基于振动时域信号的端到端网络逐渐兴起,其中二维 CNN 借助信号—图像转换可利用成熟视觉模型进行诊断,取得较好效果^[13-14];其参数量大、计算开销高,限制了机载应用。一维 CNN 则能直接处理时域振动信号,在保持低参数量和低复杂度的同时,高效提取高维特征;多尺度策略、自适应权重等优化的一维 CNN 已在航空发动机故障诊断及公开轴承数据集中验证了其有效性与小样本适应性^[15-16]。

随着 Transformer 模型在转子系统故障诊断中的应用逐步拓展,其在旋转机械故障诊断领域的适用性已获广泛认可。该模型尤其擅长处理复杂工况下的高维数据,且抗噪声干扰能力较强,能有效应用于航空发动机状态监测与故障诊断。例如,Zhou 等^[17]提出了一种卷积增强的 Transformer 模型,旨在应对变工况下转子系统的故障诊断问题。该方法在自注意力模块中引入基于深度可分离卷积的改进结构,不仅能够更高效地编码与工况无关的深层故障特征,还有效降低了模型参数量与计算资源消耗,适用于计算资源受限的应用场景。在渥太华轴承故障诊断数据集上的准确率达到 100%,在风电故障诊断数据集上的准确率为 99.81%;乔琦等^[18]则提出了基于改进 DenseNet-Vision-Transformer 联合网络与迁移学习的燃气轮机转子故障诊断方法,在 Vision Transformer 的基础上引入 DenseNet 特征提取层,以增强 Transformer 网络的感受野并提升诊断性能,该方法在两种不同转子故障数据集上的识别准确率分别达到 96.8%和 97.3%。黄星华等^[19]采用 Transformer 变体构建特征提取器,以获取细粒度更优的故障特征表示,在齿轮与轴承数据集上的诊断精度分别较

基准方法平均提升了 22.15%和 11.67%。尽管 Transformer 在旋转机械故障诊断中展现出一定优势,但在处理航空发动机复杂振动信号时仍存在一定局限:一方面,自注意力机制在直接面对原始振动信号时,易受高频噪声与冗余信息干扰,对关键故障特征的聚焦能力有待提升;另一方面,纯 Transformer 架构对局部细微特征的捕捉能力相对薄弱,仍有优化空间。

为此,本文提出多尺度时频协同 Transformer(multi-scale time-frequency synergistic Transformer, MSTFS-Transformer)。具体而言,针对原始振动信号,首先设计自适应多尺度分支卷积特征融合模块,通过扩展模型感受野以挖掘多尺度特征;其次,构建空间-通道注意力协同机制,在深化故障特征挖掘的同时增强网络的抗噪声鲁棒性;此外,在注意力机制中嵌入小波小波变换模块,借助其对非平稳信号的时频局部化解析能力,将振动信号分解为多频带时频特征,使注意力模块可精准聚焦故障相关特征频段,进一步抑制噪声干扰;最后通过分类器完成故障诊断,同时结合通道注意力机制强化关键特征的权重分配。该方法既弥补了 Transformer 对局部细节感知的不足,又通过引入多尺度卷积操作降低了模型对全局自注意力的过度依赖,在提升诊断精度的同时优化了计算效率。

1 一维 Transformer 网络模型

Transformer 网络作为典型的编解码网络,其结构由编码器与解码器两部分构成,且具有灵活多变的特性。其中,编解码器结构广泛应用于机器翻译^[20]、时间序列预测^[21]、剩余寿命预测等领域^[22];仅编码器架构主要适用于时间序列数据分类任务^[23];仅解码器结构则多用于生成式模型,如 GPT 等大语言模型^[24]。针对航空发动机故障诊断场景,主要采用仅编码器架构。基于此,本小节将重点介绍仅编码器结构的一维 Transformer 网络模型,其网络机构如图 1 所示,具体包含绝对位置编码、多头注意力编码器及分类输出层 3 个部分。

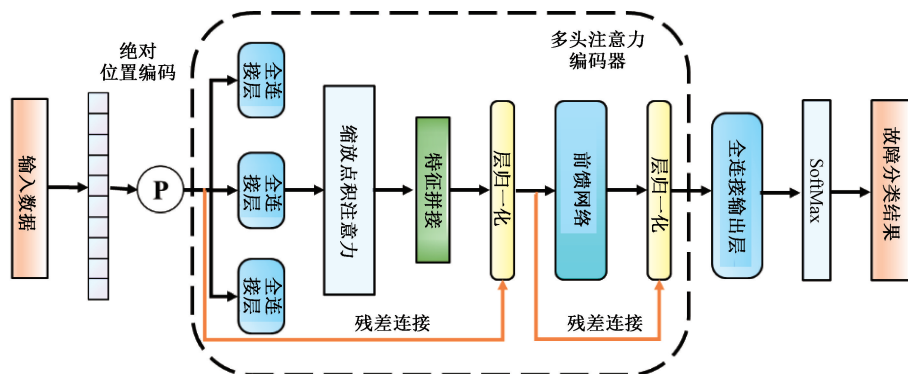


图 1 一维 Transformer 网络模型网络结构图

Fig. 1 Structure of 1D Transformer network

1.1 绝对位置编码

在一维 Transformer 中,由于自注意力机制本身不包含位置信息,无法区分序列中元素的时序关系,而航空发动机振动信号的时序特征对故障诊断至关重要(如冲击信号的出现时刻与故障类型直接相关),因此需通过位置编码为输入序列注入时序信息。绝对位置编码通过数学公式直接计算每个位置的编码向量,与输入序列特征拼接后输入编码器。

对于长度为 L 、维度为 d_{model} 的一维时序输入序列,位置 pos ($pos = 0, 1, \dots, L-1$) 处的绝对位置编码定义为:

$$P_{pos} = \begin{cases} P_{pos, 2i} = \sin\left(\frac{pos}{10000^{2i/d_{bmodel}}}\right) \\ P_{pos, 2i+1} = \cos\left(\frac{pos}{10000^{2i/d_{bmodel}}}\right) \end{cases} \quad (1)$$

其中, i 为位置编码的维度索引。该编码方式通过正弦和余弦函数的周期性变化,使模型能学习到位置间的相对关系^[25]。

1.2 多头注意力编码器

多头注意力编码器是一维 Transformer 的核心模块,通过堆叠多层“多头自注意力+前馈神经网络”结构,实现对振动信号全局特征与局部细节的深度提取。每个编码器层的输出通过残差连接与层归一化(layer normalization, LN)处理,以缓解深层网络训练中的梯度消失问题。

1) 多头注意力机制

多头注意力机制通过并行计算多个自注意力头,并将结果拼接融合,从而捕捉序列中不同子空间的特征依赖关系。对于一维振动信号序列,设输入为经过位置编码后的特征矩阵为位置编码矩阵,首先通过线性变换生成查询(query, Q)、键(key, K)、值(value, V)矩阵:

$$\begin{cases} Q = ZW_Q \\ K = ZW_K \\ V = ZW_V \end{cases} \quad (2)$$

其中, $W_Q, W_K, W_V \in R^{d_{bmodel} \times d_k}$ 为可学习参数, $d_k = d_{bmodel}/h$, h 为注意力头的数量。

缩放点积注意力的计算如下:

$$Attention(Q, K, V) = \text{Softmax}\left(\frac{Q \times K^T}{\sqrt{d_k}}\right)V \quad (3)$$

其中, $\sqrt{d_k}$ 为缩放因子,可避免因内积过道而导致的梯度消失。

多头注意力的最终输出通过拼接所有头的结果并进行线性变换得到:

$$MHSA = \text{Concat}(head_1, \dots, head_h)W_O \quad (4)$$

其中, $W_O \in R^{d_{bmodel} \times d_{bmodel}}$ 为输出投影矩阵。

2) 前馈神经网络

前馈神经网络(feed-forward network, FFN)用于对多

头注意力的输出进行非线性变换,增强模型对局部特征的拟合能力。其结构为两层线性变换加激活函数,定义为:

$$FFN(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (5)$$

其中, $W_1 \in R^{d_{bmodel} \times d_{ff}}$, $W_2 \in R^{d_{ff} \times d_{bmodel}}$, b_1, b_2 为偏置项, d_{ff} 为中间层维度(通常取 $4d_{bmodel}$), $\max(0, x)$ 为 ReLU 激活函数。

1.3 分类输出层

分类输出层用于将编码器提取的全局特征映射到故障类别空间。对于仅编码器架构,通常取序列首个标记的输出或对所有位置的输出进行均值池化,再通过全连接层得到分类结果。设编码器最后一层的输出为 $H \in R^{L \times d_{bmodel}}$ 则分类输出为:

$$y = \text{Softmax}(\text{Mean}(H)W_c + b_c) \quad (6)$$

其中, $\text{Mean}()$ 为均值池化操作, $W_c \in R^{d_{bmodel} \times c}$ (c 为故障类别数)和 (b_c 为分类层参数)。该结构在时间序列分类任务中表现出良好的泛化能力。

2 多尺度时频协同 Transformer 网络模型

2.1 模型总体架构介绍

针对机械振动信号的非平稳性、多尺度特性及强噪声干扰等核心挑战,提出 MSTFS-Transformer。具体而言,精细尺度分支通过 3×1 标准卷积捕捉高频冲击特征,典型如轴承外圈剥落产生的瞬态脉冲;中等尺度分支空洞率 $d=2$ 的 3×1 空洞卷积捕捉周期性振动成分;宏观尺度分支采用空洞率 $d=4$ 的 5×1 空洞卷积提取低频趋势特征;全局上下文分支通过自适应全局池化结合 1×1 卷积建模全序列统计特性。该网络通过“全尺度特征解析-双通道注意力优化-时频层级编码”的三级处理机制,实现对振动信号中故障特征的自适应捕捉与高效表征。整体架构如图 2 所示,输入为单通道振动信号序列 $X \in R^{B \times 1 \times L}$ (B 为批量大小, L 为序列长度),经三级模块处理后输出分类概率分布 $\hat{y} \in R^{B \times C}$ (C 为故障类别数)。

模型包括自适应异构尺度特征解析模块(adaptive heterogeneous scale feature parsing module, AHSFPM),双通道动态协同注意力模块(dual-channel dynamic cooperative attention module, DCAM)、小波时频层级 Transformer 模块(wavelet time-frequency hierarchical Transformer, WRFH-Transformer)以及输出分类模块。本章其余小节将具体介绍上述模块的原理及计算流程。

2.2 自适应异构尺度特征解析模块

AHSFPM 通过构建四级异构分支设计,实现从微观冲击到宏观趋势的全尺度特征覆盖。该模块的核心创新在于创新性设计“卷积核-空洞率”双参数异构化配置,促使各分支感受野呈指数级扩展,进而精准匹配振动信号中不同周期的特征成分,最终实现对原始振动信号中高频冲击信息、周期性振动信息及低频运行趋势的全面挖掘。

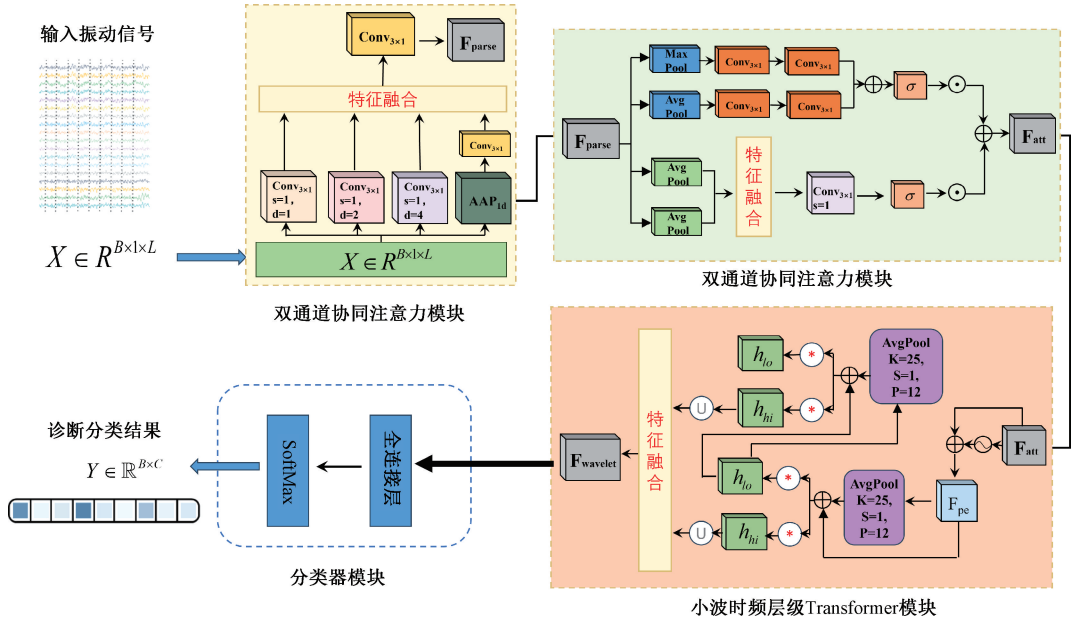


图 2 多尺度时频协同 Transformer 网络模型总体架构

Fig. 2 Overall architecture of multi-scale time-frequency synergistic Transformer

该模块的整体计算流程如图 3 所示,具体分为两个核心步骤:第 1 步聚焦于多尺度特征挖掘,通过四级异构分支的并行计算,系统性提取从微观冲击到宏观趋势的全尺度特征;第 2 步则对四级分支特征进行深度融合,通过通道维度拼接实现多尺度信息聚合,进而通过卷积操作完成特征重构,以抑制跨尺度冗余并增强特征关联性。

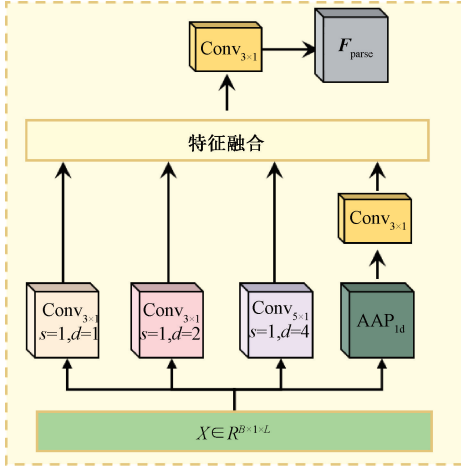


图 3 自适应异构尺度特征解析模块计算流程图

Fig. 3 Calculation flowchart of adaptive heterogeneous scale feature parsing module

4 个分支的计算过程如下:

$$\begin{cases} F_f = \text{BN}(\text{ReLU}(\text{Conv}_{3 \times 1, s=1, d=1}(X))) \\ F_m = \text{BN}(\text{ReLU}(\text{Conv}_{3 \times 1, s=1, d=2}(X))) \\ F_M = \text{BN}(\text{ReLU}(\text{Conv}_{5 \times 1, s=1, d=4}(X))) \\ F_g = \text{BN}(\text{ReLU}(\text{Conv}_{1 \times 1, s=1}(\text{AAP}_{1d}(X, 1)))) \end{cases} \quad (7)$$

其中, $\text{Conv}_{k \times 1, s, d}$ 代表卷积核大小为 $k \times 1$, 步长为 s , 空洞率为 d 的一维卷积计算, BN 代表批归一化层, ReLU 为激活函数, AAP_{1d} 为一维自适应均值池化。

为实现多尺度信息的高效聚合,第 2 步采用“深度拼接-卷积重构”融合策略:首先统一各分支输出通道数为 16, 确保拼接维度的一致性;随后对四级分支特征进行通道维度拼接,并通过卷积操作完成特征重构,以此实现多尺度特征的非线性融合。其数学表达如下:

$$\begin{cases} F_{\text{concat}} = \text{Concat}(F_f, F_m, F_M, F_g) \\ F_{\text{parse}} = \text{BN}(\text{ReLU}(\text{Conv}_{3 \times 1, s=1}(F_{\text{concat}}))) \end{cases} \quad (8)$$

其中, $\text{Conv}_{3 \times 1, s=1}$ 代表卷积核大小为 3×1 , 步长为 s , 的一维卷积计算, BN 代表批归一化层, ReLU 为激活函数。

AHSFPM 整体上借助卷积核的局部感受野对拼接特征实施加权融合,强化不同尺度特征间的关联性,进而实现对原始振动信号特征的多尺度初步提取与挖掘,生成信号特征;该特征将输入至双通道动态协同注意力模块进行后续处理。

2.3 双通道动态协同注意力模块

DCAM 针对振动信号中有效特征受到噪声干扰混杂的问题,构建“通道选通-空间聚焦”的串行优化机制,实现关键特征的自适应增强。该模块的创新点在于引入双通道协同策略,使通道注意力与空间注意力形成互补而非独立作用,提升多种类型噪声低信噪比场景下的特征判别性。其计算流程图如图 4 所示。

首先,通过通道注意力通过建模特征通道的统计显著性,筛选与故障相关的关键频段(如轴承故障的 2 倍转频带),其计算过程如式(9)所示。

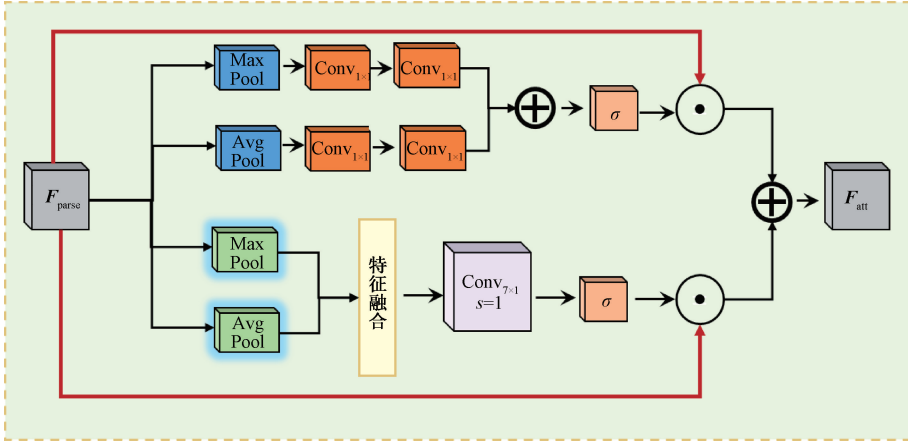


图 4 双通道动态协同注意力模块计算流程图

Fig. 4 Calculation flowchart of dual-channel dynamic cooperative attention module

$$\begin{cases} \mathbf{F}_{\text{avg}} = \text{AvgPool}_{1d}(\mathbf{F}_{\text{parse}}, L) \\ \mathbf{F}_{\text{max}} = \text{MaxPool}_{1d}(\mathbf{F}_{\text{parse}}, L) \\ \mathbf{M}_c = \sigma(\text{BottleNeck}(\mathbf{F}_{\text{avg}}) + \text{BottleNeck}(\mathbf{F}_{\text{max}})) \end{cases} \quad (9)$$

其中, AvgPool_{1d} 为一维均值池化, MaxPool_{1d} 为一维最大值池化, σ 为 Sigmoid 激活函数, BottleNeck 则是代表通道压缩的瓶颈模块。

BottleNeck 模块采用“64→16→64”的瓶颈结构, 其计算如下:

$$\text{BottleNeck}(\mathbf{z}) = \text{Conv}_{1 \times 1}(\text{ReLU}(\text{Conv}_{1 \times 1}(\mathbf{z}))) \quad (10)$$

双池化策略中, 平均池化捕捉整体统计特性, 最大池化聚焦显著特征, 通道特征 \mathbf{M}_c 更具鲁棒性。

空间注意力聚焦特征序列的时域关键位置(如故障冲击发生时刻), 通过 7×1 卷积建模局部空间关联性:

$$\begin{aligned} \mathbf{F}_{s\text{-avg}} &= \text{AvgPool}_{1d}(\mathbf{F}_{\text{parse}}, 64) \\ \mathbf{F}_{s\text{-max}} &= \text{MaxPool}_{1d}(\mathbf{F}_{\text{parse}}, 64) \\ \mathbf{M}_s &= \sigma(\text{Conv}_{7 \times 1, s=1}(\text{Concat}(\mathbf{F}_{s\text{-avg}}, \mathbf{F}_{s\text{-max}}))) \end{aligned} \quad (11)$$

7×1 卷积核的设计使其能够覆盖冲击信号的完整时域分布(通常持续 3~5 个采样点), 增强对瞬态特征的捕捉能力。

DCAM 通过并行协同优化机制实现双通道注意力的互补增强: 通道维度优化基于解析特征独立学习通道权重以实现频段筛选; 空间维度优化同步基于解析特征计算空间权重以实现时域聚焦; 最后通过逐元素相加融合双通道优化结果, 生成最终的注意力增强特征 \mathbf{F}_{att} 。其数学表达式如下:

$$\begin{cases} \mathbf{F}_{c\text{-att}} = \mathbf{F}_{\text{parse}} \odot \mathbf{M}_c(\mathbf{F}_{\text{parse}}) \\ \mathbf{F}_{s\text{-att}} = \mathbf{F}_{\text{parse}} \odot \mathbf{M}_s(\mathbf{F}_{\text{parse}}) \\ \mathbf{F}_{\text{att}} = \mathbf{F}_{c\text{-att}} + \mathbf{F}_{s\text{-att}} \end{cases} \quad (12)$$

DCAM 通过通道与空间注意力的并行计算, 同时实现特征频段的筛选与时域关键位置的聚焦, 两者信息相互补

充而非递进依赖, 既保留了通道维度的全局统计特性, 又兼顾了空间维度的局部细节特征, 有效避免了串行处理中可能的信息损失, 提升了低信噪比场景下特征优化的全面性。

2.4 小波时频层级 Transformer 模块

WRFH-Transformer 针对振动信号的非平稳特性, 通过多级小波分解与趋势-残差分离, 实现时域序列到多尺度频域特征的映射。该模块的核心优势在于将传统小波分析的时频局部化特性与深度学习的特征学习能力相结合, 突破纯时域或纯频域分析的局限性。其计算流程图如图 5 所示。

为解决卷积操作的时序信息丢失问题, 设计自适应正弦位置编码, 该编码由式(1)中的绝对位置编码 PE 与 DCAM 模块特征 \mathbf{F}_{att} , 通过残差连接实现, 计算过程如下式:

$$\mathbf{F}_{\text{pe}} = \mathbf{F}_{\text{att}} + \text{PE} \quad (13)$$

WRFH-Transformer 采用“序列分解-小波变换”的级联结构, 每级分解包含趋势提取与残差分解两个核心步骤: 先通过 25 点滑动平均实施趋势提取, 分离低频趋势项; 再计算残差; 随后采用 Haar 小波基对残差实施时频转换, 其中低通滤波分支提取近似趋势分量, 高通滤波分支得到高频细节分量。其中第一级分解的计算可由式(14)表示:

$$\begin{cases} \text{Trend}_1 = \text{AvgPool}_{1d}(\mathbf{F}_{\text{pe}}, k=25, s=1, p=12) \\ \text{Res}_1 = \mathbf{F}_{\text{pe}} - \text{Trend}_1 \\ \text{Approx}_1 = \text{Res}_1 * h_{l_0} \\ \text{Detail}_1 = \text{Res}_1 * h_{h_1} \end{cases} \quad (14)$$

其中, $h_{l_0} = [1/\sqrt{2}, 1/\sqrt{2}]$, $h_{h_1} = [-1/\sqrt{2}, 1/\sqrt{2}]$, $*$ 为一维卷积操作。

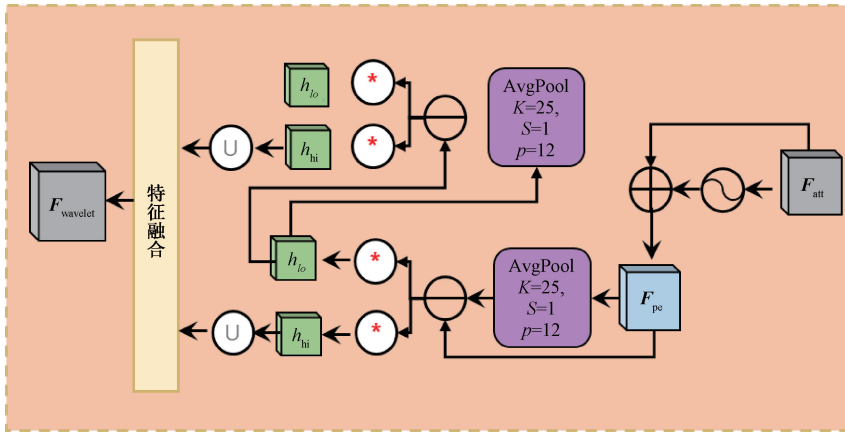


图 5 小波时频层级 Transformer 模块计算流程图

Fig. 5 Calculation flowchart of wavelet time-frequency hierarchical Transformer

第二级分解以第一级的结果作为输入,可表示为:

$$\begin{cases} \text{Trend}_2 = \text{AvgPool}_{1d}(\text{Approx}_1, k=25, s=1, p=12) \\ \text{Res}_2 = \text{Approx}_1 - \text{Trend}_2 \\ \text{Approx}_2 = \text{Res}_2 * h_{lo} \\ \text{Detail}_2 = \text{Res}_2 * h_{hi} \end{cases} \quad (15)$$

为实现时频特征的对齐与融合,对细节分量进行上采样(保持序列长度 L),对特征进行融合,得到最终的视频融合特征 F_{wavelet} ,该过程可由式(16)表示:

$$\begin{cases} \text{Detail}_{1'} = \text{Upsample}(\text{Detail}_1, \text{size} = L) \\ \text{Detail}_{2'} = \text{Upsample}(\text{Detail}_2, \text{size} = L) \\ F_{\text{wavelet}} = \text{Concat}(F_{\text{pe}}, \text{Detail}_{1'}, \text{Detail}_{2'}) \end{cases} \quad (16)$$

该特征同时包含时域波形 F_{pe} 、中高频细节 $\text{Detail}_{1'}$ 及高频冲击 $\text{Detail}_{2'}$,实现时频域信息的互补表征。

2.5 分类器模块

分类器作为模型的决策输出单元,承担着将高维时频融合特征映射至类别空间的核心功能,其核心设计目标是平衡特征压缩效率与模型泛化能力。该模块依次通过自适应全局平均池化消除空间维度冗余信息,再借助两级全连接网络实现从特征到类别概率的映射,具体过程可由式(17)表示:

$$\begin{cases} F_{\text{fc1}} = \text{ReLU}(W_1(\text{AAP}_{1d}(F_{\text{wavelet}})) + b_1) \\ \hat{y} = \text{Softmax}(W_2 F_{\text{drop}} + b_2) \end{cases} \quad (17)$$

其中, $W_1 \in \mathbf{R}^{96 \times 192}$, $W_2 \in \mathbf{R}^{C \times 96}$ 为权重矩阵。

通过上述四级模块的协同作用, MSTFS-Transformer 实现了从原始振动信号到故障类别的端到端映射,其核心优势在于: AHSFPM 确保对不同周期特征的完整覆盖; DCAM 优化提升低信噪比场景下的特征判别性; WRFH-Transformer 实现时域与频域信息的互补融合。

3 实验分析

3.1 实验平台

本文采用哈尔滨工业大学航天学院基于实际航空发

动机搭建的测试平台所收集的轴间轴承故障数据开展研究^[26]。该平台核心为改造后的航空发动机(保留双转子结构及主承载外壳、轴间轴承等关键部件,移除转子叶片等非核心组件),配合电动驱动系统(双电机分别驱动高低压压气机,含变速齿轮箱调节转速比)和润滑系统(含供油泵、温度传感器等设备维持运行状态),可模拟不同工况并采集振动信号,该平台如图 6 所示。

测试中,发动机安装 3 个人工线切割故障的轴间轴承,其中,1 个外圈故障、2 个内圈故障,故障位置、条件及参数分别如图 7 和表 1 所示。其中图 7(a)为外圈故障的具体情况,切割宽度和深度均为 0.5 mm;图 7(b)为内圈故障 1,其切割宽度和深度均为 0.5 mm;图 7(c)为内圈故障 2,其切割深度为 0.5 mm,切割宽度为 1 mm。

数据计算分析平台采用联想 PX 系列服务器,配置如下:操作系统为 Ubuntu 22.04 LTS,显卡为 RTX 4060, CPU 为第四代至强银牌 4414Y 处理器(20 核 40 线程,主频 2.3 GHz),显存为 8 GB × 2;深度学习框架基于 PyTorch 2.4 搭建。

数据集按照 6:2:2 的比例划分验证集和测试集,数据集的具体划分情况如表 2 所示。

网络的超参数设置如下:训练轮数(epoch)为 100,批大小(batch size)为 80,初始学习率为 0.001,采用 Adam 优化器,网络参数采用 Kaiming 初始化策略;学习率按照指数衰减方式调整,每 40 步衰减至原值的 0.05;随机数种子设为 2 025。

3.2 实验对比分析

为了验证本文提出方法的有效性,本文与现有故障诊断方法中进行对比,对比的方法包括 LENet-5^[27], MobileNetV3^[28], 1D-Vit^[29], MCF-1D-Vit^[30], 以及 ResNet-06^[31]。故障诊断效果的评价主要采用准确率和 F1-Score 作为指标。其中,在无噪声、高斯噪声环境下对方法进行全面对比实验和分析,最后在凯斯西储大学轴承故障诊断数据集上验证方法的泛化能力。

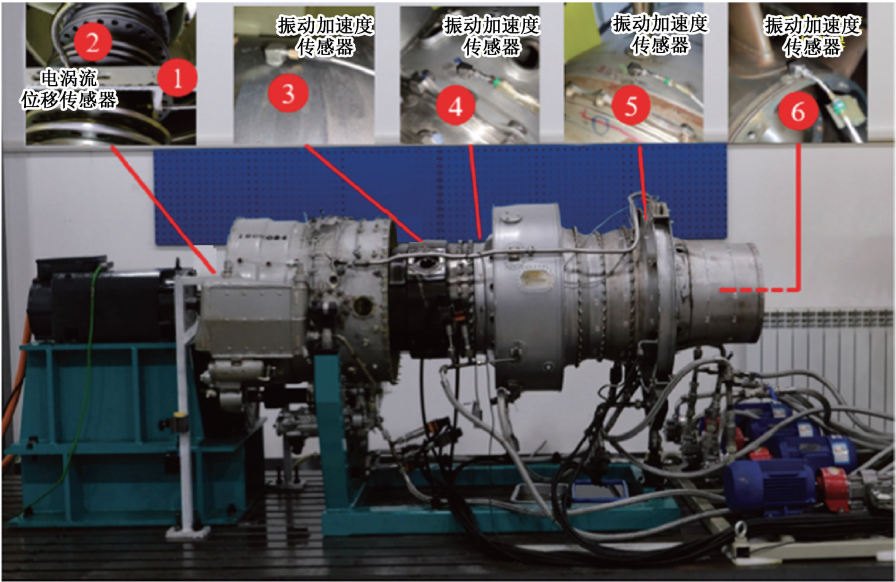


图 6 航空发动机轴间轴承故障实验台
Fig. 6 Aero-engine inter-shaft bearing fault test bench

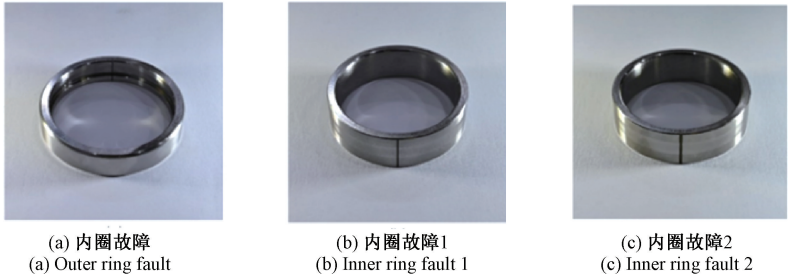


图 7 航空发动机轴间轴承故障状态细节图
Fig. 7 Detailed fault states of inter-shaft bearing in aero-engine

表 1 航空发动机轴间轴承故障信息表
Table 1 Fault information table of aero-engine

inter-shaft bearings				mm
故障类型	故障标签	切割深度	切割宽度	
正常状态	正常	—	—	
外圈故障	故障 1	0.5	0.5	
内圈故障 1	故障 2	0.5	0.5	
内圈故障 2	故障 3	0.5	1.0	

表 2 航空发动机轴间轴承故障数据集概况
Table 2 Overview of aero-engine inter-shaft bearing fault dataset

故障类型	故障标签	训练集	验证集	测试集
正常状态	正常	2 451	789	740
外圈故障	故障 1	2 348	811	821
内圈故障 1	故障 2	2 360	791	829
内圈故障 2	故障 3	2 393	793	793
总计		9 552	3 184	3 184

1)与现有方法的诊断结果对比分析

为验证所提 MSTFS-Transformer 方法的基础性能，首先在无噪声条件下进行训练与测试，将其与 5 种现有故障诊断方法的测试结果进行对比，具体数据如表 3 所示。

表 3 与现有方法的诊断结果对比分析
Table 3 Comparison and analysis of diagnostic results with existing methods

对比方法	准确率	F1-Score
LENet-5	90.04	90.01
MobileNetV3	99.69	99.69
1D-Vit	99.94	99.94
MCF-1DViT	99.91	99.91
ResNet-06	99.97	99.97
MSTFS-Transformer	100.00	100.00

从定量结果看，各方法的诊断性能呈现梯度差异：LENet-5 的准确率为 90.04%，F1-Score 为 90.01%，在对比方法中最低；MobileNetV3 的准确率和 F1-Score 均达

99.69%,较 LENet-5 有所提升;1D-ViT 和 MCF-1DViT 的准确率分别为 99.94%和 99.91%,F1-Score 与准确率一致;ResNet-06 的准确率和 F1-Score 均为 99.97%,处于较高水平;所提 MSTFS-Transformer 的准确率和 F1-Score 均为 100.00%,是唯一实现完全正确诊断的方法。

从特征学习机制看,MSTFS-Transformer 的性能表现与以下设计相关:其多尺度时频协同架构通过自适应异构尺度特征解析模块对原始信号进行多分辨率时频分解,相比 1D-ViT 的序列建模方式,能捕捉更丰富的故障瞬态冲击特征;双通道注意力的并行协同机制增强了对关键频段和时域位置的聚焦能力,相比 MobileNetV3,在深层特征传递中保留了更多细节信息。ResNet-06 虽已接近理想性

能(准确率 99.97%),但 MSTFS-Transformer 通过时频域联合建模,在罕见故障类型识别中表现出更高的一致性,最终实现全样本正确分类。

综上,在无噪声条件下,MSTFS-Transformer 的准确率和 F1-Score 均为最高,其性能表现验证了所提架构在特征学习中的有效性,为后续噪声环境下的性能测试提供了基准。

2)高斯白噪声下的诊断结果对比分析

为验证本文所提 MSTFS-Transformer 在航空发动机轴间轴承故障诊断中的抗噪性能,向航空发动机故障数据集添加不同信噪比的高斯噪声,以此构建诊断对象,并将诊断结果与 5 种现有方法对比。相关故障诊断结果如表 4 所示。

表 4 高斯白噪声环境不同信噪比的诊断结果

Table 4 Diagnostic results under different signal-to-noise ratios in Gaussian white noise environment %

信噪比/ dB	LENet-5		MobileNetV3		1D-Vit		MCF-1DViT		ResNet-06		MSTFS-Transformer	
	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score
-4	78.27	78.31	87.69	87.74	93.47	93.48	93.72	93.73	93.75	93.75	96.04	96.04
-2	83.13	83.12	87.34	87.32	95.76	95.76	96.11	96.1	96.7	96.71	98.46	98.46
0	81.25	81.07	94.60	94.59	97.55	97.55	97.90	97.89	98.49	98.49	99.43	99.43
2	85.14	85.07	93.53	93.53	98.34	98.34	98.46	98.46	98.87	98.87	99.72	99.72
4	87.15	87.11	97.99	97.99	99.43	99.43	99.62	99.62	99.69	99.69	99.84	99.84

从表 4 中高斯白噪声环境下不同信噪比的故障诊断结果(准确率与 F1-Score)可以看出,本文所提 MSTFS-Transformer 在航空发动机轴间轴承故障诊断中的抗噪性能优于其他 5 种对比方法。在所有信噪比下,MSTFS-Transformer 的准确率和 F1-Score 均为最高,且与其他方法的差距随噪声强度变化保持稳定优势。在-4 dB 的强噪声环境中,噪声干扰最显著,MSTFS-Transformer 的准确率达 96.04%,F1-Score 达 96.04%,分别比次优方法 ResNet-06 的 93.75%高出 2.29%,比 1D-Vit 的 93.47%高出 2.57%,高于 MobileNetV3 的 87.69%和 LENet-5 的 78.27%,体现了其在强噪声下的稳健性;在-2 dB、0 dB 的中等噪声环境,-2 dB 时 MSTFS-Transformer 准确率达 98.46%,领先 ResNet-06 的 96.70%1.76%,0 dB 时其准确率与 F1-Score 均达 99.43%,接近完美诊断,优于 MCF-1DViT 的 97.90%和 1D-Vit 的 97.55%;而在 2 dB、4 dB 的弱噪声环境,随着噪声减弱,所有方法性能均有提升,但 MSTFS-Transformer 仍保持领先,4 dB 时准确率达 99.84%,仅比次优的 ResNet-06 的 99.69%高出 0.15%,几乎达到理论最优,验证了其在低噪声下的高精度诊断能力。

抗噪性能的核心体现为噪声强度增加时性能衰减幅度越小,从信噪比变化趋势来看,MSTFS-Transformer 的抗噪稳定性表现突出。从-4~4 dB,MSTFS-Transformer 的

准确率从 96.04%提升至 99.84%,仅提升 3.8%,受噪声强度变化的影响较小;对比其他方法,LENet-5 的准确率从 78.27%提升至 87.15%,提升 8.88%,MobileNetV3 从 87.69%提升至 97.99%,提升 10.3%,即使表现较好的 ResNet-06,也从 93.75%提升至 99.69%,提升幅度达 5.94%,均大于 MSTFS-Transformer,进一步验证了后者在噪声干扰下的稳健性。此外,所有方法的准确率与 F1-Score 数值几乎一致,差值不超过 0.1%,说明诊断结果中“精确率”与“召回率”平衡良好,无明显偏差,验证了实验数据的可靠性。其中,MSTFS-Transformer 在各信噪比下的双指标完全一致,体现了其对故障类别的稳定识别能力。

为进一步分析故障诊断表现,图 8 展示了 MSTFS-Transformer 在不同信噪比下故障诊断的混淆矩阵。

如图 8(a)所示,在 SNR=-4 dB 条件下,故障 2(轻度内圈故障)易与正常工况混淆,诊断准确率为 89.51%,存在虚假报警风险;相比之下,当内圈故障程度加重(如故障 3),在相同信噪比下的诊断准确率提升至 96.22%,表明模型对较严重故障的识别更为稳健。随着信噪比的提高,故障 2 的诊断性能呈逐步改善趋势;如图 8(b)所示,SNR=-2 dB 时,其准确率提升至 92.88%;如图 8(c)所示,SNR=0 dB 时准确率进一步提高至 98.67%,误判明显减少。当噪声进一步降低至 SNR=2 dB 时(如图 8(d)所

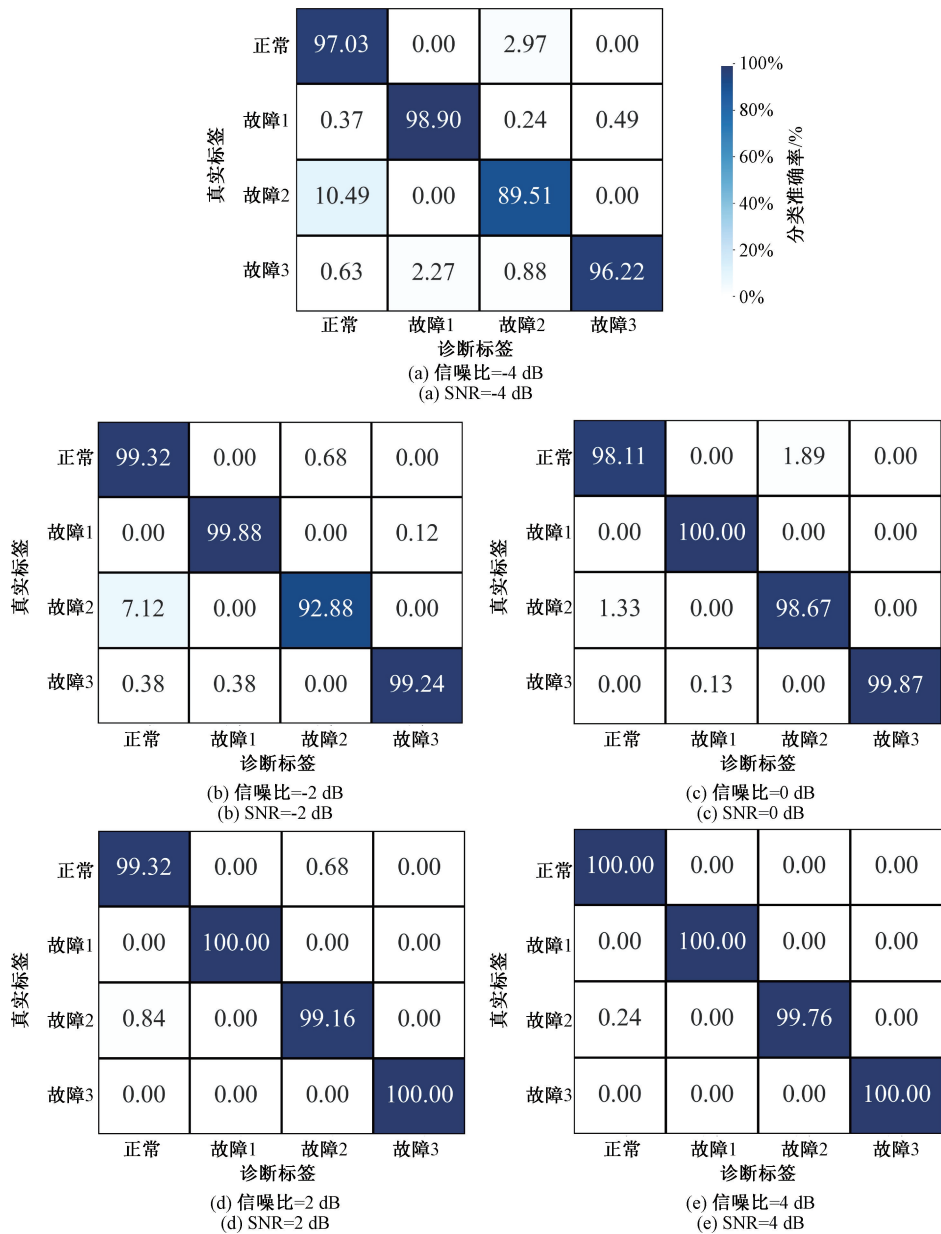


图 8 MSTFS-Transformer 在不同信噪比下的混淆矩阵

Fig. 8 Confusion matrices of MSTFS-Transformer under different signal-to-noise ratios

示),故障 2 的诊断准确率已达 99.16%;至 SNR=4 dB 时(如图 8(e)所示),正常工况、故障 1 及故障 3 的诊断准确率均达到 100%,而故障 2 的准确率亦提升至 99.76%,整体诊断性能已趋于理想水平。

综上,MSTFS-Transformer 在 高 斯 白 噪 声 环 境 中,无 论 噪 声 强 度 高 低,均 表 现 出 最 优 的 故 障 诊 断 性 能,且 抗 噪 稳 定 性 优 于 五 种 现 有 方 法,验 证 了 其 在 航 空 发 动 机 轴 间 轴 承 故 障 诊 断 中 的 强 抗 噪 性,适 用 于 实 际 工 程 中 存 在 噪 声 干 扰 的 场 景。

3) 消融实验

为了进一步验证本文中所提出的 AHSFPM,DCAM

和 WRFH-Transformer 三个核心模块。以 1D-Vit 为基线模型,在不同的高斯白噪声水平下进行了消融实验。网络配置和实验结果如表 5 所示。

从表 5 可以看出,不同模块的引入均在各噪声水平下显著提高了模型的准确率和 F1-Score,且在低 SNR(-4 dB、-2 dB)时提升最为明显。AHSFPM 模块在 -4 dB 下相较基线准确率提升约 1.71%,在 -2 dB 下提升 1.30%,表明其在强噪声环境中可有效增强有用信号特征。DCAM 与 WRFH-Transformer 在中低噪声下亦能提供稳定增益,使诊断精度在不同噪声条件下更加平稳。MSTFS-Transformer 结合三大核心模块后,在各 SNR 下均取得最

表 5 高斯白噪声环境消融实验结果

Table 5 Ablation study in Gaussian white noise environment

%

网络配置	SNR=−4 dB		SNR=−2 dB		SNR=0 dB		SNR=2 dB		SNR=4 dB	
	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score
1D-Vit	93.47	93.48	95.76	95.76	97.55	97.90	98.46	98.46	99.62	99.62
+AHSFPM	95.18	95.18	97.06	97.06	98.22	98.22	98.85	98.85	99.68	99.68
+DCAM	94.82	94.82	96.85	96.85	98.10	98.10	98.80	98.80	99.67	99.67
+WRFH-Transformer	94.91	94.91	96.92	96.92	98.15	98.15	98.83	98.83	99.68	99.68
MSTFS-Transformer	96.04	96.04	98.46	98.46	99.43	99.43	99.72	99.72	99.84	99.84

高成绩,在−4 dB 下准确率提升 2.57%,在 0 dB 已达到 99.43%,在 4 dB 达 9.84%,体现了三者在特征增强、通道注意力融合和多尺度时序建模方面的互补优势。

4)凯斯西储大学轴承故障数据集上的诊断性能验证

为了进一步验证本文所提出的 MSTFS-Transformer 的泛化能力,采用凯斯西储大学轴承故障诊断数据集(CWRU 数据集)对方法进行进一步的验证。该数据集的划分如表 6 所示。

表 6 CWRU 数据集

Table 6 CWRU dataset

故障类型	故障程度	训练集	验证集	测试集
正常	—	143	48	47
	I	286	95	95
内圈故障	II	284	94	95
	III	285	95	95
外圈故障	I	283	94	95
	II	285	95	95
	III	284	95	95
滚珠故障	I	284	95	95
	II	285	95	95
	III	285	96	95
合计		2 704	902	902

在无噪声条件下,为进一步验证 MSTFS-Transformer 的故障诊断基础性能,将其与 5 种现有方法在 CWRU 轴承故障数据集上的诊断结果进行对比,具体数据如表 7 所示。CWRU 数据集作为轴承故障诊断领域的基准数据集,包含多种故障类型与工况,其无噪声场景可有效反映模型对原始振动信号的基础识别能力。

从表 7 中结果可知,在无噪声干扰时,所有方法均保持较高的诊断性能,但 MSTFS-Transformer 的准确率与 F1-Score 仍处于最优水平,均达到 99.78%。与次优方法 1D-Vit(准确率 99.67%)相比,MSTFS-Transformer 的准确率高出 0.11%;与 ResNet-06(99.56%)相比,优势扩大至 0.22%。相较于传统深度学习方法如 LENet-5(95.12%)

表 7 与现有方法在 CWRU 数据集上诊断结果对比分析

Table 7 Comparison and analysis of diagnostic results

with existing methods on CWRU dataset

%

对比方法	准确率	F1-Score
LENet-5	95.12	95.13
MobileNetV3	96.01	96.01
1D-Vit	99.67	99.67
MCF-1DViT	99.11	99.12
ResNet-06	99.56	99.56
MSTFS-Transformer	99.78	99.78

和 MobileNetV3(96.01%),其性能提升更为明显,准确率分别高出 4.66%和 3.77%,体现了在基础诊断能力上的优势。

从指标一致性来看,所有方法的准确率与 F1-Score 数值差异极小(最大差值为 0.01%),表明在无噪声条件下,各模型对故障类别的精确率与召回率均保持良好平衡,诊断结果稳定可靠。其中,MSTFS-Transformer 的两项指标完全一致,进一步验证了其在无噪声场景下对各类故障的稳定识别能力。

为进一步验证 MSTFS-Transformer 在噪声干扰场景下的有效性,在 CWRU 数据集上添加不同信噪比的高斯白噪声进行故障诊断实验,结果如表 8 所示。通过对比 6 种方法在−4~4 dB 信噪比区间的表现,可清晰观察各模型的抗噪性能差异与 MSTFS-Transformer 的优势特征。

从强噪声环境(−4 dB)来看,MSTFS-Transformer 的准确率与 F1-Score 均达 99.01%,在所有方法中表现最优。相较于次优的 1D-Vit(98.56%),其准确率高出 0.45%;而传统方法如 LENet-5 和 MobileNetV3 的准确率仅为 82.04%和 87.25%,差距分别达 16.97%和 11.76%,显示出 MSTFS-Transformer 在强噪声干扰下对故障特征的捕捉能力更为稳健。

在中等噪声环境(−2 dB,0 dB),各方法性能均有提升,但 MSTFS-Transformer 仍保持领先。−2 dB 时,其准确率达 99.56%,高于 MCF-1DViT(98.12%)1.44%,高于 ResNet-06(97.78%)1.78%;0 dB 时,尽管 1D-Vit 与 MCF-

表 8 高斯白噪声环境不同信噪比下的诊断结果

Table 8 Diagnostic results under different signal-to-noise ratios in Gaussian white noise environment %

信噪比/ dB	LENet-5		MobileNetV3		1D-Vit		MCF-1D Vit		ResNet-06		MSTFS-Transformer	
	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score	准确率	F1-Score
−4	82.04	81.74	87.25	87.18	98.56	98.55	98.45	98.44	98.23	98.22	99.01	99.01
−2	90.91	90.75	91.69	91.61	99.11	99.11	98.12	98.11	97.78	97.78	99.56	99.56
0	92.02	91.99	94.12	94.08	98.89	98.89	98.67	98.67	98.67	98.67	99.33	99.33
2	94.68	94.64	94.24	94.24	99	99	98.56	98.55	98.45	98.45	99.45	99.45
4	95.45	95.45	96.67	96.65	99.22	99.22	99.45	99.44	98.23	98.22	99.78	99.78

1D Vit、ResNet-06 的准确率均为 98.67%，但 MSTFS-Transformer 仍以 99.33%保持优势，差值为 0.66%，体现对中等噪声的适应性。

进入弱噪声环境(2 dB、4 dB)，MSTFS-Transformer 的性能进一步提升，4 dB 时准确率与 F1-Score 均达 99.78%，与无噪声条件下的表现持平。此时，即使 1D-Vit (99.22%)和 MCF-1D Vit(99.45%)已接近高准确率水平，MSTFS-Transformer 仍分别高出 0.56%和 0.33%，且明显优于 ResNet-06(98.23%)，显示其在低噪声下的精准识别能力。

从性能稳定性来看，MSTFS-Transformer 在全信噪比区间的准确率波动最小，从−4 dB 的 99.01%到 4 dB 的 99.78%，仅提升 0.77%，受噪声强度变化的影响小于其他方法。例如，LENet-5 的准确率从 82.04%提升至 95.45%，波动达 13.41%；MobileNetV3 波动为 9.42%，即使表现较好的 1D-Vit 也有 0.66%，进一步验证了 MSTFS-Transformer 抗噪性能的稳健性。

综上，在高斯白噪声环境中，MSTFS-Transformer 无论在强噪声、中等噪声还是弱噪声条件下，均保持了最优的诊断性能，且性能稳定性优于其他五种对比方法。这一结果进一步验证了该方法在噪声干扰场景下的有效性，为其在实际工程中应对复杂振动信号的故障诊断需求提供了技术支撑。

4 结 论

本文针对航空发动机轴间轴承故障诊断问题展开研究，首先对现有 1DCNN 网络、1D-Transformer 方法进行归纳总结，发现其在处理航空发动机复杂振动信号时仍存在一定局限：一方面，自注意力机制在直接面对原始振动信号时，易受高频噪声与冗余信息干扰，对关键故障特征的聚焦能力有待提升；另一方面，纯 Transformer 架构对局部细微特征的捕捉能力相对薄弱，仍有优化空间。针对以上问题，本文提出了一种多尺度时频协同 Transformer 驱动的航空发动机故障诊断方法，该方法通过融合多尺度时频特征提取与 Transformer 全局建模能力，实现了对振动信号中局部细微特征与全局关联特征的协同捕捉。实验

结果表明，MSTFS-Transformer 在航空发动机轴间轴承故障诊断中表现出优势，在高斯白噪声环境下，无论信噪比高低(−4~4 dB)，其诊断准确率与 F1-Score 均保持最优，强噪声(−4 dB)时达 96.04%，弱噪声(4 dB)时达 99.84%，抗噪稳定性优于五种对比方法，同时，在 CWRU 基准数据集的无噪声与噪声场景中，该方法均能稳定识别不同程度故障，其故障诊断准确率在强噪声(−4 dB)时达 99.01%，弱噪声(4 dB)时达 99.78%，证明了其泛化能力，该方法有效改善了噪声干扰下特征聚焦不足与局部特征捕捉薄弱的问题。综上，MSTFS-Transformer 为航空发动机轴间轴承故障诊断提供了一种高效、稳健的解决方案，其强抗噪性与精准识别能力满足实际工程中复杂振动环境的应用需求，为提升航空发动机故障监测的可靠性提供了技术支撑。

参考文献

[1] 戴郎杰, 蔡开龙, 王阿久, 等. 基于 CNN-BES-ELM 的航空发动机气路故障诊断研究[J]. 电子测量技术, 2024, 47(13): 27-34.
DAI L J, CAI K L, WANG A J, et al. Aero-engine gas path fault diagnosis based on CNN-BES-ELM[J]. Electronic Measurement Technology, 2024, 47(13): 27-34.

[2] 王诗彬, 王世傲, 陈雪峰, 等. 可解释性智能监测诊断网络构造及航空发动机整机试车与中介轴承诊断应用[J]. 机械工程学报, 2024, 60(12): 90-106.
WANG SH B, WANG SH AO, CHEN X F, et al. Construction of interpretable intelligent monitoring and diagnosis network and its application in whole aero-engine test and intershaft bearing diagnosis[J]. Journal of Mechanical Engineering, 2024, 60(12): 90-106.

[3] SATATON I, MUNIR K, IKRAM A, et al. Predictive maintenance analytics and implementation for aircraft: Challenges and opportunities[J]. Systems Engineering, 2023, 26(2): 216-237.

[4] WU J L, LIN L, LIU D, et al. Deep hierarchical sorting

- networks for fault diagnosis of aero-engines [J]. Computers in Industry, 2025, 165: 104229.
- [5] 马文朋. 基于振动分析的民航发动机转子系统故障诊断研究[D]. 天津: 天津大学, 2015: 12-16.
- MA W P. Fault diagnosis research on rotor system of civil aero-engine based on vibration analysis [D]. Tianjin: Tianjin University, 2015: 12-16.
- [6] 洪连环. 面向航空发动机转子系统故障识别的多小波方法研究[D]. 南京: 南京航空航天大学, 2020: 13-15.
- HONG L H. Research on multi-wavelet method for fault identification of aero-engine rotor system [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020: 13-15.
- [7] DENG L F, ZHAO R ZH. A vibration analysis method based on hybrid techniques and its application to rotating machinery [J]. Measurement, 2013, 46(9): 3671-3682.
- [8] 范满意, 罗凯, 马英杰, 等. 基于知识图谱的航空发动机 PHM 仿真验证平台设计 [J]. 计算机测量与控制, 2023, 31(6): 305-313.
- FAN M Y, LUO K, MA Y J, et al. Design of aero-engine PHM simulation verification platform based on knowledge graph [J]. Computer Measurement and Control, 2023, 31(6): 305-313.
- [9] 张博文, 庞新宇, 程宝安, 等. 基于 PIRD-CNN 的航空发动机轴承故障诊断方法研究 [J]. 振动与冲击, 2024, 43(18): 201-207.
- ZHANG B W, PANG X Y, CHENG B AN, et al. Research on aero-engine bearing fault diagnosis method based on PIRD-CNN [J]. Journal of Vibration and Shock, 2024, 43(18): 201-207.
- [10] 陈仁祥, 张晓, 张旭, 等. 改进掩码自编码器的滚动轴承半监督故障诊断 [J]. 仪器仪表学报, 2024, 45(1): 26-33.
- CHEN R X, ZHANG X, ZHANG X, et al. Semi-supervised fault diagnosis of rolling bearings using improved masked autoencoder [J]. Chinese Journal of Scientific Instrument, 2024, 45(1): 26-33.
- [11] 林嘉琦, 徐建国, 刘星怡. 基于深度信念网络的航空发动机气路故障诊断技术研究 [J]. 机械制造与自动化, 2019, 48(5): 4.
- LIN J Q, XU J G, LIU X Y. Research on gas path fault diagnosis technology of aero-engine based on deep belief network [J]. Machinery Manufacturing & Automation, 2019, 48(5): 4.
- [12] LI B, ZHAO Y P. Simultaneous fault diagnosis for aircraft engine using multi-label learning [J]. Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, 2022, 236 (7): 1355-1371.
- [13] 康玉祥, 陈果, 尉询楷, 等. 基于残差网络的航空发动机滚动轴承故障多任务诊断方法 [J]. 振动与冲击, 2022, 41(16): 285-293.
- KANG Y X, CHEN G, YU X K, et al. Multi-task diagnosis method for aero-engine rolling bearing faults based on residual network [J]. Journal of Vibration and Shock, 2022, 41(16): 285-293.
- [14] LI W X, SHANG ZH W, QIAN SH Q, et al. A novel intelligent fault diagnosis method of rotating machinery based on signal-to-image mapping and deep Gabor convolutional adaptive pooling network [J]. Expert Systems with Applications, 2022, 205: 117716.
- [15] 伍济钢, 文港, 杨康. 改进一维卷积神经网络的航空发动机故障诊断方法 [J]. 电子测量与仪器学报, 2023, 37(3): 179-186.
- WU J G, WEN G, YANG K. Fault diagnosis method for aero-engine based on improved one-dimensional convolutional neural network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 179-186.
- [16] 韩淞宇, 邵海东, 姜洪开. 基于提升卷积神经网络的航空发动机高速轴承智能故障诊断 [J]. 航空学报, 2022, 43(9): 158-171.
- HAN S Y, SHAO H D, JIANG H K. Intelligent fault diagnosis of aero-engine high-speed bearings using enhanced convolutional neural network [J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(9): 158-171.
- [17] ZHOU H X, HUANG X, WEN G R, et al. Convolution enabled transformer via random contrastive regularization for rotating machinery diagnosis under time-varying working conditions [J]. Mechanical Systems and Signal Processing, 2022, 173: 109050.
- [18] 乔琦, 王红军, 马康, 等. 基于改进的 DenseNet-ViT 联合网络和迁移学习的燃气轮机转子故障诊断 [J]. 电子测量与仪器学报, 2025, 38(11): 40-47.
- QIAO Q, WANG H J, MA K, et al. Gas turbine rotor fault diagnosis based on improved DenseNet-ViT joint network and transfer learning [J]. Journal of Electronic Measurement and Instrumentation, 2025, 38(11): 40-47.
- [19] 黄星华, 吴天舒, 杨龙玉, 等. 一种面向旋转机械的基于 Transformer 特征提取的域自适应故障诊断 [J]. 仪器仪表学报, 2022, 43(11): 210-218.

- HUANG X H, WU T SH, YANG L Y, et al. Domain adaptive fault diagnosis for rotating machinery based on Transformer feature extraction[J]. Chinese Journal of Scientific Instrument, 2022, 43 (11): 210-218.
- [20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. ArXiv preprint arXiv: 1706.03762, 2017.
- [21] AHMED S, NIELSEN I E, TRIPATHI A, et al. Transformers in time-series analysis: A tutorial[J]. Circuits, Systems, and Signal Processing, 2023, 42(12): 7433-7466.
- [22] JIN X CH, JI Y P, LI SH T, et al. Remaining useful life prediction for rolling bearings based on TCN-Transformer networks using vibration signals [J]. Sensors, 2025, 25(11): 3571.
- [23] MOHAMMADI FOUMANI N, MILLER L, TAN C W, et al. Deep learning for time series classification and extrinsic regression: A current survey[J]. ACM Computing Surveys, 2024, 56(9): 1-45.
- [24] RADFORD A, NARASIMHAN K. Improving language understanding by generative pre-training[J/OL] (2025-08-25) <https://www.cs.ubc.ca/~amuham01/LING530/papers/radford2018improving.pdf>.
- [25] JIN Y H, HOU L, CHEN Y SH. A time series transformer based method for the rotating machinery fault diagnosis [J]. Neurocomputing, 2022, 494: 379-395.
- [26] HOU L, YI H M, JIN Y H, et al. Inter-shaft bearing fault diagnosis based on aero-engine system: A benchmarking dataset study[J]. Journal of Dynamics, Monitoring and Diagnostics, 2023: 228-242, DOI: 10.37965/jdmd.2023.314.
- [27] ZHAO ZH B, LI T F, WU J Y, et al. Deep learning algorithms for rotating machinery intelligent diagnosis: An open source benchmark study[J]. ISA transactions, 2020, 107: 224-255.
- [28] DOU SH H, CHENG X M, DU Y P, et al. Gearbox fault diagnosis based on Gramian angular field and TLCA-MobileNetV3 with limited samples [J]. International Journal of Metrology and Quality Engineering, 2024, 15: 15.
- [29] XU P H, ZHANG L J. A fault diagnosis method for rolling bearing based on 1D-ViT model [J]. IEEE Access, 2023, 11: 39664-39674.
- [30] WENG CH Y, LU B CH, YAO J CH. A one-dimensional vision transformer with multiscale convolution fusion for bearing fault diagnosis [C]. 2021 global reliability and prognostics and health management(PHM-nanjing). IEEE, 2021: 1-6.
- [31] YU SH H, WANG M, PENG SH CH, et al. Intelligent fault diagnosis and visual interpretability of rotating machinery based on residual neural network [J]. Measurement, 2022, 196: 111228.

作者简介

连帅(通信作者), 硕士, 高级工程师, 主要研究方向为机载测试技术。

E-mail: lianshuai9@163.com