

DOI:10.13382/j.jemi.B2508440

基于跨传感器特征融合的滚动轴承故障诊断*

吕轶¹ 祝志荣¹ 赵天宇²

(1. 沈阳航空航天大学电子信息工程学院 沈阳 110136; 2. 东北大学理学院 沈阳 110819)

摘要:神经网络处理复杂场景下的故障诊断任务会面临强噪声干扰和单个传感器信息不完整,针对其导致诊断性能下降问题,提出了一种跨传感器特征融合的卷积神经网络模型。首先,提取数据特征时结合卷积神经网络与双环残差模块来缓解训练过程中的梯度消失问题;然后,引入卷积注意力模块进而提升模型对关键特征的专注能力;随后,使用特征优化重构模块改善特征学习效率与表达能力;之后,利用自适应特征融合模块将不同传感器所提取的高级特征进行自适应融合;最后,通过全局平均池化层、全连接层和 Softmax 函数对融合后的特征进行分类,实现故障诊断任务。结果表明,该方法能有效融合多传感器数据特征,且对不同强度噪声表现出良好的鲁棒性;模型平均诊断准确率在-2~-18 dB 噪声下达到 97.48%,相对于单个传感器提升 1.88%,为解决复杂场景下的故障诊断提供有效参考。

关键词:故障诊断;跨传感器;强噪声;卷积注意力模块;特征融合

中图分类号: TN911.72; TH133.33

文献标识码: A

国家标准学科分类代码: 510.4010

Fault diagnosis of rolling bearings based on cross-sensor feature fusion

Lyu Yi¹ Zhu Zhirong¹ Zhao Tianyu²

(1. School of Electronic Information Engineering, Shenyang Aerospace University, Shenyang 110136, China;

2. School of Sciences, Northeastern University, Shenyang 110819, China)

Abstract: Neural networks employed for fault diagnosis in complex scenarios often face challenges like strong noise interference and incomplete information from individual sensors, leading to degraded diagnostic performance. To address this issue, a cross-sensor convolutional neural network with dual residual and feature adaptation model is proposed. Firstly, during the data feature extraction process, a dual-ring residual module is utilized to alleviate the gradient vanishing problem during training. Subsequently, the convolutional block attention module attention mechanism is introduced to enhance the model's ability to focus on critical features. Then, a feature optimization and reconstruction module is utilized to improve the efficiency of feature learning and the capability of feature expression. Thereafter, an adaptive feature fusion module is employed to adaptively fuse high-level features extracted from different sensors. Finally, the fused features are classified through a global average pooling layer, a fully connected layer, and a Softmax function to accomplish the fault diagnosis task. The results demonstrate that the proposed method effectively integrates multi-sensor data features and exhibits robustness against noise of varying intensities. The average diagnostic accuracy of the model reaches 97.48% under noise levels ranging from -2 to -18 dB, showing an improvement of 1.88% compared to using a single sensor. This study provides an effective reference for solving fault diagnosis problems in complex scenarios.

Keywords: fault diagnosis; cross-sensor; strong noise; attention mechanism; feature fusion

0 引言

滚动轴承是机器中应用频次极高的部件,也是各类

旋转机械的核心组成部分^[1],其应用场景包括直升机、航空发动机、风力发电机、高速列车等。在机械设备运行过程中,轴承会出现腐蚀、磨损和断裂等故障^[2],进而影响生产安全,造成经济损失^[3]。因此,对轴承进行故障诊断

对机械设备的正常运转具有重要意义。

针对滚动轴承的故障诊断方法从一开始的基于专家经验和知识的故障判断,逐渐发展到基于数据驱动的故障诊断方法^[4]。在数据驱动的故障诊断方法中,传统机器学习方法是重要分支,常见的基于机器学习的方法有贝叶斯分类器^[5]、支持向量机^[6]、随机森林^[7]以及K-近邻算法^[8]。然而,这类方法仍需依赖专家经验完成诊断任务。近年来,深度学习因在数据自动提取、特征学习和模式识别等方面的突出性能,已成为各研究领域的关注焦点。目前,应用于故障诊断的深度学习算法主要包括自编码器^[9]、卷积神经网络(CNN)^[10]、深度置信网络^[11]以及长短期记忆网络^[12]。其中,卷积神经网络凭借其强大的特征提取能力,已成为故障诊断领域的研究热点。Gao等^[13]将自适应修正互补集成经验模态分解与卷积神经网络相结合应用于滚动轴承故障诊断,得到较好诊断效果。Xue等^[14]利用马尔可夫过渡场(Markov transition Field, MTF)获得其图像,并使用基于自校准坐标注意机制和多尺度卷积神经网络的深度学习模型进行轴承故障诊断,故障诊断精度得到显著提升。Sun等^[15]将包络谱变换、离散余弦S变换与密集残差模型相结合,通过区分特征重要性,从而有效提升故障诊断网络的特征提取能力与效率。

尽管上述方法诊断效果较好,但在复杂环境中,单一传感器信号易受机械振动、电磁干扰等影响,从而导致诊断准确性下降。而通过融合不同传感器的互补数据进行协同分析,可有效提升故障诊断的准确性与鲁棒性。Wang等^[16]为提取多传感器数据的深层特征,将卷积神经网络与改进多头注意力机制相结合。使所提取特征包含传感器互补的故障信息,为故障诊断任务提供了更全面的数据支撑。Choudhary等^[17]将多输入卷积神经网络与恒定Q非平稳Gabor变换相结合用来融合振动-声学信号特征,为多源信号协同进行诊断提供可行路径。Xue等^[18]提取电流信号和振动信号的时域、频域以及时频域特征进行融合,进一步丰富了多源信号的故障信息表征。

以上深度学习方法应用于滚动轴承故障诊断,虽精度较高,但往往依赖无噪声的理想数据集。然而,实际工程中,旋转机械工作环境复杂,且噪声干扰显著,这使得故障诊断精度下降。为解决这一问题,本文提出一种跨传感器特征融合的卷积神经网络(cross-sensor convolutional neural network with dual residual and feature adaptation, CCDFA)。该网络首先,将卷积神经网络与双残差模块(dual-ring residual module, DRRM)相结合,以提取数据特征并缓解神经网络训练的梯度消失问题;其次,引入卷积注意力模块(convolutional block attention module, CBAM)注意力机制,提升模型对关键特征的关注能力,进而提升特征学习能力;然后,使用特征优化重构模块

(feature optimization and reconstruction module, FORM)以剔除冗余特征,改善特征学习效率与表达能力;随后,利用自适应特征融合模块(adaptive feature fusion, AFF)对不同传感器提取的特征进行融合,强化多源信息协同作用;最后,通过全局平均池化层、全连接层及Softmax函数对融合后的特征进行分类,完成故障诊断任务。

1 CCDFA 模型理论

CCDFA 模型组成包括 CBAM 模块、DRRM 模块、FORM 模块以及 AFF 模块。

1.1 双环残差模块

残差网络由 He 等^[19]于 2015 年提出,网络通过引入残差连接,有效缓解了因网络深度增加而引起的梯度消失与梯度爆炸问题,使得训练极深的神经网络成为可能。因此,为在提取数据深层特征的同时缓解训练中的梯度消失问题,本文采用 DRRM 模块,可通过双残差学习机制来有效缓解深度神经网络训练中的梯度消失问题。其结构如图 1 所示。

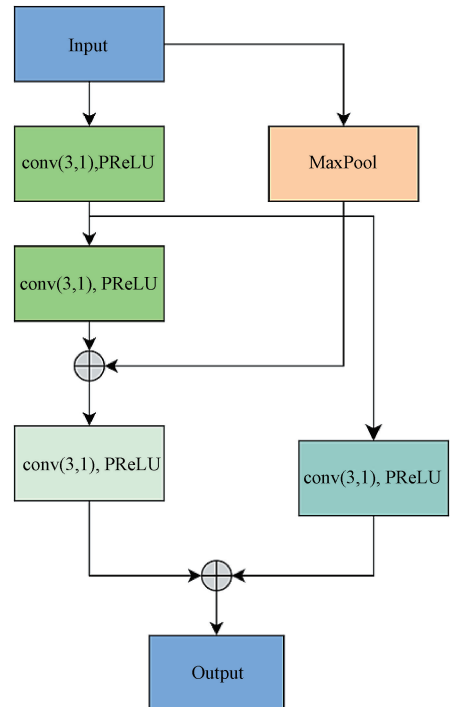


图1 双环残差结构

Fig. 1 Dual-ring residual module structure diagram

该模块包含两个相互协同的残差环路,在第1个残差环中,首先采用由两个串联的卷积操作与PRReLU激活函数组成的卷积层;同时,使用最大池化层进行下采样;然后,通过残差连接将卷积结果与池化结果相加,得到增强后的特征:

$$X_i = \phi(\text{Conv}(X_{i-1})) \quad i = 1, 2 \quad (1)$$

$$X_{MP} = MP(X_0) \quad (2)$$

$$X_{res1} = X_2 + X_{MP} \quad (3)$$

式中: X_0 为初始输入特征图; $\text{Conv}()$ 为卷积操作; $MP()$ 为最大池化操作; ϕ 为 PReLU 激活函数, 定义如式(4)。

$$\phi(x) = \begin{cases} x, & x > 0 \\ ax, & x \leq 0 \end{cases} \quad (4)$$

式中: a 是可学习参数。

为了进一步增强特征表示, 引入第 2 个残差环。第 1 个残差环的输出经过一个卷积和 PReLU 激活函数。同时, 第 1 个残差环的第 1 个卷积层的输出也经过一个卷积层和 PReLU 激活函数。最终, 两个特征图相加, 形成模块的输出:

$$X_{res2} = \phi(\text{Conv}(X_1)) + \phi(\text{Conv}(X_{res1})) \quad (5)$$

式中: X_1 为第 1 层输入特征图; X_{res1} 为第 1 残差环的输出; X_{res2} 为第 2 残差环的输出, 即 DRRM 的最终输出。

双环残差模块融合了残差结构与多层卷积操作。该设计不仅能提取多层次特征, 还能通过残差跳跃连接缓解梯度消失并保留细节信息, 从而增强模型的特征表征能力。

1.2 CBAM 模块

CBAM 模块是由韩国首尔大学的 Woo 等^[20]提出的一个轻量级、可嵌入的注意力模块, 旨在通过明确地强调有用特征和抑制无用特征来提升卷积神经网络的表示能力。CBAM 由通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)所组成的, 能够有效增强卷积神经网络对关键特征的关注能力。其结构如图 2 所示。




图 2 CBAM 结构

Fig. 2 CBAM structure diagram

CAM 通过对重要特征通道赋予更高的权重来突出重要特征通道。给定输入特征图 $F \in \mathbf{R}^{C \times H \times W}$, 通道注意力权重 $M_1 \in \mathbf{R}^{C \times H \times W}$ 的计算过程如下。

首先, 分别对特征图进行全局平均池化和全局最大

池化, 得到两个空间上下文表述符 F_{avg}^c 和 F_{max}^c :

$$F_{avg}^c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F^c(i, j), \quad F_{max}^c = \max_{i,j} F^c(i, j) \quad (6)$$

然后, 将两个表述符输入共享的多层感知机(multilayer perceptron, MLP), 生成通道注意力权重:

$$M_c(F) = \sigma(\text{MLP}(F_{avg}^c) + \text{MLP}(F_{max}^c)) \quad (7)$$

式中: σ 表示 Sigmoid 激活函数。

SAM 通过对特征图中的关键区赋予更高的权重来聚焦于特征图中的关键区域。给定通道注意力模块的输出特征图 $F' \in \mathbf{R}^{C \times H \times W}$, 空间注意力权重 $M_s \in \mathbf{R}^{1 \times H \times W}$ 的计算过程如下。

首先, 沿通道维度对特征图进行全局平均池化和全局最大池化, 得到两个空间特征图 F_{avg}^s 和 F_{max}^s :

$$F_{avg}^s = \frac{1}{C} \sum_{c=1}^C F'_c, \quad F_{max}^s = \max F'_c \quad (8)$$

然后, 将两个特征图拼接并通过卷积层生成空间注意力权重:

$$M_s(F') = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (9)$$

式中: $f^{7 \times 7}$ 表示 7×7 卷积操作; σ 表示 Sigmoid 激活函数。

最终, 将输入特征图 F 通过通道注意力和空间注意力权重进行调整得到最终输出 F'' :

$$F'' = F \otimes M_c(F) \otimes M_s(F') \quad (10)$$

式中: \otimes 表示逐元素乘法。

CBAM 模块通过结合通道注意力和空间注意力机制, 能够同时从通道和空间维度对特征图进行调整, 从而提升模型对关键信息的关注度, 进而提升模型性能。

1.3 特征优化重构模块

本文采用 FORM 模块来缓解卷积神经网络中因网络深度增加导致的特征通道冗余问题。该模块通过空间特征重构和通道特征重构两个阶段, 能够有效提升特征的学习效率与表达能力。

1) 空间特征重构

空间特征重构阶段通过对输入特征进行分组归一化和权重分配, 以提取重要特征并抑制冗余信息, 结构如图 3 所示。




图 3 空间特征重构结构

Fig. 3 Spatial feature reconstruction structure diagram

对输入特征进行组归一化 (group normalization, GN):

$$X_{GN} = \gamma \cdot \frac{Y - \mu}{\sqrt{\sigma^2 + \epsilon}} + \beta \quad (11)$$

式中: Y 是输入特征; μ 和 σ 分别是特征的均值和标准差; ϵ 是一个常数; γ, β 是可学习参数。

对通道权重进行归一化以平衡各通道的贡献度:

$$W_\gamma = \{w_i\} = \frac{\gamma_i}{\sum_{j=1}^c \gamma_j} \quad i, j = 1, 2, \dots, C \quad (12)$$

式中: W_γ 是通道的归一化权重; C 是通道数; γ_j 是第 j 通道的缩放参数。

使用 Sigmoid 函数将归一化权重转换为空间信息权重,并通过阈值划分为 W_1 和 W_2 两部分:

$$W_q = Gate(Sigmoid(W_\gamma \cdot GN(Y))) \quad q = 1, 2 \quad (13)$$

式中: $Gate()$ 是阈值门控函数,本文设定为 0.5。

将输入特征 Y 分别与 W_1 和 W_2 相乘,得到加权特征

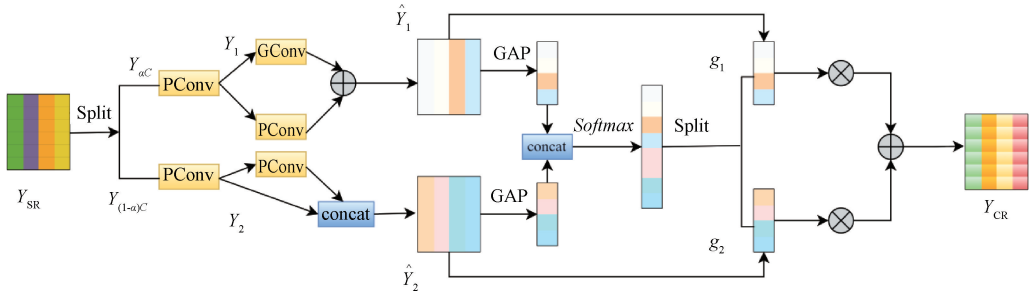


图4 通道特征重构结构

Fig. 4 Channel feature reconstruction structure diagram

将空间重建特征沿通道维度分割为两部分:

$$Y_{SR} \rightarrow Y_{\alpha C}, Y_{(1-\alpha)C} \quad (18)$$

利用逐点卷积 (pointwise convolution, PCConv) 压缩通道数得到 Y_1 与 Y_2 :

$$Y_1 = PCConv(Y_{\alpha C}) \quad (19)$$

$$Y_2 = PCConv(Y_{(1-\alpha)C})$$

式中: α 是分割比例,设为 0.5。

对 Y_1 使用分组卷积 (group convolution, GConv) 和 PCConv 并行扩展通道数,并通过加法操作融合结果得到 \hat{Y}_1 ;对 Y_2 使用 PCConv,并将结果与原始特征拼接得到 \hat{Y}_2 :

$$\hat{Y}_1 = GConv(Y_1) + PCConv(Y_1) \quad (20)$$

$$\hat{Y}_2 = PCConv(Y_2) \cup Y_2$$

对扩展后的特征 \hat{Y}_1 和 \hat{Y}_2 分别进行全局平均池化 (global average pooling, GAP),并通过 Softmax 函数计算通道权重 g :

Y_{W1} 和 Y_{W2} 得到 Y_{W1} 和 Y_{W2} :

$$\begin{cases} Y_{W1} = W_1 \otimes Y \\ Y_{W2} = W_2 \otimes Y \end{cases} \quad (14)$$

式中: \otimes 表示逐元素乘法。

将 Y_{W1} 和 Y_{W2} 沿通道维度分割为两部分:

$$Y_{W1} \rightarrow Y_{W1}^1, Y_{W1}^2 \quad (15)$$

$$Y_{W2} \rightarrow Y_{W2}^1, Y_{W2}^2$$

将信息较少的特征 Y_{W1}^1 和 Y_{W1}^2 与信息丰富的特征 Y_{W2}^2 和 Y_{W2}^1 相加:

$$Y'_{W1} = Y_{W1}^1 + Y_{W2}^2 \quad (16)$$

$$Y'_{W2} = Y_{W2}^2 + Y_{W1}^1$$

最后,通过连接操作得到空间重构特征 Y_{SR} :

$$Y_{SR} = Y'_{W1} \cup Y'_{W2} \quad (17)$$

式中: \cup 表示特征拼接操作。

2) 通道特征重构

通道特征重构的目标是通过通道分割、压缩和扩展操作,进一步优化特征并减少冗余,如图 4 所示。

$$g = Softmax(GAP(\hat{Y}_1) \cup GAP(\hat{Y}_2)) \quad (21)$$

将权重 g 划分为两部分 g_1 和 g_2 ,并应用于特征上。

最终,将权重向量 g_1 和 g_2 分别与 \hat{Y}_1 和 \hat{Y}_2 相乘,并将结果相加,得到最终重构特征 Y_{CR} :

$$Y_{CR} = g_1 \times \hat{Y}_1 + g_2 \times \hat{Y}_2 \quad (22)$$

式中: \times 表示通道乘法。

FORM 模块通过上述空间特征重构和通道特征重构阶段,能够减少冗余特征,提升特征表达能力和学习效率,为后续任务提供更加有效的特征表示,整体结构如图 5 所示。




图5 特征优化重构结构

Fig. 5 Feature optimization and reconstruction module structure diagram

1.4 自适应特征融合模块

本文采用 AFF 模块来处理多源传感器数据特征融合问题,该模块通过动态权重学习与多维度特征表征,实现跨传感器数据特征的自适应深度融合,整体结构如图 6 所示。




图 6 自适应特征融合结构

Fig. 6 Adaptive feature fusion module structure diagram

首先,对两个传感器所得到的特征分别进行全局平均池化和全局最大池化操作以生成两组不同的特征描述:

$$\begin{cases} S_{A-avg}^c = \frac{1}{L} \sum_{i=1}^L F_A^c(i) \\ S_{B-avg}^c = \frac{1}{L} \sum_{i=1}^L F_B^c(i) \end{cases} \quad (23)$$

$$\begin{cases} S_{A-max}^c = \max_{i=1}^L F_A^c(i) \\ S_{B-max}^c = \max_{i=1}^L F_B^c(i) \end{cases} \quad (24)$$

式中: $c = 1, 2, \dots, M$; S_{A-avg}^c 和 S_{B-avg}^c 分别表示传感器 A 和 B 的第 c 个通道的全局平均池化特征; L 表示特征空间的维度; M 是特征通道数; $F_A^c(i)$ 和 $F_B^c(i)$ 分别表示传感器 A 和 B 的第 c 个通道的第 i 个特征值; S_{A-max}^c 和 S_{B-max}^c 分别表示传感器 A 和 B 的第 c 个通道的最大池化特征。

之后,将经过全局平均池化和最大池化操作所获得的两个传感器信号的特征整合,以生成全局表示信息 F_g 并且经过非线性变换,再经过 Softmax 函数以生成每个通道特征权重:

$$F_g = [S_{A-avg}^c, S_{A-max}^c, S_{B-avg}^c, S_{B-max}^c] \quad (25)$$

$$F_z = \text{Softmax}(\sigma(W \cdot F_g + b)) \quad (26)$$

最后,将每个传感器的特征与特征权重相乘。同时,引入残差连接,在原始特征数据与加权特征数据之间建立联系:

$$F = (P_A \otimes F_A + F_A) + (P_B \otimes F_B + F_B) \quad (27)$$

式中: P_A 和 P_B 分别表示传感器 A 和 B 的通道特征权重。

通过上述方式,该模块能够自适应地调整不同传感器特征的融合权重,在保留原始信息的同时增强跨传感器特征的判别能力。

2 CCDFA 故障诊断模型架构

为有效提取复杂工况下不同传感器振动信号的故障特征,本文提出一种端到端的 CCDFA 模型。该模型包含两个并行的特征提取通路,分别处理来自驱动端和风扇端传感器的原始振动信号。每条通路的结构组成一致,均由 DRRM 模块、CBAM 模块、FORM 模块以及 AFF 模块组成,能够显著提升复杂情况下不同传感器振动信号的故障特征提取能力。

2.1 CCDFA 故障诊断模型架构

CCDFA 故障诊断模型结构如图 7 所示。首先,该模型利用驱动端与风扇端传感器的振动信号作为输入以确保模型输入包含丰富的特征;之后,将卷积神经网络与两个 DRRM 模块相结合,以提取数据特征并缓解神经网络训练的梯度消失问题;随后,利用 CBAM 模块筛选和强化关键特征以突出故障特征;其次,利用 FORM 模块对特征进行空间和通道重构,进一步优化特征分布并增强特征的表达能力;然后,使用 AFF 模块对多源特征进行加权融合,以充分利用不同传感器所得到的数据特征。最后,通过全局平均池化层与全连接层(fully connected, FC)以及 Softmax 函数得到故障标签。整个网络通过多层次的特征提取、优化和融合,显著提升了故障诊断的精度和鲁棒性。

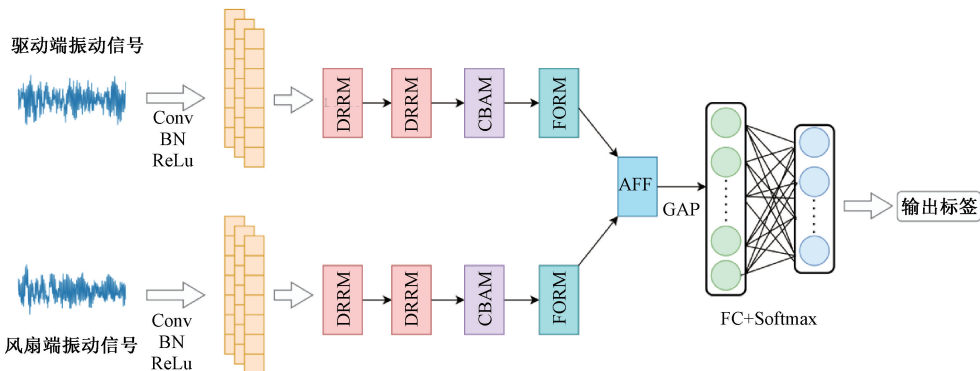


图 7 故障诊断模型

Fig. 7 Fault diagnosis model

2.2 故障诊断流程

基于 CCDFA 模型的轴承故障诊断方法如图 8 所示。首先,系统将驱动端与风扇端传感器采集到的数据划分为训练集、验证集和测试集;其次,在模型训练阶段,系统先初始化模型参数,再通过 CCDFA 模型进行特征提取和训练,同时利用反向传播算法不断优化模型参数。在每次迭代过程中,系统会计算模型的准确率和损失值,若未达到预设的最大迭代次数,则继续训练;反之,保存最优模型参数。最后,使用测试数据集对模型性能进行评估,输出故障诊断结果。

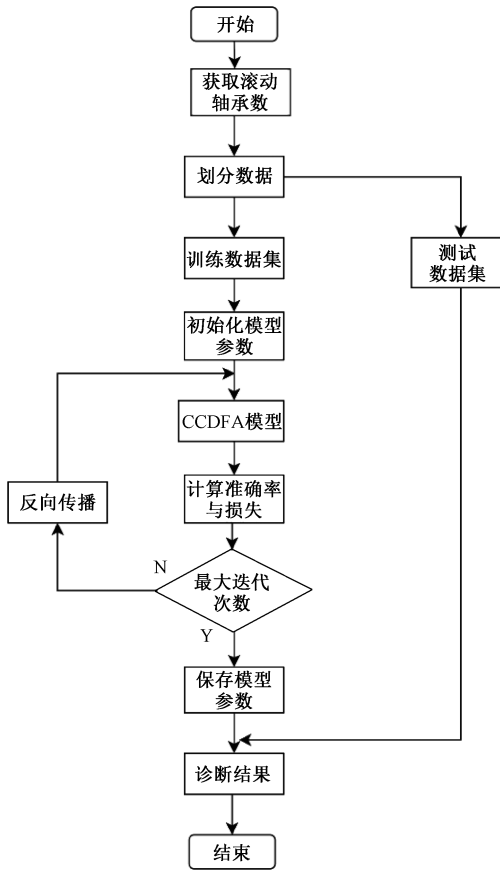


图 8 故障诊断流程

Fig. 8 Fault diagnosis structure process diagram

3 实验验证

3.1 实验数据来源与划分

本文使用美国凯斯西储大学(CWRU)轴承故障数据集。其轴承故障由电火花技术引入,由内圈故障、滚动体故障和外圈故障 3 种故障类型组成,每种故障类型包含 0.177 8、0.355 6 和 0.533 4 mm 3 种尺寸。因此,可将轴承状态分为 9 种故障状态和一种正常状态,如表 1 所示。实验选取安装在电机驱动端与风扇端的传感器所测得的

数据,采样频率设置为 12 kHz,选取 0、1、2 和 3 hp (1 hp ≈ 735 W) 4 种负载混合条件下的所有数据。每个样本截取 1 024 个连续数据点,最终选取的数据集总样本数量为 5 000 个。以 8 : 1 : 1 的方式将数据集划分为训练集、验证集和测试集,其中训练集包含 4 000 个样本,验证集和测试集各包含 500 个样本。每类故障的样本总数为 500 个,按照相同比例划分后,训练集中每类故障包含 400 个样本,验证集和测试集中各包含 50 个样本。

表 1 实验数据集

Table 1 Experimental data set

| 故障 | 损伤程度 | 训/验/测 | 标签 |
|-----|---------|-----------|----|
| 滚动体 | 0.177 8 | 400/50/50 | 1 |
| | 0.355 6 | 400/50/50 | 2 |
| | 0.533 4 | 400/50/50 | 3 |
| 外圈 | 0.177 8 | 400/50/50 | 4 |
| | 0.355 6 | 400/50/50 | 5 |
| | 0.533 4 | 400/50/50 | 6 |
| 内圈 | 0.177 8 | 400/50/50 | 7 |
| | 0.355 6 | 400/50/50 | 8 |
| | 0.533 4 | 400/50/50 | 9 |
| 正常 | — | 400/50/50 | 0 |

实验所使用的计算机为 Windows11 64 位操作系统, Intel Core i5-12400F 处理器, 16 GB 内存, GTX 1060 显卡, 实验环境为 Python 3.8.6, 使用 Paddle 深度学习框架进行模型训练与测试。实验参数设计为 Batchsize 大小为 32, 初始学习率为 0.001, 训练轮数 Epoch 为 200, 使用 Adam 优化器进行训练。CCDFA 模型的部分参数如表 2 所示。

表 2 模型参数设置

Table 2 Model parameter settings

| 模块 | 描述 | 激活函数 | 输出特征图形状 |
|---------|---|-------|------------|
| Conv | 卷积核 3×1 步长 2×1 Conv1: 卷积核 3×1 步长 2×1 | ReLU | 32, 512, 1 |
| DRRM1 | Max Pooling: 核大小 2×1 步长 2×1 Conv2: 卷积核 3×1 步长 2×1 Conv1: 卷积核 3×1 步长 2×1 | PreLU | 32, 128, 1 |
| DRRM2 | Max Pooling: 核大小 2×1 Conv2: 卷积核 3×1 步长 2×1 | PreLU | 32, 64, 1 |
| FORM | GConv: 卷积核 3×1 步长 2×1 分组数 64 PConv: 卷积核 1×1 步长 1×1 | | 32, 64, 32 |
| AFF | FC: 64 | ReLU | 32, 64, 32 |
| Flatten | | ReLU | 65 536, 1 |
| Softmax | FC: 10 | ReLU | 10, 1 |

3.2 模型性能评估与分析

CCDFA 模型在 4 种不同负载情况下的混合数据测

试,训练集与验证集的准确率及损失值随时间变化的情况如图 9 所示。从图 9 可以看出,随着迭代步数的增加,诊断准确率越来越高,同时,当训练轮数分别达到 20 与 50 时,模型在训练集与验证集的准确率趋于最大 1,损失值达到最小。

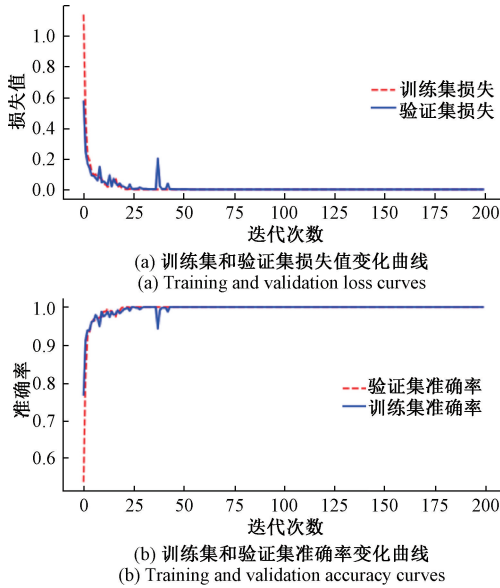


图 9 训练集和验证集准确率及损失变化曲线

Fig. 9 Training and validation accuracy and loss curves

同时,为了观察 CCDFA 模型的故障识别能力以及 CCDFA 模型在 10 类故障中的诊断效果,对测试集样本进行一次随机测试,得到的混淆矩阵如图 10 所示。图 10 中混淆矩阵的主对角线显示了模型正确分类的样本数量,可以看出,该模型能够较为准确的识别出不同的故障类型。




图 10 混淆矩阵

Fig. 10 Confusion matrix

3.3 噪声鲁棒性实验

信噪比 (signal-to-noise ratio, SNR) 表示信号中噪声的强弱。SNR 值越大,表示信号中所含噪声越少^[21-22]。信噪比计算公式如下所示:

$$SNR = 10 \cdot \lg \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \quad (28)$$

为了验证本文提出的 CCDFA 模型在不同噪声条件下的鲁棒性和故障诊断性能,该实验在原始数据中分别添加了信噪比为 -2、-6、-10、-14 和 -18 dB 的高斯白噪声,如图 11 所示,可以看出随着信噪比的降低,噪声强度逐渐增大,原始振动信号逐渐被噪声淹没。

同时,本文实验设计了多个对比方案,包络设置仅采用单驱动端振动信号与仅采用单风扇端振动信号作为输入的 CCDFA 模型变体,以及 ResNet、WDCNN^[23] 及 RSBU-CS^[24] 的经典模型进行比较,验证了 CCDFA 模型设计的有效性。为确保实验公平性,对比实验均使用 CWRU 数据集进行,且各实验参数设置相同。实验结果通过 10 次独立重复实验取平均值获得,实验数据如表 3 所示。可以看出当信噪比在 -2~-18 dB 范围内时,本文所使用的 CCDFA 模型的平均准确率为 97.48%,明显优于其他网络模型。在 -2 dB 条件下,CCDFA 的准确率达到 99.38%,相对于较次优的 RSBU-CS 模型提升了 0.95%;同时,在 -18 dB 条件下,CCDFA 模型仍能保持 95.47% 的准确率。随着噪声从 -2 dB 下降到 -18 dB,CCDFA 模型的性能下降幅度仅为 3.91%,远小于其他模型。实验结果表明所提出模型在噪声环境下具备鲁棒性,同时,能够有效提取故障特征。

表 3 加噪实验测试集故障准确率对比

Table 3 Comparison of fault detection accuracy on noise-injected test sets (%)

| 实验方法 | -2 dB | -6 dB | -10 dB | -14 dB | -18 dB |
|-------------------------|-------|-------|--------|--------|--------|
| 单个驱动端 | 97.78 | 96.27 | 94.43 | 93.40 | 92.26 |
| 单个风扇端 | 97.37 | 97.02 | 95.98 | 94.09 | 93.18 |
| ResNet | 98.01 | 97.35 | 96.71 | 94.35 | 93.87 |
| WDCNN ^[23] | 97.78 | 96.26 | 95.53 | 93.91 | 93.11 |
| RSBU-CS ^[24] | 98.43 | 98.12 | 96.71 | 95.37 | 94.25 |
| CCDFA | 99.38 | 98.56 | 97.44 | 96.53 | 95.47 |

3.4 消融实验对比分析

为了验证 CCDFA 模型中各模块的有效性,本文通过系统的消融实验对 CCDFA 模型进行了模块级性能分析。具体设置了如下 4 种消融实验作为对比:在原模型基础上去除 DRRM 模块,命名为 CCDFA#1;原模型基础上去除 CBAM 模块,命名为 CCDFA#2;原模型基础上去除 FORM 模块,命名为 CCDFA#3;原模型基础上去除 AFF 模块并且使用拼接操作替换以处理不同通道所得到的特征,命名为 CCDFA#4。

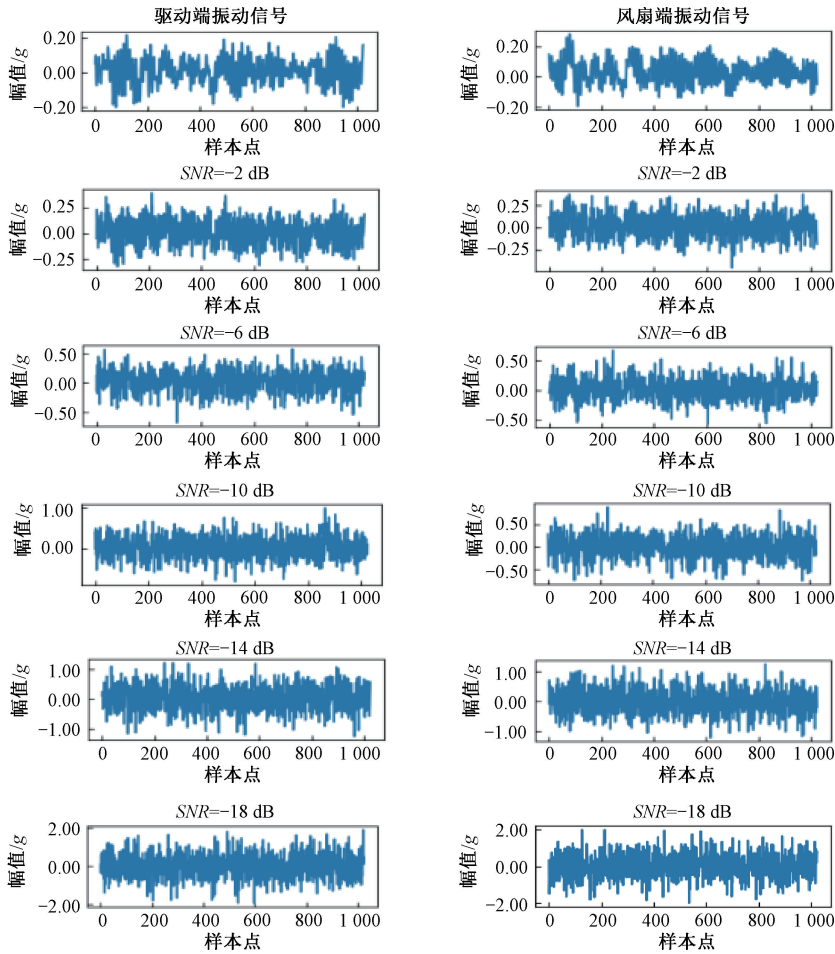


图 11 加噪与未加噪信号对比

Fig. 11 Signals comparison with noisy and noise-free

实验通过 10 次独立重复实验取平均值获得,结果如表 4 所示,在添加了 -2 ~ -18 dB 的不同噪声强度下,完整 CCDFA 模型的平均准确率为 97.48% 显著高于所有消融变体,表明所有模块必须协同工作,才能实现高性能的故障诊断。当模型缺少 DRRM 模块时,平均故障诊断准确率下降至 93.69%,表明该模块能够有效的缓解神经网络训练过程中的梯度消失问题;当缺少 CBAM 模块时,平均准确率为 95.66%,说明 CBAM 模块能显著增强模型对关键特征的专注能力;当移除 FORM 模块时,平均准确率为 95.73%,验证了该模块在消除特征冗余方面的重要作用;当采用简单特征拼接替代 AFF 模块时,平均准确率为 94.76%,表明本文所使用的自适应融合策略能够更好地提取多传感器信息。

3.5 模型可视化分析

为了观察 CCDFA 模型在噪声条件下的故障诊断效果,本文采用 t-SNE (t-distributed stochastic neighbor embedding) 方法对原始数据及 -10 dB 噪声下最优模型

全连接层提取的特征进行二维降维可视化,不同故障类别以不同颜色的散点进行区分。如图 12 所示,可以看出原始数据特征混合严重无法区分,但是经过本文所提出的模型之后,多数故障类别的特征形成了相对独立的聚类簇,展现出良好的类内聚集性和类间分离性。然而,部分故障类别间仍存在重叠现象。这可能是由于强噪声严重污染了故障特征,同时,不同工况数据间的差异性也增加了特征学习的难度。

表 4 消融实验故障诊断准确率对比

Table 4 Comparison table of troubleshooting accuracy of ablation experiments (%)

| 实验方法 | -2 dB | -6 dB | -10 dB | -14 dB | -18 dB |
|---------|-------|-------|--------|--------|--------|
| CCDFA#1 | 97.18 | 95.23 | 93.13 | 92.30 | 90.62 |
| CCDFA#2 | 98.18 | 96.72 | 95.90 | 94.08 | 93.44 |
| CCDFA#3 | 97.95 | 97.13 | 95.49 | 95.08 | 93.01 |
| CCDFA#4 | 96.48 | 95.55 | 94.88 | 93.85 | 93.03 |
| CCDFA | 99.38 | 98.56 | 97.44 | 96.53 | 95.47 |

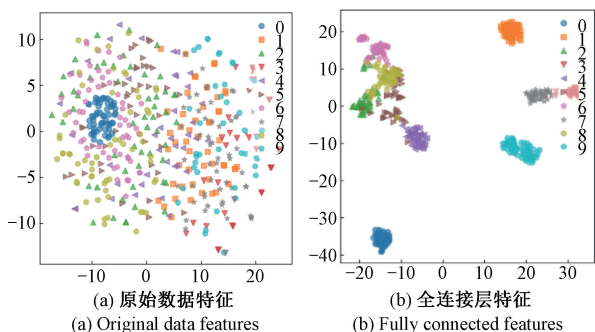


图 12 t-SNE 可视化分析

Fig. 12 t-SNE visualization analysis

4 结 论

本文针对复杂场景下滚动轴承故障诊断面临的噪声干扰和单传感器信息不完整问题,提出了跨传感器特征融合的卷积神经网络。所提模型通过 DRRM 模块、CBAM 模块、FORM 模块和 AFF 模块,同时,使用凯斯西储大学轴承数据集进行验证,有效提升了故障诊断的准确性和鲁棒性。实验结果表明,CCDFA 模型能够有效融合多传感器数据特征,并且在 $-2 \sim -18$ dB 强噪声环境下仍保持较高诊断精度,优于其他对比模型。由于 CCDFA 模型的训练需要大量的样本数据,并且训练时间较长,因此,未来研究将优化模型的小样本适应能力,并提升其在实际场景中的应用性能。

参考文献


- [1] WANG Y, DING X, ZENG Q, et al. Intelligent rolling bearing fault diagnosis via vision ConvNet [J]. IEEE Sensors Journal, 2020, 21(5):6600-6609.
- [2] LIU S, JIANG H, WU Z, et al. Data synthesis using deep feature enhanced generative adversarial networks for rolling bearing imbalanced fault diagnosis [J]. Mechanical Systems and Signal Processing, 2022, 163:108139.
- [3] ZHAO Y J, XU J. A small sample bearing fault diagnosis method based on novel Zernike moment feature attention convolutional neural network [J]. Measurement Science and Technology, 2024, 35(6):066208.
- [4] 王敏, 邓艾东, 马天霆, 等. 基于双注意力机制的 MSCN-BiGRU 的滚动轴承故障诊断方法 [J]. 振动与冲击, 2024, 43(6):84-92, 103.
WANG M, DENG A D, MA T T, et al. Fault diagnosis method for rolling bearings based on MSCN-BiGRU with dual attention mechanism [J]. Journal of Vibration and Shock, 2024, 43(6):84-92, 103.
- [5] 仝兆景, 李金香, 乔征瑞, 等. 基于改进贝叶斯网络的电机轴承故障诊断方法 [J]. 电子测量技术, 2022,

45(7):48-55.

- TONG ZH J, LI J X, QIAO ZH R, et al. A motor bearing fault diagnosis method based on improved Bayesian network [J]. Electronic Measurement Technology, 2022, 45(7):48-55.
- [6] 丁嘉鑫, 王振亚, 姚立纲, 等. 广义复合多尺度加权排列熵与参数优化支持向量机的滚动轴承故障诊断 [J]. 中国机械工程, 2021, 32(2):147-155.
DING J X, WANG ZH Y, YAO L G, et al. Rolling bearing fault diagnosis based on generalized composite multiscale weighted permutation entropy and parameter-optimized support vector machine [J]. China Mechanical Engineering, 2021, 32(2):147-155.
- [7] 李兵, 韩睿, 何怡刚, 等. 改进随机森林算法在电机轴承故障诊断中的应用 [J]. 中国电机工程学报, 2020, 40(4):1310-1319.
LI B, HAN R, HE Y G, et al. Application of improved random forest algorithm in fault diagnosis of motor bearings [J]. Proceedings of the CSEE, 2020, 40(4):1310-1319.
- [8] 王栋瑾, 丁云飞, 朱晨烜. 基于中智 KNN 的齿轮箱故障诊断方法 [J]. 振动与冲击, 2019, 38(20):148-153.
WANG D C, DING Y F, ZHU CH X. Gearbox fault diagnosis method based on neutrosophic KNN [J]. Journal of Vibration and Shock, 2019, 38(20):148-153.
- [9] 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 based on improved masked autoencoder [J]. Chinese Journal of Scientific Instrument, 2024, 45(1):26-33.
- [10] 刘颖, 陶建峰, 黄武涛, 等. 小波包能量与 CNN 相结合的滚动轴承故障诊断方法 [J]. 机械设计与制造, 2021(11):127-131.
LIU Y, TAO J F, HUANG W T, et al. Fault diagnosis method for rolling bearings combining wavelet packet energy and CNN [J]. Machinery Design & Manufacture, 2021(11):127-131.
- [11] CHEN Z, LI W. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network [J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(7):1693-1702.
- [12] 谢锦阳, 姜媛媛, 王力. 基于 RA-LSTM 的轴承故障诊断方法 [J]. 电子测量与仪器学报, 2022, 36(6):213-219.
XIE J Y, JIANG Y Y, WANG L. Bearing fault diagnosis

- method based on RA-LSTM [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (6): 213-219.
- [13] GAO S Z, LI T C, ZHANG Y M, et al. Fault diagnosis method of rolling bearings based on adaptive modified CEEMD and 1DCNN model [J]. ISA Transactions, 2023, 140:309-330.
- [14] XUE L L, LEI C L, JIAO M X, et al. Rolling bearing fault diagnosis method based on self-calibrated coordinate attention mechanism and multi-scale convolutional neural network under small samples [J]. IEEE Sensors Journal, 2023, 23 (9): 10206-10214.
- [15] SUN J D, WEN J T, YUAN C Y, et al. Bearing fault diagnosis based on multiple transformation domain fusion and improved residual dense networks [J]. IEEE Sensors Journal, 2022, 22 (2): 1541-1551.
- [16] WANG D C, LI Y B, SONG Y, et al. Bearing fault diagnosis method based on complementary feature extraction and fusion of multisensor data [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 99:1.
- [17] CHOUDHARY A, MISHRA R K, FATIMA S, et al. Multi-input CNN based vibro-acoustic fusion for accurate fault diagnosis of induction motor [J]. Engineering Applications of Artificial Intelligence, 2023, 120:105872.
- [18] XUE Y P, WEN B C, WANG Z D, et al. A novel framework for motor bearing fault diagnosis based on multi-transformation domain and multi-source data [J]. Knowledge-Based Systems, 2024, 283:111205.
- [19] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:770-778.
- [20] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. European Conference on Computer Vision (ECCV), 2018:3-19.
- [21] ZHANG K, TANG B, DENG L, et al. A fault diagnosis method for wind turbines gearbox based on adaptive loss weighted meta-ResNet under noisy labels [J]. Mechanical Systems and Signal Processing, 2021, 161:107963.
- [22] YAN X, YAN W J, XU Y, et al. Machinery multi-sensor fault diagnosis based on adaptive multivariate feature mode decomposition and multi-attention fusion residual convolutional neural network [J]. Mechanical Systems and Signal Processing, 2023, 202:110664.
- [23] SHAO S Y, RU Q Y, LU Y D, et al. DCNN-based multi-signal induction motor fault diagnosis [J]. IEEE Transactions on Instrumentation & Measurement, 2020, 69:2658-2669.
- [24] ZHAO M H, ZHONG S S, XU Y F, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16 (7): 4681-4690.

作者简介



吕轶, 2012 年于东北大学获得博士学位, 现为沈阳航空航天大学副教授, 硕士生导师, 主要研究方向为信号检测与处理、电磁成像。

E-mail: lvyi_julia@126.com

Lyu Yi received her Ph. D. degree from Northeastern University in 2012. She is now an associate professor and M. Sc. supervisor at Shenyang Aerospace University. Her main research interests include signal detection and processing, and electromagnetic imaging.



祝志荣 (通信作者), 现为沈阳航空航天大学硕士研究生, 主要研究方向为信息获取与处理技术、轴承故障诊断。

E-mail: zZR151525@163.com

Zhu Zhirong (Corresponding author) is now a M. Sc. candidate at Shenyang Aerospace University. His main research interests include information acquisition and processing technology, and bearing fault diagnosis.