

振动-声学异构信号迁移学习故障诊断方法*

赵豪雨¹, 曹培¹, 马泰安²

(1. 西北农林科技大学机械与电子工程学院 杨凌, 712100)

(2. 西安交通大学机械工程学院 西安, 710049)

摘要 针对齿轮及轴承故障检测方法依赖人工特征提取、复杂工况下适应性差以及跨信号类型与跨工况迁移能力弱等问题, 提出基于迁移学习的振动-声学故障诊断方法。首先, 采集齿轮与轴承振动数据集及声学信号数据集, 进行归一化与分段切片等预处理形成统一长度样本; 其次, 利用格拉姆差角场 (Gramian angular difference field, 简称 GADF) 将一维振动时序信号映射为二维时频图像, 突出时序相关性与局部幅值变化, 使其适配卷积特征提取, 在此基础上构建卷积神经网络 (convolutional neural network, 简称 CNN) 源域模型, 实现端到端学习与分类, 获得可迁移的深层特征表示, 并将源域权重作为目标域训练初始化, 在多云工况条件下源域诊断准确率大于 98.5%; 最后, 面向声学信号分布差异与样本稀缺场景, 设计振动 (源域) 到声学 (目标域) 的跨信号类型迁移策略, 采用浅层卷积层参数冻结以保留通用表征能力, 并对深层判别层进行微调以重构决策边界, 建立跨工况声学诊断模型。实验结果表明: 目标域平均准确率达 90.4%, 较从新训练 CNN 提升 5.3%, 训练时间缩短 35.5%; t-分布邻域嵌入 (t-distributed stochastic neighbor embedding, 简称 t-SNE) 对网络特征降维结果显示迁移后类间间隔增大、类内聚合增强, 验证特征可分性提升; 所提方法实现异构监测数据特征共享与知识复用, 可在监测与传感器布置受限条件下降低对振动单一测点/传感器的依赖, 支持振动与声学协同监测, 为多云工况、多信号类型旋转机械故障诊断提供工程化支撑, 并提升声学诊断模型构建效率。

关键词 故障诊断; 卷积神经网络; 振动-声学信号; 迁移学习
中图分类号 TH165.3; TH17

0 引言

齿轮及轴承作为旋转机械动力传动系统的核心部件, 广泛应用于航空航天、电力和交通运输等工业装备中, 其运行状态直接影响系统的运行安全性与可靠性。然而, 在复杂工况和长期服役条件下, 齿轮与轴承易发生损伤或出现故障, 若未能及时诊断与排除, 会导致严重后果^[1]。因此, 研究齿轮与轴承运行状态的监测与智能诊断方法具有重要的工程意义和应用价值。

传统的机械故障诊断方法主要依赖信号处理技术与浅层机器学习模型, 采用小波变换、经验模态分解等常用时频分析技术对监测信号进行特征提取^[2-3], 结合支持向量机 (support vector machine, 简称 SVM)、多层感知机 (multilayer perceptron, 简称 MLP) 等分类器构建故障诊断模型。然而, 这类方法存在以下不足: ① 过度依赖专家经验进行人工特征工程设计, 对复杂多变的工况适应性较差; ② 浅层

机器学习模型的表征能力有限, 难以满足跨域故障诊断任务的需求。近年来, 深度学习因其自动特征提取与强大表征能力而成为机械故障诊断领域研究热点^[4]。CNN 作为深度学习的重要分支, 能够充分挖掘传感器信号的时空特征, 在滚动轴承、齿轮等旋转机械故障诊断中展现出显著优势^[5]。已有研究表明, 基于 CNN 的端到端故障诊断方法可通过将信号转化为图像输入网络, 实现对旋转机械故障的高精度诊断, 并在多源信息融合、多任务故障诊断等方面展现出良好的应用潜力^[6-8]。需要指出的是, 现有基于深度学习的机械故障诊断方法仍面临以下挑战: ① 诊断模型对大量标注样本存在较强依赖, 而实际工程中同一工况条件下故障数据往往稀缺; ② 工况变化会导致监测数据分布偏移, 进而降低模型的泛化性能^[9-10]。

迁移学习为解决跨工况、跨信号类型的故障诊断问题提供了新的思路。研究者们还利用声学或声

* 国家自然科学基金青年基金资助项目 (32301698); 陕西省重点产业链资助项目 (2023-ZDLNY-58); 中央高校基本科研业务费专项资金资助项目 (Z1011124001)

收稿日期: 2025-10-30; 修回日期: 2025-12-09

发射信号进行旋转机械状态监测,或将振动与声学信息联合分析。研究表明,声学/声发射信号在高频段对裂纹萌生、齿面早期微损伤等故障更为敏感,而振动信号在中低频段能较好地反映整体动力学响应,二者在频带覆盖和故障演化阶段的敏感性上具有互补性^[11]。部分研究通过时频分析与特征级融合实现振动-声学联合诊断^[12],或引入迁移学习或域适配方法,将某一传感器通道学到的故障知识迁移至其他通道,以提升少样本条件下的诊断性能^[13]。然而,现有研究多聚焦于同平台、同步采集的多传感器信号,较少涉及公开振动数据与新采集声学数据的跨域迁移应用^[14]。迁移学习通过将源域数据的特征学习成果迁移至目标域诊断任务中,能显著提升跨工况条件下的诊断性能,减少目标域对训练数据的依赖,缩短训练时间并提高诊断效率^[15],为实际工业故障诊断提供了有效的解决方案^[16]。

笔者提出一种基于迁移学习的齿轮及轴承振动-声学信号故障诊断方法:首先,获取齿轮和轴承故障的振动数据集与声学信号数据集,经过预处理后通过 GADF 将一维时序信号映射为二维时频图像,并利用振动信号建立源域深度学习诊断模型;其次,设计振动-声学信号的迁移机制,将源域的振动信号诊断知识迁移到目标域的声信号中,实现两者在故障诊断任务中的协同应用。该方法旨在解决跨工况、跨信号类型下特征分布差异与样本稀缺问题,为旋转机械的故障诊断提供一种新方法。

需要指出的是,笔者并未在同一平台上同步采集振动与声学信号,而是选择公开的齿轮箱振动基准数据集作为源域,并使用自建实验台采集的声学数据作为目标域。这一设置反映了实际工程中的常见情况:某些设备在初期建设阶段已经布置了完善的振动监测系统,积累了大量的历史数据;但在后续推广或改造过程中,由于成本和空间限制,新现场往往更倾向于采用非接触且灵活布置的声学监测手段。在这种背景下,如何利用已有的振动故障知识提升新工况下声学监测的诊断性能,成为迁移学习亟需解决的问题。因此,笔者构建的公开振动数据加自采声学数据实验方案,本质上是一种跨工况、跨信号类型的迁移诊断验证场景,更加贴近工程应用的实际需求。

1 数据采集与预处理

1.1 振动信号数据集与特征提取

为建立源域诊断模型,笔者选用东南大学公开

的齿轮箱振动基准数据集^[17]。该数据集通过 SpectraQuest 动力传动故障诊断实验平台采集,涵盖齿轮和轴承2类旋转机械部件的典型故障模式。实验设置2种工况:①转速为20 Hz、负载为0 V,即(20 Hz, 0 V);②转速为30 Hz、负载为2 V,即(30 Hz, 2 V)。其中,转速为20 Hz和30 Hz分别对应该平台较典型的低速与中速运行状态,可代表齿轮箱在常见工况下的受力与啮合特征差异。采样频率设为5 120 Hz,覆盖由转频到啮合频率及其倍频、边带在内的主要振动频段,每组原始信号包含1 048 560个采样点。在后续 GADF 编码与 CNN 识别过程中,不再人为限定或筛选特定频带,而是保留从低频转速成分到中高频啮合与缺陷调制成分在内的全频段信息,由网络自动从中挖掘与故障相关的判别特征。

振动信号数据集的信号分割如图1所示。在数据预处理环节,首先,对原始信号进行归一化与时域分割,采用1 024点非重叠窗生成样本,每组可获得1 000条独立记录;其次,依据故障类别对样本进行标注,分别构建轴承和齿轮子数据集;最后,将2类数据融合,形成包含9种故障模式的混合数据集。经上述处理,得到规模为 $9\,000 \times 1\,025$ 的结构化矩阵,其中,前1 024列为标准化振动时序数据,最后1列为故障类别标签。

表1~3分别为轴承数据集、齿轮数据集以及混合数据集的结构。该设计实现了原始信号与诊断知识的对应映射,为后续深度学习模型的构建提供了标准化输入。




图1 振动信号数据集的信号分割

Fig.1 Signal segmentation of the vibration signal dataset

笔者将东南大学公开的齿轮箱振动基准数据集作为源域的标准故障样本库,用于学习齿轮及轴承在典型工况下的振动故障特征,再将这些特征迁移至自采声学数据,实现跨工况的知识迁移。这不仅保证了研究结果的可复现性和与已有工作的可比性,也更符合源域数据充分、目标域数据有限的工程现实。

表 1 轴承数据集结构

Tab.1 Structure of the bearing fault sub-dataset

故障类型	工况	样本个数	数据长度	标签
滚动体裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	0
内外圈复合故障	(20 Hz,0 V)、(30Hz,2 V)	1 000	1 024	1
健康状态	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	2
内圈裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	3
外圈裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	4

表 2 齿轮数据集结构

Tab.2 Structure of the gear fault sub-dataset

故障类型	工况	样本个数	数据长度	标签
底部裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	0
健康状态	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	1
齿轮断齿	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	2
根部裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	3
表面磨损	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	4

表 3 混合数据集结构

Tab.3 Structure of the hybrid fault sub-dataset

故障类型	工况	样本个数	数据长度	标签
滚动体裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	0
内外圈复合故障	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	1
健康状态	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	2
内圈裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	3
外圈裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	4
底部裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	5
齿轮断齿	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	6
根部裂纹	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	7
表面磨损	(20 Hz,0 V)、(30 Hz,2 V)	1 000	1 024	8

1.2 声音信号采集流程设计

为实现跨信号类型迁移学习,笔者在自建齿轮箱实验平台上采集声信号作为目标域数据。与源域公开振动数据相比,自建平台在传动结构形式、安装环境及转速设置等方面存在一定差异,但二者的故障机理均源于齿轮啮合过程中的啮合冲击与接触损伤,均包含健康、断齿与表面磨损等典型齿轮状态,在故障类别语义上保持一致。

声音信号采集实验平台如图 2 所示,采用 MPA4171/4 英寸自由场传声器在齿轮箱近场位置(距 20 mm)采集声压信号。实验设置 4 种转速工况(9、14、17 和 21 Hz),覆盖了该齿轮箱由低速到接近额定转速的典型运行区间。在空载条件下分别获得健康、断齿与表面磨损 3 种典型齿轮状态。采样频率为 10 240 Hz,每段信号采集时长为 5 s,共得到




图 2 声音信号采集实验平台

Fig.2 Sound signal acquisition experimental platform

960 组样本。结合采样频率,声学信号在 0~5 kHz 频段内能够完整捕获齿轮啮合噪声、高频撞击以及早期损伤产生的宽带特征,从频带分布上与振动信号形成互补。

在数据处理流程中,笔者保持与振动信号相同的分割与标签规范,最终形成大小为 $2\,880 \times 1\,025$ 的齿轮箱声音信号数据集,如表 4 所示。该一致性设计保证了振动、声学信号数据在时间分辨率与样本容量上的对齐性,为迁移学习建立了可比性基础。

表 4 齿轮箱声音信号数据集
Tab.4 Gearbox sound signal dataset

故障类型	工况	样本 个数	数据 长度	标签
健康状态	(9 Hz, 0 V)、(14 Hz, 0 V) (17 Hz, 0 V)、(21 Hz, 0 V)	960	1 024	0
齿轮断齿	(9 Hz, 0 V)、(14 Hz, 0 V) (17 Hz, 0 V)、(21 Hz, 0 V)	960	1 024	1
表面磨损	(9 Hz, 0 V)、(14 Hz, 0 V) (17 Hz, 0 V)、(21 Hz, 0 V)	960	1 024	2

为保证实验的可重复性与统计学可靠性,对预处理后的振动与声学信号均按 8:2 比例随机划分训练集与测试集。其中,训练集(80%)用于模型参数优化,测试集(20%)用于模型验证与性能评估。该划分策略既能有效防止过拟合,又可保证结果的稳健性。考虑到源域数据在设备和工况上的差异,笔者设计了一个更具挑战性的跨工况、跨信号类型的迁移任务。这种设置有助于检验所提方法在实际工程场景中的鲁棒性和推广能力,而非仅限于理想条件下的同平台、同步采集验证。

2 GADF-CNN 源域诊断模型构建

2.1 GADF 图像编码理论

在机械故障诊断中,信号表示方式直接决定了特征提取与分类性能。笔者引入格拉姆差角场方法,将一维振动信号映射为二维时频图像,用作卷积神经网络的输入。与频谱图、递归图等传统时频表征方法相比,GADF 在非平稳信号处理与计算复杂度方面具有优势。

其核心思想如下:首先,对原始时序信号进行归一化处理,使其映射到区间 $[0, 1]$,从而保证信号值与极角映射的一一对应关系。假设一维时间序列为 $X = x_1, x_2, \dots, x_N$,定义规范化后的格拉姆矩阵 G 为

$$G = \begin{pmatrix} \cos(\phi_{1,1}) & \cos(\phi_{1,2}) & \cdots & \cos(\phi_{1,n}) \\ \cos(\phi_{2,1}) & \cos(\phi_{2,2}) & \cdots & \cos(\phi_{2,n}) \\ \vdots & \vdots & & \vdots \\ \cos(\phi_{n,1}) & \cos(\phi_{n,2}) & \cdots & \cos(\phi_{n,n}) \end{pmatrix} \quad (1)$$

其中: $\phi_{i,j}$ 为向量 i 和向量 j 之间的夹角。

然后,将标准化后的序列映射到极坐标系,利用时间戳与信号幅值建立极径与极角之间的对应关系,即

$$\begin{cases} \phi_i = \arccos \tilde{x}_i \\ r_i = \frac{t_i}{N} \end{cases} \quad (2)$$

其中: $\tilde{x}_i$ 为 X 规范化之后的值; $t_i \in N$,为点 $\tilde{x}_i$ 的时间戳; N 为序列中所包含的点的个数。

在此基础上计算不同时间点间的极角差值,二维差角场矩阵的表达式为

$$G = [\sin(\phi_i - \phi_j)] = \sqrt{I - \tilde{X}^2} \cdot \tilde{X} - X' \sqrt{I - \tilde{X}^2} \quad (3)$$

通过上述变换,生成的二维图像既保持了原始信号的全局时序特征,又增强了局部幅值波动特性。图 3 为混合数据集在(20 Hz, 0 V)工况下的 GADF 图像,不同故障状态在纹理与结构特征上表现出明显差异。




图 3 混合数据集在(20 Hz, 0 V)工况下的 GADF 图像
Fig.3 GADF images of the hybrid dataset under the operating condition of 20 Hz rotational speed and 0 V load

综合来看,GADF 表征具有以下优势:①避免短时傅里叶变换在时频分辨率上的固有限制;②减少递归图对阈值设定的敏感性;③便于卷积神经网络捕获故障特征。因此,GADF 编码为后续深度学习的端到端故障诊断提供了理想输入。

2.2 卷积神经网络架构设计

深度卷积神经网络已在图像识别和故障诊断领域取得广泛应用。结合任务需求与计算复杂度,笔者选择VGG-16作为基础网络。该模型以统一的 3×3 卷积核和逐层加深的结构为特点,能够在保持计算效率的同时充分提取图像特征。相比之下,ResNet与DenseNet虽具更优的梯度传播与特征复用能力,但结构复杂,训练开销较大;EfficientNet虽以高效性著称,但依赖架构搜索,开发成本较高。因此,VGG-16在本研究中实现了性能与复杂度的平衡。

结合旋转机械故障诊断任务的需求,笔者构建的VGG-16网络由5个卷积模块和3层全连接层组成,最终通过Softmax分类器输出分类结果。训练参数设置如下:迭代轮次为100,批大小为32;优化器采用Adam,同时监控训练集与测试集的分类准确率,以动态评估模型收敛性能。图4为VGG-16网络结构示意图。




图4 VGG-16网络结构示意图


Fig.4 Schematic diagram of the VGG-16 network

2.3 模型性能验证与对比分析


图5为GADF-CNN模型在转速为20 Hz、负载为0 V工况下的训练结果。模型在训练过程中准确率与损失曲线的变化如图5(a)、(b)所示,整体收敛性良好。测试阶段得到的混淆矩阵与受试者工作特征曲线(receiver operating characteristic curve,简称ROC)曲线如图5(c)、(d)所示,表明分类结果理想且稳定。

在完成各工况下的模型训练后,计算分类模型的性能评价指标。


1) 准确率表示模型正确分类样本数占总样本数的比例,表达式为



(a) 准确率曲线
(a) Accuracy curve




(b) 损失曲线
(b) Loss curve



(c) 混淆矩阵

(c) Confusion matrix



(d) ROC曲线
(d) ROC curve

图5 GADF-CNN模型在(20 Hz,0 V)工况下的训练结果

Fig.5 Training results of the GADF-CNN model under the operating condition of 20 Hz rotational speed and 0 V load

$$A_{cc} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

其中:TP为被正确分类为正类的样本数;FP为被错误分类为正类的负类样本数;TN为被正确分类为

负类的样本数;FN为被错误分类为负类的正类样本数。

2) 精确率表示被预测为正类的样本中,真正为正类的比例,表达式为

$$P_{re} = \frac{TP}{TP + FP} \tag{5}$$

3) 召回率表示真实正类样本中,被正确识别为正类的比例,表达式为

$$R_{ec} = \frac{TP}{TP + FN} \tag{6}$$

4) F_1 值用于综合评价模型在精确率与召回率之间的平衡性能,表达式为

$$F_1 = 2P_{re}R_{ec}/(P_{re} + R_{ec}) \tag{7}$$

5) ROC曲线通过绘制真正例率(TPR)与假正

例率(FPR)的关系反映模型性能。TPR和FPR的表达式分别为

$$TPR = \frac{TP}{TP + FN} \tag{8}$$

$$FPR = \frac{FP}{FP + TN} \tag{9}$$

表5为GADF-CNN模型在测试集上的性能评估,其中,AUC为ROC曲线下面积。结果表明,GADF-CNN模型在6种工况下的故障诊断准确率均超过98.5%,最高达99.7%,其他性能指标也表现出接近理想的结果。这些结果表明,GADF-CNN模型不仅在源域数据上实现了高精度的故障诊断,而且展示了出色的特征表征能力和类间分离能力,为后续的迁移学习提供了坚实的基础。

表 5 GADF-CNN 模型在测试集上的性能评估

Tab.5 Performance evaluation of the GADF-CNN model on the test set

故障类型	工况	准确率 $A_{cc}/\%$	精确率 $P_{re}/\%$	召回率 $R_{ec}/\%$	F_1 值/ $\%$	AUC
轴承	(20 Hz, 0 V)	99.70	99.23	99.97	99.60	1
轴承	(30 Hz, 2 V)	99.50	100.00	100.00	100.00	1
齿轮	(20 Hz, 0 V)	99.20	100.00	100.00	100.00	1
齿轮	(30 Hz, 2 V)	99.70	99.92	98.87	99.39	1
混合	(20 Hz, 0 V)	99.56	98.92	98.85	98.89	1
混合	(30 Hz, 2 V)	98.50	99.58	99.13	99.35	1

3 振动-声学信号迁移学习模型研究

3.1 迁移学习网络设计

CNN通常由特征提取器和分类器2部分组成:前者由卷积层和池化层构成,用于逐层提取边缘、纹理及高层语义等特征;后者由全连接层构成,将高维特征映射到故障类别空间。

迁移学习的核心在于利用源域知识帮助目标域学习。对于同信号类型任务(如相同传感器采集的数据),常采用冻结特征提取器与微调分类器的策略。由于在跨信号类型任务中,源域为振动信号,目标域为声学信号,二者在信号传播路径与传感器响应上存在差异,因此直接迁移会引入分布偏移。为此,笔者提出分层迁移策略,即在迁移过程中,冻结浅层卷积层以保持通用特征的提取能力,同时对深层卷积层与分类器进行微调,以适配声学信号的频域特性。

需要说明的是,网络在迁移过程中并不要求振动与声学信号中的每一个局部特征实现一一对应。冻结的浅层卷积层主要学习到边缘、纹理等低级结

构模式,其中包含一部分与故障无关但在不同信号类型中普遍存在的特征。通过在声学目标域上对深层卷积层和全连接分类器进行微调,网络会在反向传播过程中自动抑制那些只在源域中有效、但与目标域声学诊断无关的特征响应,同时增强对2种信号中共同反映故障机理(如啮合冲击、调制成分等)的高层抽象特征的敏感度。换言之,非对应特征在迁移过程中被降权或忽略,而共享故障特征则被保留并重用,从而实现跨信号类型的有效知识迁移。

图6为VGG-16网络的迁移学习模型结构示意图。该策略合理性主要体现在2方面:

1) 结构一致性:虽然信号采集方式和传感器类型不同,但2类信号均反映了齿轮啮合过程中的故障模式,在故障类型上具有高度对应性。经过GADF编码后,振动和声学信号的时频图像在空间拓扑结构上呈现出相似性,能够有效支持跨信号类型的迁移学习。

2) 物理相关性:振动信号和声学信号均源自齿轮啮合过程中产生的能量辐射,二者在频域特征上存在耦合关系。振动信号主要反映齿轮接触和运动




图6 VGG-16网络的迁移学习模型结构示意图

Fig.6 Schematic diagram of the transfer learning model based on VGG-16 network

的机械响应,而声学信号则捕捉到由此产生的声波传播,二者在故障状态下的特征具有较强的关联性,能够为故障诊断提供互补的信息。

通过冻结与微调相结合的方式,模型能够在保留源域知识的同时,学习声学信号特有特征,从而实现有效迁移。

3.2 振动-声学信号迁移性能评估

为验证方法有效性,笔者在不同转速工况下进行了迁移学习实验。训练参数设定与源域模型一

致,图7为迁移学习模型在转速为21 Hz、负载为0 V工况下的训练结果。模型在训练过程中准确率与损失曲线的变化如图7(a)、(b)所示,图7(b)中的损失为多类别交叉熵损失。由于源域振动特征与目标域声学特征在分布上存在明显差异,且网络在训练初期参数仍接近随机初始化,因此损失初值较高属于正常现象。随着训练迭代的推进,损失值快速下降并趋于稳定,与图7(a)中准确率稳步提升的趋势相一致,整体收敛性良好。测试阶段得到的混淆矩阵与ROC曲线如图7(c)、(d)所示,表明分类结果理想且稳定。




图7 迁移学习模型在(21 Hz, 0 V)工况下的训练结果

Fig.7 Training results of the transfer learning model under the operating condition of 21 Hz rotational speed and 0 V load

表 6 为迁移学习模型在测试集上的性能评估结果。结果显示,模型在 4 类工况下的诊断准确率分别为 86.63%、89.5%、91.33% 和 93.92%,平均准确率达到 90.4%;各工况的 F_1 值均在 83% 以上,AUC 值均超过 0.97,说明迁移学习模型在多工况条件下具有较强的稳定性与可靠性。

表 6 迁移学习模型在测试集上的性能评估结果

Tab.6 Performance evaluation results of the transfer learning model on the test set						
工况	$A_{cc}/\%$	$P_{re}/\%$	$R_{ec}/\%$	$F_1/\%$	AUC	训练时间/s
(9 Hz, 0 V)	86.63	81.68	90.14	85.69	0.97	908
(14 Hz, 0 V)	89.50	82.46	84.57	83.47	0.97	908
(17 Hz, 0 V)	91.33	88.04	90.28	89.13	0.98	909
(21 Hz, 0 V)	93.92	94.16	90.72	92.39	0.99	907

需要指出的是,笔者更关注的是在多工况测试集上的识别性能及其波动情况,而非单次训练过程中损失函数的绝对数值。由表 6 可见,在 9、14、17 和 21 Hz 这 4 种转速工况下,模型的 A_{cc} 、 F_1 值与 AUC 均保持在较高水平,说明在存在较大域间差异的条件下,迁移学习模型在目标域声学诊断任务中仍具有较好的泛化能力。

此外,将迁移学习模型与未经预训练的 VGG-16 基准模型在识别准确率和训练效率方面进行了对比。迁移学习模型与基准模型训练效果对比结果如图 8 所示。基准模型的平均准确率仅为

85.1%,训练时间长达 1 408 s;相比之下,迁移学习模型不仅实现了更高的诊断精度,同时显著缩短了训练时间,整体性能优于传统从新训练模式。

3.3 特征可视化与机制分析

为深入揭示深度学习与迁移学习在特征表征方面的作用,笔者采用 t-SNE 对振动与声学信号的原始特征、深度网络输出特征以及迁移学习优化后的特征空间进行了可视化分析。图 9 为混合数据集原




图 8 迁移学习模型与基准模型训练效果对比结果
Fig.8 Comparison between transfer learning model and base-line model




图 9 混合数据集原始特征及 GADF-CNN 模型输出特征的 t-SNE 可视化结果
Fig.9 t-SNE visualization results of the original features of the mixed dataset and the output features of the GADF-CNN model

始特征及 GADF-CNN 模型输出特征的 t-SNE 可视化结果。图 10 为声学信号原始特征及迁移学习模型优化后特征的 t-SNE 可视化结果。




图 10 声学信号原始特征及迁移学习模型优化后特征的 t-SNE 可视化结果

Fig.10 t-SNE visualization results of the original features of acoustic signals and the optimized features of the transfer learning model

结果表明:在原始特征空间中,不同故障类别之间存在较大重叠,难以形成清晰的分类边界,说明直接利用原始信号进行诊断存在显著困难。经过 GADF-CNN 深度学习模型提取后,特征分布呈现出较好的聚类趋势,类间区分度明显增强,验证了深度学习在特征抽象与可分性提升方面的优势。在迁移学习机制作用下,健康、断齿与表面磨损 3 类故障在二维空间中形成边界清晰、类间分离度高的聚类结构。该结果表明,迁移学习不仅有效实现了源域知识向目标域的迁移,还进一步增强了声学信号特征的可分性与稳健性,充分验证了分层冻结与微调策略的合理性。从 t-SNE 可视化结果可以看出,经过迁移学习优化后,不同故障类别在声学特征空间中的聚类紧凑、边界清晰,说明大量在源域中存在但对目标域声学诊断不具判别力的非对应特征已被网络自动削弱或过滤。

深度学习与迁移学习的协同作用改善了特征空间分布,使模型能够在多工况条件下保持优良的诊断性能,同时降低了训练开销,展现出在工业设备多源异构信号协同诊断中的应用潜力。

4 结 论

1) 利用齿轮及轴承振动信号,构建了基于格拉姆差角场与 CNN 的源域深度学习模型框架,实现了一维振动信号向二维时频图像的映射,并在多工况下获得超过 98.5% 的诊断准确率,优于传统浅层方法。

2) 提出跨信号类型迁移学习策略,通过浅层冻结与深层微调实现振动特征向声学特征的有效迁移。在声学信号分类中,平均准确率达 90.4%,较基准模型提升 5.3%,训练时间缩短 35.5%。

3) t-SNE 可视化结果表明,迁移学习优化后的特征空间呈现类间边界清晰、类内聚合紧密的分布格局,进一步验证了其增强特征可分性与解释性的能力。


4) 本研究在方法上拓展了单一振动信号向振动-声学联合诊断的应用边界,在已有振动故障知识的辅助下,验证了基于声学信号开展故障识别的可行性,在部分受限工况下为降低对单一振动测点的依赖提供了一种思路,但声学监测在工程应用中仍应与振动监测形成互补,而非简单替代。

5) 笔者训练与测试数据均采自实验台架,现场工况下还存在更加复杂的背景噪声、结构耦合与工况波动等因素,模型在工业现场的实际表现仍需进一步评估与优化。

参 考 文 献

- [1] YU X L, ZHAO Z B, ZHANG X W, et al. A universal transfer network for machinery fault diagnosis[J]. Computers in Industry, 2023, 151: 103976.
- [2] GILLES J. Empirical wavelet transform[J]. IEEE Transactions on Signal Processing, 2013, 61(16): 3999-4010.
- [3] 李俊逸, 尧远, 刘明浩. 基于振动信号最优特征提取算法的风力机齿轮箱 SVM 故障诊断[J]. 太阳能学报, 2024, 45(7): 626-633.
LI Junyi, YAO Yuan, LIU Minghao. Fault diagnosis of wind turbine gearbox based on optimal feature extraction algorithm of vibration signal using SVM[J]. Acta Energetica Solaris Sinica, 2024, 45(7): 626-633. (in Chinese)

- [4] PLAKIAS S, BOUTALIS Y S. A novel information processing method based on an ensemble of auto-encoders for unsupervised fault detection[J]. Computers in Industry, 2022, 142: 103743.
- [5] WU C Z, JIANG P C, DING C, et al. Intelligent fault diagnosis of rotating machinery based on one-dimensional convolutional neural network[J]. Computers in Industry, 2019, 108: 53-61.
- [6] 朱岸锋, 赵前程, 周凌, 等. 基于 CNN-LSTM-Attention 的风电机组状态监测与健康评估[J]. 振动、测试与诊断, 2025, 45(2): 256-263.
ZHU Anfeng, ZHAO Qiancheng, ZHOU Ling, et al. State monitoring and health assessment of wind turbines based on CNN-LSTM-Attention[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(2): 256-263. (in Chinese)
- [7] WEN L, LI X Y, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method [J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [8] 刘涛, 麻德权. 基于 CBAM-CNN 的涡旋压缩机故障诊断[J]. 振动、测试与诊断, 2024, 44(5): 900-906.
LIU Tao, MA Dequan. Fault diagnosis of scroll compressor based on CBAM-CNN [J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(5): 900-906. (in Chinese)
- [9] ZHAO X L, YAO J Y, DENG W X, et al. Intelligent fault diagnosis of gearbox under variable working conditions with adaptive intraclass and interclass convolutional neural network[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(11): 6339-6353.
- [10] 张亚洲, 赵小强, 惠永永, 等. 基于多传感器数据融合的 SA-DACNN 齿轮箱故障诊断方法[J]. 控制与决策, 2024, 39(11): 3699-3708.
ZHANG Yazhou, ZHAO Xiaoqiang, HUI Yongyong, et al. Gearbox fault diagnosis method based on multi-sensor data fusion and SA-DACNN[J]. Control and Decision, 2024, 39(11): 3699-3708. (in Chinese)
- [11] TIBONI M, REMINO C, BUSSOLA R, et al. A review on vibration-based condition monitoring of rotating machinery[J]. Applied Sciences, 2022, 12(3): 972.
- [12] KUNDU P. Review of rotating machinery elements condition monitoring using acoustic emission signal[J]. Expert Systems with Applications, 2024, 252: 124169.
- [13] JUNG W H, KIM S H, YUN S H, et al. Vibration, acoustic, temperature, and motor current dataset of rotating machine under varying operating conditions for fault diagnosis[J]. Data in Brief, 2023, 48: 109049.
- [14] ZHANG H, CHE W M, CAO Y R, et al. Condition monitoring and fault diagnosis of rotating machinery towards intelligent manufacturing: review and prospect [J]. Iranian Journal of Science and Technology, Transactions of Mechanical Engineering, 2025, 49(1): 1-34.
- [15] ZHUANG F Z, QI Z Y, DUAN K Y, et al. A comprehensive survey on transfer learning[J]. Proceedings of the IEEE, 2021, 109(1): 43-76.
- [16] ZHANG R, TAO H Y, WU L F, et al. Transfer learning with neural networks for bearing fault diagnosis in changing working conditions[J]. IEEE Access, 2017, 5: 14347-14357.
- [17] SHAO S Y, MCALEER S, YAN R Q, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. IEEE Transactions on Industrial Informatics, 2019, 15(4): 2446-2455.



第一作者简介:赵豪雨,男,2002年6月生,硕士生。主要研究方向为深度学习与故障智能诊断技术等。

E-mail: 2024056148@nwafu.edu.cn

通信作者简介:曹培,女,1989年10月生,博士、副教授。主要研究方向为机械电子工程。

E-mail: caopei2020@nwafu.edu.cn