

基于 CAE-LSTM 的航发轴承故障诊断方法

尹震宇^{2,3}, 刘思宇^{1,2,3}, 张飞青^{2,3}, 徐光远^{1,2,3}, 宋丹^{2,3}

¹(中国科学院大学,北京 100049)

²(中国科学院沈阳计算技术研究所,沈阳 110168)

³(辽宁省国产基础软硬件工控平台技术研究重点实验室,沈阳 110168)

E-mail:congmy@163.com

摘要:随着计算机深度学习理论的发展及航空领域对关键装备智能化故障诊断与运维需求的提升,基于深度学习的航空发动机运行状态的监测与评估方法成为了飞机安全运行的重要保障.由于航空发动机机械结构复杂,轴承在高温、高压等恶劣环境下高速运行,其故障特征信息存在多尺度、非线性等问题,使得故障信号难以有效识别及分析诊断.因此,本文提出了一种基于 CAE-LSTM 的航发轴承故障诊断方法,首先利用改进的卷积自编码器(Convolutional Autoencoder, CAE)对高维振动信号进行降维和特征提取,然后将提取到的特征输入到长短期记忆网络(Long Short-Term Memory, LSTM)分类器中进行故障类型识别,从而提升轴承故障分类的准确性和鲁棒性.实验结果表明本文提出的方法能够有效地学习航发轴承传感信号序列中的动态特征,提高航发轴承故障诊断的精确性和智能性.

关键词:航空发动机;卷积自编码器;长短期记忆网络;特征提取;故障诊断

中图分类号: TP181

文献标识码: A

文章编号: 1000-1220(2026)05-1041-07

Fault Diagnosis Method for Aero-engine Bearings Based on CAE-LSTM

YIN Zhenyu^{2,3}, LIU Siyu^{1,2,3}, ZHANG Feiqing^{2,3}, XU Guangyuan^{1,2,3}, SONG Dan^{2,3}

¹(University of Chinese Academy of Sciences, Beijing 100049, China)

²(Shenyang Institute of Computing Technology, Chinese Academy of Sciences, Shenyang 110168, China)

³(Liaoning Key Laboratory of Domestic Industrial Control Platform Technology on Basic Hardware & Software, Shenyang 110168, China)

Abstract: With the development of computer deep learning theory and the enhancement of the demand for intelligent fault diagnosis and operation and maintenance of key equipment in the field of aviation, the monitoring and evaluation method of the operating state of aero-engine based on deep learning has become an important guarantee for the safe operation of aircraft. Due to the complexity of the mechanical structure of the aero-engine and the high-speed operation of the bearings in a harsh environment such as high temperature and high pressure, there are problems such as multi-scale and non-linearity in the fault characteristic information, which makes it difficult to effectively identify and analyze and diagnose the fault signals. Therefore, this paper proposes a CAE-LSTM-based fault diagnosis method for airframe bearings, which firstly utilizes the improved Convolutional Autoencoder (CAE) to perform downscaling and feature extraction for high-dimensional vibration signals, and then inputs the extracted features into the Long Short-Term Memory (LSTM) classification network. Memory (LSTM) classifier for fault type identification, thus improving the accuracy and robustness of bearing fault classification. The experimental results show that the method proposed in this paper can effectively learn the dynamic features in the aircraft bearing sensing signal sequence and improve the accuracy and intelligence of aircraft bearing fault diagnosis.

Keywords: aero-engine; convolutional autoencoder; long short-term memory; feature extraction; fault diagnosis

0 引言

深度学习技术因其卓越的特征提取和模式识别能力,已成为机械设备健康状态检测与故障诊断的重点研究内容.航空发动机是飞行器关键的动力组成部分,其机械结构复杂而精密,航发轴承作为支撑和稳定旋转部件的重要组件承受着高温、高速和高负荷等恶劣工作环境^[1,2].在极端条件下,润滑油的性能相对下降,更容易产生机械损伤^[3],轴承一旦发生故障,可能导致转子偏移、卡滞等,危及发动机的正常工作

并直接威胁飞行安全.通过轴承健康状态监测与故障诊断,可以在问题扩展前采取修复措施,避免更大范围的损坏,从而降低维护成本.因此,研究航发轴承健康状态诊断,确保飞行器动力系统稳定运行,对降低维护成本及保障飞行安全具有重大的研究意义.

由于航发轴承所处恶劣工作环境,无法通过内置传感器等方式对该部件进行运行状态及故障实时检测.通过采集发动机机匣振动信号进行分析,得到的发动机振动信号中含有较多激励成分,航发轴承在早期故障时产生的冲击信号幅值

收稿日期:2025-02-12 收修修改稿日期:2025-03-05 基金项目:辽宁省科技重大专项项目(2024JH1/1170043)资助. 作者简介:尹震宇(通信作者),男,1979年生,博士,研究员,博士生导师,研究方向为工业互联网、网络通信、嵌入式技术等;刘思宇,女,1997年生,硕士研究生,研究方向为工业互联网、深度学习等;张飞青,女,1992年生,博士,副研究员,研究方向为工业互联网、深度学习等;徐光远,男,1992年生,博士研究生,研究方向为工业互联网、深度学习等;宋丹,女,1989年生,副研究员,研究方向为工业互联网、嵌入式技术等.

较小,往往被淹没在背景噪声中^[4,5]。这种情况使得早期故障信号难以被及时检测和识别,给故障诊断带来了较大挑战。

深度学习在滚动轴承故障诊断中得到了普遍的应用和广泛的认可,主流的故障诊断方法包含卷积神经网络识别方法、循环神经网络识别方法、深度度量学习识别方法以及基于注意力机制的识别方法等^[6-8],以上方法在轴承诊断时可以快速有效地处理轴承的振动信号,不依赖于专家知识去提取信号的深层特征,进而获得精确的识别结果。然而,航空发动机中介轴承运行状态实时感知与故障诊断过程存在轴承特征信号信噪比低、干扰信号复杂、轴承故障特征信息存在多尺度和非线性,且实际数据集分布不一致等问题,上述故障诊断方法难以有效地识别航空发动机中介轴承信号序列中的动态特征并实现故障诊断^[9]。

针对目前诊断方法存在的问题,本文提出了一种基于CAE-LSTM的航发轴承故障诊断方法,首先采用基于CAE的轴承信号特征提取方法,有效提升信号分解和重构的性能,解决了中介轴承传感器采集到的信息信噪比低,信号特征识别困难的问题,并在提取低维特征基础上构建基于LSTM的分类器,捕捉时间序列中的长期依赖性。通过在哈工大航空发动机轴承公开数据集上的实验,验证了本文所提出的方法能够有效地学习航发轴承传感信号序列中的动态特征,提高航发轴承故障诊断的精确性和智能性。

1 相关工作

1.1 信号特征提取

故障信号特征的提取是航发轴承故障诊断任务的重要环节,深度学习模型能够不依赖于专家知识快速有效地处理轴承的传感信号,从原始数据中提取具有代表性的特征构成新特征。滚动轴承由内圈、外圈、滚动体和保持架组成,正常轴承如图1(a)所示,在运转过程中由于多种因素轴承可能会出现磨损、腐蚀、断裂等损伤,不同故障类型的加工示意图如图1(b)和图1(c)所示。




图1 不同形态轴承示意图

Fig. 1 Schematic diagram of different forms of bearings

当轴承出现故障(如内圈、外圈、滚动体或保持架的损伤)时,滚动体经过损伤区域会产生周期性冲击信号,但轴承早期故障信号微弱,不宜提取。有效的特征提取有能够从原始信号中去除噪声干扰,使得故障特征更加明显,从而提高故障诊断模型的学习效率和诊断准确性。传统的故障诊断方法往往依赖大量标记数据,而在实际应用中,标记样本的获取成本高且容易受到噪声干扰,导致诊断效果不理想。为解决这一问题,Zhang等人首先应用基于小波变换的特征预提取机制对数据进行预处理^[10],以有效提取关键特征,并将有限的标记样本与大量未标记样本输入到IGAN模型中进行训练,该方

法能够利用未标记数据的潜在信息,增强模型的学习效果。Cao等人通过截断可行域有效地捕获真实发生的故障分量以减少能量泄漏效应,并设计一个通用的SBL框架,恢复复合稀疏脉冲信号^[11]。张博文等人通过在传统的卷积层前面增加了PIRD的提取层^[12],提取转子振动位移信号的概率密度信息,有效降低数据冗余度的同时保留了故障监测的重要指标。Chen等人针对轴承振动噪声数据识别精度低的问题,利用递归图技术将滚动轴承振动信号转换为彩色图像,其携带比灰度图像更多的信息,具有较强的抗噪性^[13]。Xu等人基于信号包络频率的解析信号离散化表达式,构建字典矩阵并推导系数向量解公式,结合频率网格迭代匹配策略^[14],实现了滚动轴承基本旋转频率和故障特征频率的精确提取。随着多传感器系统在机械故障诊断中的应用日益增加,Zhang等人提出了一种多尺度通道注意力驱动的图动态融合学习方法^[15],以应对外部干扰和传感器精度差异下,信号质量的非一致性,该方法通过挖掘不同通道间的重要性差异,计算通道注意力权重,从而增强节点特征表示。上述方法在实施过程中信号处理流程复杂,相关人员需要具备信号处理专业知识并对轴承振动信号的频率成分和不同故障的特征形式清楚掌握,具有局限性。

1.2 故障诊断模型

轴承故障诊断是确保机械设备可靠性和延长使用寿命的重要环节,通过有效的故障诊断方法可以及时识别潜在的故障,避免设备损坏、生产停滞,甚至由此引起的安全事故。

随着深度学习技术的进步,数据驱动的方法逐渐成为研究的主流,Chen等人通过调查神经网络的权重分布,发现模型在输入数据响应上的不均匀性,神经网络倾向于从数据的某些局部区域学习更多信息,进而提出了一种新的动态聚焦注意力机制,通过动态调整模型对不同输入特征的注意程度,能够有效提取关键频带的判别特征^[16]。An等人为了减少时间序列分析过程中的计算复杂性,并降低随机干扰对后续特征提取的影响,提出了一种基于周期性稀疏注意力(PSAL)的故障诊断方法^[17],通过聚焦于信号中的周期特征,减少随机干扰的影响,从而提高特征提取的效率,然后使用LSTM网络提取故障信号中的长期依赖特征,以捕捉信号变化中的关键模式。刘飞等人提出了一种基于迁移学习(TL)与深度残差网络(ResNet)的快速故障诊断算法(TL-ResNet)^[18],首先通过短时傅里叶变换(STFT)与伪彩色处理相结合的技术,将振动信号转换为三通道图像数据,然后利用在ImageNet数据集上训练的ResNet18模型作为预训练模型,通过迁移学习的方法,将其应用于滚动轴承故障诊断领域,采用小样本迁移的方法对滚动轴承在不同工况下的故障进行诊断。Yang等人利用自编码器和泰勒级数展开相结合的方法,提出了一种基于自编码器多维泰勒网络(MTN)的智能故障检测方法,同时为解决由于小样本导致的智能故障诊断精度低的问题引入联邦学习,针对联邦学习中客户端与中心之间的信息交互面临被窃听的风险,提出基于惩罚窃听者的混合加乘编码信息保护策略实现惩罚窃听者的效果,通过合并多客户端数据以提高智能故障诊断的准确性^[19]。Fan等人基于普通灰度图像(GI),通过局部二值模式(LBP)获得特征增强的灰度纹理图像(GTI),并结合改进的自适应激活函数和多尺度特征提取,开

发了轻量级多尺度卷积神经网络 (Ada-act LMCNN)^[20]. 姜波舟等人提出了一种基于转子位移信息多尺度特征提取的航空发动机轴承故障诊断方法^[21]. 相较于传统机械设备,航空发动机结构复杂,在多源背景噪声环境下,上述方法难以精确地实现航发轴承的故障诊断.

2 方法描述

本节提出一种基于 CAE-LSTM 的航发轴承故障诊断方法,通过改进的 CAE 模型对航发轴承原始振动信号进行特征提取,捕捉局部模式,提取输入的空间特征或局部依赖关系,得到压缩的高维特征表示,LSTM 则在这些特征基础上进一

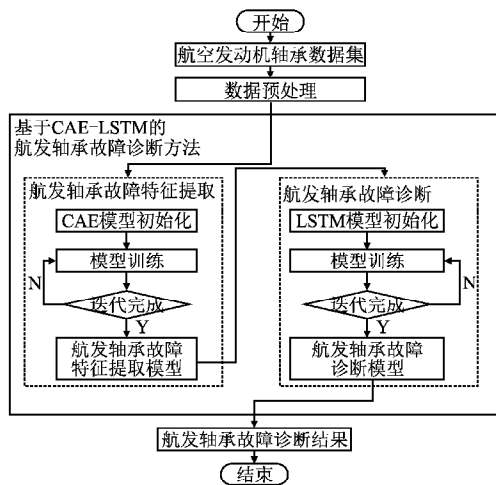


图 2 基于 CAE-LSTM 的航发轴承故障诊断方法流程图
Fig. 2 Flowchart of a fault diagnosis method for aeroengine bearings integrating CAE-LSTM

步提取时序依赖,提升了整个模型的特征提取能力.该模型在处理高维时序数据时表现出色,适用于复杂的航发轴承故障诊断任务,故障诊断方法流程如图 2 所示.

2.1 基于 CAE 的航发轴承故障特征提取方法

在深度学习领域,卷积神经网络 (Convolutional Neural Network, CNN) 和自编码器 (Auto-Encoder, AE) 都是广泛应用于特征提取和数据表示学习的重要模型.卷积神经网络是一种具有局部连接、权重共享等特性的深层前馈神经网络,在处理空间或时序结构数据方面具有优势.自编码器通过无监督的方式来学习数据的有效编码,由编码器和解码器两部分组成,编码器将输入数据压缩为低维表示,解码器则将低维表示重构回原始数据.

滚动轴承光滑度高,滚道尺寸精密,反映运转状态信息的能量微弱,航发轴承工作时伴随着多源背景噪声的早期故障特征更加难以提取.因此,提出了一种基于卷积自编码器的特征提取模型,能够从多维时间序列数据中提取特征并进行特征降维,航发轴承故障特征提取模型结构如图 3 所示.

本文模型的编码器负责将输入的时间序列数据压缩到低维表示,采用一系列卷积 (Conv1D)、批量归一化 (Batch Normalization) 和最大池化层 (Max Pooling) 替换传统自编码器模型中的全连接层,在轴承传感信号的时间序列数据中可能包含短时间的异常或周期性波动,卷积操作能够捕捉局部依赖

关系,有效地捕捉到故障轴承振动的周期性变化、冲击信号等局部特征,并且相比于全连接层,卷积层参数更少,更为高效,充分利用了 CNN 在处理具有空间或时序结构数据方面的优势.批量归一化操作对卷积层的输出进行归一化,确保每一层的输入数据在训练过程中具有相对稳定的分布,加速训练过程,并使模型更加稳定.通过池化操作,时间步数逐步减半,从而实现压缩,生成紧凑的潜在特征表示.同时,经过多层卷积和池化层的自编码器具备了深度自编码器的特性,能够学习到更复杂的特征表示.模型的解码器负责将编码器生成的低维特征重新解码为原始输入的维度,解码过程是编码器的逆过程,解码器由 3 个一维卷积层 (与编码器对称),通过上采样操作 (UpSampling1D) 逐步恢复时间步数,最后使用线性激活函数的卷积层输出重构后的数据.

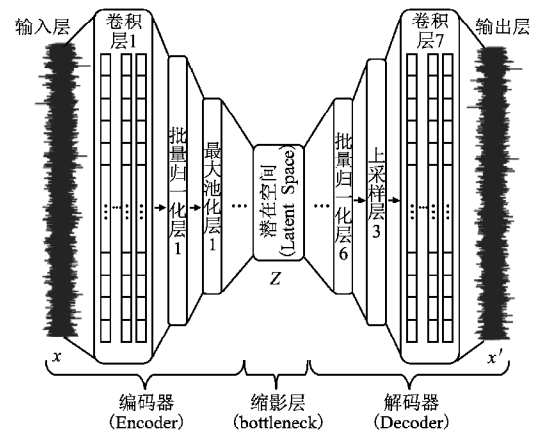


图 3 故障特征提取模型结构
Fig. 3 Fault feature extraction model structure

对于输入层的样本 x ,模型潜在空间的活性值为输入层 x 的编码,如式 (1) 所示:

$$z = f(W^{(1)}x + b^{(1)}) \quad (1)$$

模型的输出为重构的数据,如式 (2) 所示:

$$x' = f(W^{(2)}x + b^{(2)}) \quad (2)$$

其中 $W^{(1)}, W^{(2)}, b^{(1)}, b^{(2)}$ 为网络参数, $f(\cdot)$ 为激活函数.

本文特征提取模型的输入形状为 (样本数, 时间步数, 特征数),通过一系列的卷积层和池化层,逐层减少滤波器数量 (256→128→64),提取不同层次的特征,将输入的 20480 个时间步、4 个特征的高维数据压缩成为 2560 个时间步、64 个特征的低维潜在空间表示,其中图 4(a) 为输入的 4 个特征,图 4(b) 为提取到的部分潜在空间表示.

通过 CAE 故障特征提取模型能够得到有效的数据表示,最小化输入与重构数据之间的均方误差损失函数,训练结束后只保留编码器部分,将编码器输出的潜在空间表示作为后续故障诊断模型的输入,从而提高航发轴承故障诊断模型的鲁棒性和精确性.

2.2 故障诊断模型设计

在轴承故障检测中,传感信号时间序列数据包含复杂的动态信息,长短时记忆网络 (Long Short-Term Memory, LSTM) 通过引入记忆单元和门控机制,有选择地加入新的信息,并有选择地遗忘之前累积的信息,有效解决了传统 RNN 模型难以处理长序列依赖问题的不足,结合本文上一小节的

航发轴承故障信号特征提取方法,设计并构建了一个能够有效提取高层次时序特征并捕捉长时依赖关系的 CAE-LSTM 的航发轴承故障诊断模型,用于分类正常、内圈故障、外圈故障

等不同状态的轴承信号,显著提升了航发轴承故障信号的识别效果。

本文设计的 CAE-LSTM 的航发轴承故障诊断模型主要

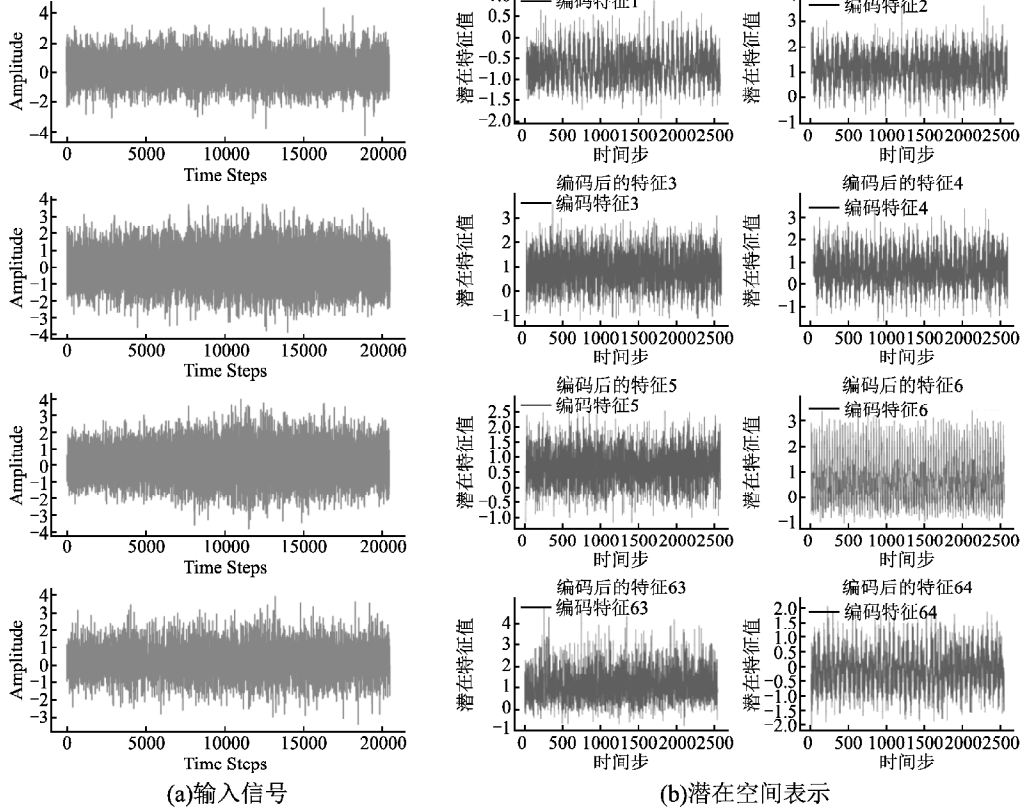


图4 输入信号与潜在空间表示

Fig. 4 Input signal and latent spatial representation

结构如图5所示,包含以下关键部分:

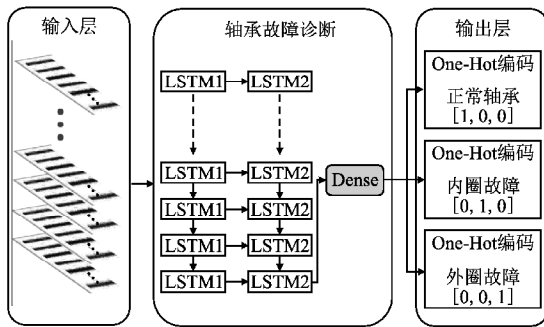


图5 轴承故障诊断模型结构

Fig. 5 Bearing fault diagnosis model structure

1) 双层 LSTM 结构:第1层 LSTM 设置了 128 个隐藏单元,内部状态 c_t 线性的传递循环信息,非线性输出信息给隐藏层的外部状态 h_t ,通过门控机制(遗忘门、输入门、输出门)控制信息的存储和更新,遗忘门 f_t 控制上一个时刻的内部状态 c_{t-1} 丢弃哪些信息,输入门 i_t 控制当前时刻的候选状态 \tilde{c}_t 保存哪些信息,输出门 o_t 控制当前时刻的内部状态 c_t 有哪些信息作为输出传递给外部状态 h_t ,避免了长时间步依赖带来的梯度消失问题,内部的计算公式如式(3)~式(8)所示:

$$c_t = f_t \times c_{t-1} + i_t \times \tilde{c}_t \quad (3)$$

$$h_t = o_t \times \tanh(c_t) \quad (4)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (5)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (6)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (7)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (8)$$

为确保后续 LSTM 层能够继续处理时间序列数据,设置返回序列输出 (`return_sequences = True`). 第2层 LSTM 具有 64 个隐藏单元,用于捕获更高层次的时间依赖特征,在每层 LSTM 后均加入 Dropout 层,防止过拟合。

2) 全连接层与输出层:LSTM 输出经过全连接层(128 个神经元,ReLU 激活)进行特征映射,随后通过 Softmax 输出层实现多分类,输出类别对应轴承的不同故障类型。

3) 输入与输出:输入数据为本文提出的基于卷积自编码器的特征提取模型提取的潜在空间表示,其形状为(样本数量,时间步长,特征数量)。输出为 One-Hot 编码后的标签,代表轴承的正常、内圈故障和外圈故障不同状态。

模型的训练过程在训练集上进行,优化器采用 Adam 优化器,学习率设定为 0.0002,为避免过拟合,使用验证集来监控模型的训练过程,引入 ReduceLROnPlateau 回调函数,用于动态调整学习率,当验证损失在 5 个 epoch 内不改善时,学习

率会按0.5的因子进行衰减,最低可降至 $1e-6$ 。在50个训练轮次下进行训练,并使用交叉熵损失函数优化分类模型的多类别输出。

3 实验与结果分析

3.1 实验环境

本文实验采用深度学习框架TensorFlow,使用GPU加速,实验具体硬件和软件配置如表1所示,实验环境保证了在

表1 实验环境配置

Table 1 Experimental environment configuration

实验环境	环境配置
操作系统	Ubuntu 20.04
CPU	Intel(R) Xeon(R) Platinum 8255C
GPU	NVIDIA RTX 2080 Ti
Python 版本	Python 3.8
CUDA 版本	CUDA 11.2
深度学习框架	TensorFlow 2.9.0

轴承数据集上的模型训练与评估的高效性。

3.2 实验数据集

为验证本文提出方法对航发轴承故障诊断的有效性,实验使用哈尔滨工业大学航空发动机轴承公开数据集,数据集基于以真实航空发动机为原型搭建的试验台,通过更换人为故障轴承,得到正常、内圈故障、外圈故障3种状态的五组数据集,采样频率为25000Hz。数据集由长时间序列分段为共有2412组包含20480个数据点的短序列,前两列存储位移响应,第3~第6列存储加速度响应,第7列存储高、低转速信息,第8列存储标签信息。相较于位移传感器,加速度传感器

表2 数据集组成

Table 2 Dataset composition

数据集	正常	内圈故障	外圈故障
训练集	668	705	315
验证集	143	152	67
测试集	143	151	68

对快速变化的振动信号更为敏感,能够捕捉到瞬时故障或异常振动,本文实验选取第3~第6列的加速度信息作为特征,选取第8列作为标签信息,采用One-Hot编码对标签进行处理,并将数据集按比例严格划分为训练集(70%)、验证集(15%)和测试集(15%),划分后的数据集划分情况如表2所示,共有2412个样本,每个样本有20480个时间步,每个时间步有4个特征。

3.3 评价指标

为全面评价模型的性能,本文选用精度(Precision)、召回率(Recall)和F1-score和准确率等分类指标作为模型的评价指标,计算公式如式(9)~式(12),并在测试集上生成分类报告:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (9)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (10)$$

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (11)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

其中TP(True Positive)为真正例,正确预测为正类的样本数量;TN(True Negative)为真负例,正确预测为负类的样本数量;FP(False Positive)为假正例,错误预测为正类的样本数量;FN(False Negative)为假负例,错误预测为负类的样本数量。

3.4 实验结果

为验证本文方法的有效性,在同等算力及数据集条件下,将本文提出的基于CAE-LSTM的航发轴承故障诊断方法与轴承故障诊断常用的1D-CNN模型、AE+Classifier模型、CNN模型、LSTM模型、MLP模型5种基础深度学习模型做对比,实验结果显示,随着Epoch的增加,模型在第50轮后基本趋于稳定,在测试集上的准确率比较如图6所示。相比之下,AE+Classifier模型、LSTM模型、MLP模型在训练过程中准确率提升幅度较小,趋于稳定后,模型分类准确率仍较低,本文方法在航发轴承故障诊断任务中表现出较好的收敛状态,准确率情况明显优于其他模型。




图6 准确率比较

Fig. 6 Comparison of accuracy

相较于传统模型,本文方法在准确率、精确率、召回率和F1分数等多个指标上均表现更优,实验的精确率、召回率和F1值对比如表3所示。

表3 对比实验结果

Table 3 Comparative experimental results

方法	类别	精度	召回率	F1-score
本文方法	正常	0.97	0.99	0.98
	内圈故障	0.99	0.97	0.98
	外圈故障	0.99	1.00	0.99
1D-CNN	正常	0.94	0.87	0.91
	外圈故障	0.82	0.97	0.89
AE + Classifier	正常	0.81	0.81	0.81
	内圈故障	0.71	0.81	0.75
	外圈故障	0.76	0.51	0.61
CNN	正常	0.91	0.83	0.87
	内圈故障	0.89	0.91	0.90
	外圈故障	0.86	0.97	0.91
LSTM	正常	0.81	0.85	0.83
	内圈故障	0.76	0.74	0.74
	外圈故障	0.77	0.72	0.74
MLP	正常	0.77	0.66	0.71
	内圈故障	0.64	0.71	0.68
	外圈故障	0.56	0.60	0.58

图7(a)为测试样本输入到本文提出的基于CAE-LSTM的航发轴承故障诊断方法的混淆矩阵图,在各类别上的分类准确率均较高,误分类情况较少。通过与1D-CNN模型、AE+

Classifier模型、CNN模型、LSTM模型、MLP模型5种模型混淆矩阵对比,图7可以直观地体现6种方法的分类性能。

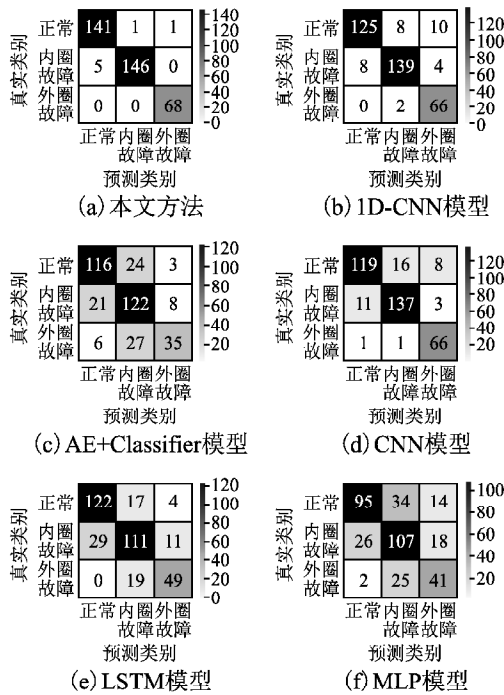


图7 轴承故障诊断混淆矩阵

Fig. 7 Bearing fault diagnosis confusion matrix

3.5 结果对比

本文提出的基于CAE-LSTM的航发轴承故障诊断方法进一步与TST^[9]、PIRD-CNN^[12]、DI-MCNN-LSTM^[21]等3种最新的航发轴承故障诊断方法进行对比,相较于相关工作本文所提出方法能够不依赖于信号处理专业知识和繁杂的

表4 准确率对比

Table 4 Accuracy comparison

方法	准确率(%)
本文的方法	98.48
TST	71.07
PIRD-CNN	96.58
DI-MCNN-LSTM	92.92

信号处理过程,通过CAE模块有效地去除复杂航发轴承传感信号中的噪声,同时保留数据的关键特征,并基于改进的LSTM模块实现高准确、智能化的航发轴承故障诊断,准确率提升了2%~27%,故障诊断准确率对比如表4所示。

4 总结

本文提出了一种基于CAE-LSTM的航发轴承故障诊断方法,充分利用CAE与LSTM两者的优势,实现高效的特征提取与智能的故障诊断,并在哈工大轴承数据集上进行了验证。实验结果表明,本文提出的基于CAE的航发轴承故障特征提取方法针对航发轴承复杂传感信号的深层次特征提取具有明显优势,通过对输入数据的降维与去噪,有效提升了LSTM分类器的性能。综上所述,本文方法在航发轴承故障诊

断任务中展现出了良好的精确性和智能性。

References:

[1] Jin Y, Zhou X, Quan X, et al. Topological structures of vibration responses for dual-rotor aeroengine [J]. Mechanical Systems Signal Processing, 2024, 208: 1-22, doi: 10.1016/j.ymssp.2023.111053.

[2] Chongyang Wang, Zihang Li, Haoze Wang, et al. Nonlinear modeling and vibration response analysis of rod fastening rotor-bearing system with curvic coupling [J]. Tribology International, 2024, 199: 1-17, doi: 10.1016/j.triboint.2024.109984.

[3] Xu G, Guo R, Yin Z, et al. MCRCNet: a bearing fault diagnosis method for unknown faults based on transfer learning [J]. Applied Sciences, 2025, 15: 1-20, doi: 10.3390/app15020921.

[4] Yin Z, Zhang F, Xu G, et al. Multi-scale rolling bearing fault diagnosis method based on transfer learning [J]. Applied Sciences, 2024, 14(3): 1-20, doi: 10.3390/app14031198.

[5] LIU J F, YU X, WAN II B, et al. Fault diagnosis method of rolling bearing using MFMD and Transformer-CNN [J]. Journal of Aerospace Power, 2023, 38(6): 1446-1456.

[6] Long Wen, Guang Yang, Longxin Hu, et al. A new unsupervised health index estimation method for bearings early fault detection based on Gaussian mixture model [J]. Engineering Applications of Artificial Intelligence, 2024, 128: 1-14, doi: 10.1016/j.engappai.2023.107562.

[7] Lingli Cui, Zhilin Dong, Hai Xu, et al. Triplet attention-enhanced residual tree-inspired decision network: a hierarchical fault diagnosis model for unbalanced bearing datasets [J]. Advanced Engineering Informatics, 2024, 59: 102322, doi: 10.1016/j.aei.2023.102322.

[8] LIU J, TAN Y T, YANG N. A study on bearing fault diagnosis based on ACYCBD-MTF-MobileViT under strong noise [J]. Journal of Vibration and Shock, 2024, 43(24): 34-47.

[9] Hou L, Yi H, Jin Y, et al. Inter-shaft bearing fault diagnosis based on an aero-engine system: a benchmarking dataset study [J]. Journal of Dynamics, Monitoring and Diagnostics, 2023, 4(2): 228-242.

[10] Lijie Zhang, Bin Wang, Pengfei Liang, et al. Semi-supervised fault diagnosis of gearbox based on feature pre-extraction mechanism and improved generative adversarial networks under limited labeled samples and noise environment [J]. Advanced Engineering Informatics, 2023, 58: 1-14, doi: 10.1016/j.aei.2023.102211.

[11] Cao Z, Dai J, Xu W, et al. Sparse Bayesian learning approach for compound bearing fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2024, 20(2): 1562-1574.

[12] ZHANG B W, PANG X Y, CHENG B A, et al. Fault diagnosis method for aeroengine bearings based on PIRD-CNN [J]. Journal of Vibration and Shock, 2024, 43(18): 201-207 + 231.

[13] Chen Z, Xu B, Zhang Z. Rolling bearing fault diagnosis based on recurrence plot [J]. IEEE Access, 2024, 12: 149710-149721, doi: 10.1109/access.2024.3472454.

[14] Xu W, He J, G. Li, et al. Bearing fault feature extraction via adaptive frequency matching and coupling analysis [J]. IEEE Sensors Journal, 2024, 24(23): 39565-39577.

[15] Zhang X, Liu J, Zhang X, et al. Multiscale channel attention-driven graph dynamic fusion learning method for robust fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2024, 20(9): 11002-11013.

