

基于深度学习的轴承故障诊断模型研究

张天据

广西钢铁集团有限公司冷轧厂 广西 防城港 538001

摘要: 本文系统综述了基于深度学习的轴承故障诊断方法,重点分析了卷积神经网络(CNN)、循环神经网络(RNN)、注意力机制及混合模型在该领域的应用,并提出一种融合一维卷积与多头自注意力机制的新型诊断模型(1D-CNN-MHA)。在公开数据集CWRU上进行实验验证,结果表明所提模型在多种工况下均具有较高的诊断准确率(平均达99.23%),优于传统机器学习方法及部分现有深度学习模型。最后,本文对当前研究存在的挑战及未来发展方向进行了展望,为后续研究提供理论参考和技术路径。

关键词: 滚动轴承; 故障诊断; 深度学习; 卷积神经网络; 自注意力机制; CWRU数据集

引言

滚动轴承是旋转机械的核心支撑部件,广泛应用于重大装备中。约30%的旋转机械故障源于轴承失效,故障轻则设备停机、生产降效,重则引发事故,造成巨大损失。因此,对轴承进行实时精准的状态监测与故障诊断,对实现预测性维护、降低成本、提升可靠性意义重大。传统轴承故障诊断方法,如基于信号处理(依赖人工特征工程和专家经验,难适应复杂工况)、基于物理模型(需精确建模,计算复杂、通用性差)的方法存在局限。随着传感器与数据采集系统进步,工业现场可获取大量原始振动数据,为数据驱动的智能诊断方法奠定基础。深度学习作为人工智能重要分支,能自动学习多层次抽象特征,避免人工特征设计,在多领域取得突破,近年来在轴承故障诊断中应用日益广泛,前景广阔。

1 轴承故障机理与数据集

1.1 轴承故障类型与振动特性

滚动轴承主要由内圈、外圈、滚动体和保持架组成。常见故障类型包括:(1)内圈故障:故障点位于内圈滚道,振动频率与轴转速、滚动体数量、接触角等参数相关;(2)外圈故障:故障点位于外圈滚道,其特征频率通常低于内圈故障;(3)滚动体故障:滚动体表面出现剥落或裂纹,产生调制效应;(4)复合故障:同时存在两种及以上故障类型,信号更为复杂。当轴承出现局部损伤时,每次滚动体经过故障点会产生冲击脉冲,该脉冲在轴承系统固有频率下被调制,形成周期性冲击响应^[1]。通过振动传感器采集的信号包含丰富的故障信息,但常被噪声、其他部件振动及非平稳工况所掩盖。

1.2 常用公开数据集

目前,国际上广泛采用的标准数据集主要包括:(1)凯斯西储大学(CWRU)轴承数据中心数据集:由

美国Case Western Reserve University提供,包含不同负载、转速下正常及四种单点故障(内圈、外圈、滚动体、复合故障)的振动信号,采样频率为12 kHz或48 kHz,是评估故障诊断算法的基准数据集。(2)Paderborn University数据集:包含加速寿命试验下的全生命周期数据,适用于剩余寿命预测研究。(3)XJTU-SY数据集:由西安交通大学发布,涵盖变转速、变负载条件下的轴承退化数据。本文选用CWRU数据集进行实验,因其标签清晰、工况明确、使用广泛,便于结果对比。

2 深度学习在轴承故障诊断中的典型方法

2.1 卷积神经网络(CNN)

在轴承故障诊断中,研究者通常采用一维卷积神经网络(1D-CNN)直接作用于原始或分段的振动时间序列。这种设计避免了传统方法中将信号转换为时频图所带来的信息损失和额外计算开销。1D-CNN通过滑动卷积核在时间维度上扫描信号,逐层提取从低级波形特征到高级故障模式的抽象表示。每一层卷积后通常接有非线性激活函数(如ReLU)、批归一化(Batch Normalization)和池化操作,以增强模型的非线性表达能力和抗噪性。研究表明,即使不进行复杂的信号预处理,1D-CNN也能自动学习到与故障相关的冲击成分、周期性调制等关键特征,从而实现高精度分类。此外,通过堆叠多个卷积层,模型可逐步扩大感受野,捕捉更长距离的时序依赖,但其本质上仍受限于局部连接结构,难以有效建模全局上下文关系。

2.2 循环神经网络(RNN)与LSTM

循环神经网络(RNN)专为处理序列数据而设计,其内部状态可传递历史信息,理论上能捕捉任意长度的时间依赖。然而,标准RNN在训练过程中易受梯度消失或爆炸问题困扰,导致难以学习长期依赖。为克服这

一缺陷,长短期记忆网络(LSTM)被引入故障诊断领域。LSTM通过引入输入门、遗忘门和输出门三个门控机制,有选择地保留或丢弃历史信息,从而有效缓解梯度问题^[2]。在处理轴承振动信号时,LSTM能够建模故障冲击在时间轴上的演化规律,尤其适用于非平稳或变转速工况下的诊断任务。然而,LSTM的串行计算特性导致其训练速度较慢,且对信号中的局部突变特征(如瞬时冲击)不如CNN敏感。因此,单纯依赖LSTM可能无法充分挖掘振动信号中的丰富时空特征。

2.3 自编码器(AE)与变分自编码器(VAE)

自编码器(Autoencoder,AE)是一种无监督或半监督的神经网络结构,由编码器和解码器两部分组成,旨在通过低维潜在空间重构输入数据。在故障诊断中,AE常被用于异常检测:模型在大量正常样本上进行训练,使其能够精确重构正常信号;当输入故障信号时,由于其分布与训练数据差异较大,重构误差显著增大,从而实现故障判别。为进一步提升模型的泛化能力和对不确定性的建模能力,变分自编码器(Variational Autoencoder,VAE)被提出。VAE在编码过程中引入概率分布约束(通常为高斯分布),使得潜在空间具有更好的连续性和结构性。尽管AE/VAE在无标签场景下具有应用价值,但其诊断性能通常低于有监督分类模型,且对故障类型的区分能力有限,难以满足精细化诊断需求。

2.4 注意力机制与Transformer

注意力机制的核心思想是让模型在处理输入序列时,动态地为不同位置分配不同的权重,从而聚焦于对当前任务最相关的信息。多头自注意力(Multi-Head Self-Attention, MHA)通过并行计算多个注意力子空间,能够同时捕获不同表示子空间中的依赖关系,增强模型的表达能力。最初在自然语言处理中取得成功的Transformer架构完全摒弃了循环和卷积结构,仅依赖注意力机制进行序列建模,具备强大的并行计算能力和长程依赖建模能力^[3]。近年来,Transformer被逐步引入机械故障诊断领域。研究者将振动信号视为“词序列”,利用MHA学习各时间步之间的全局关联,有效识别出分散在时间轴上的故障相关片段。然而,纯Transformer模型对局部细节特征的感知较弱,且在小样本条件下容易过拟合,因此常需与其他结构结合使用。

2.5 混合模型

鉴于单一模型难以兼顾局部特征提取、时序建模和全局依赖捕获等多重需求,研究者开始探索混合深度学习架构。例如,CNN-LSTM模型先通过CNN提取局部时域特征,再将特征序列送入LSTM建模长期动态,

兼顾了空间局部性和时间连续性;CNN-Attention模型则在CNN之后引入注意力机制,对关键通道或时间步进行加权,提升模型对故障敏感区域的关注度;残差网络(ResNet)通过跳跃连接缓解深层网络的梯度退化问题,使得构建更深的诊断模型成为可能。这些混合策略在复杂工况和多故障类型场景下通常表现出优于单一模型的综合性能,体现了“优势互补”的设计思想,也成为当前故障诊断模型发展的主流趋势。

3 所提模型:1D-CNN-MHA

3.1 模型设计动机

尽管CNN能有效提取局部特征,但其感受野有限,难以建模长距离依赖;而纯注意力模型计算复杂度高,对局部细节不敏感。为此,本文提出一种两阶段融合模型:先用1D-CNN提取局部时域特征,再通过MHA建模全局上下文关系,实现“局部+全局”的联合表征。

3.2 模型结构

所提出的1D-CNN-MHA模型以原始振动信号片段作为输入,长度统一为2048个采样点。首先进入1D-CNN特征提取模块,该模块包含三层一维卷积层,卷积核大小依次为64、32和16,对应的输出通道数为64、128和256。每层卷积后均接有批归一化、ReLU激活函数和最大池化操作(池化窗口大小为2),以逐步降低时间维度、提升特征抽象层次。经过该模块后,原始信号被转化为一个高维特征序列,每个时间步对应一个256维的特征向量。随后,该序列被送入多头自注意力模块^[4]。在此模块中,每个特征向量被视为一个“token”,通过线性变换生成查询(Query)、键(Key)和值(Value)矩阵。采用8个并行的注意力头分别计算注意力权重,再将各头输出拼接并通过线性层融合。为稳定训练过程并缓解梯度问题,模块中引入了残差连接和层归一化(Layer Normalization)。接着,通过全局平均池化将变长的特征序列压缩为固定维度的向量,消除时间维度的影响。最后,该向量经由两层全连接网络(含Dropout正则化)映射至10个故障类别,并通过Softmax函数输出类别概率分布。

3.3 损失函数与优化

采用交叉熵损失函数:

$$\mathcal{L} = -\sum_{i=1}^C y_i \log(\hat{y}_i)$$

其中C为类别数, y_i 为真实标签, \hat{y}_i 为预测概率。

优化器选用Adam,初始学习率设为0.001,采用早停策略防止过拟合。

4 实验与结果分析

4.1 实验设置

本实验基于CWRU轴承数据集开展,选取驱动端12 kHz采样率下的数据,构建包含10个类别的标准分类任务(1类正常+3类单点故障×3种故障尺寸+1类复合故障)。每个类别随机抽取200个样本,每个样本截取连续2048点振动信号,不进行滤波、降噪或时频变换等预处理。数据集按7:3比例划分为训练集和测试集,并采用5折交叉验证以确保结果的稳定性。为全面评估模型性能,选取支持向量机(SVM)、随机森林(Random Forest)、1D-CNN、LSTM、CNN-LSTM和Transformer作为对比模型。评价指标包括准确率、精确率、召回率和F1-score。

4.2 实验结果

表1 实验结果

模型	平均准确率(%)	F1-score
SVM	89.45	0.887
Random Forest	91.23	0.905
1D-CNN	97.81	0.976
LSTM	96.54	0.962
CNN-LSTM	98.12	0.979
Transformer	98.67	0.985
1D-CNN-MHA (本文)	99.23	0.991

从表1可见,所提模型在所有对比模型中表现最优。尤其在复合故障和滚动体故障类别上,准确率提升显著,说明MHA有效增强了模型对复杂故障模式的判别能力。混淆矩阵显示,各类别分类错误率均低于1%,且无明显类别混淆现象,表明模型具有良好的类别区分能力。

4.3 消融实验

为验证各模块贡献,进行消融实验:

仅1D-CNN: 准确率97.81%;

1D-CNN + 单头注意力: 98.45%;

1D-CNN + MHA (无残差): 98.92%;

完整模型(含残差与LayerNorm): 99.23%。

结果表明,多头机制、残差连接和归一化均对性能提升有积极作用。

4.4 鲁棒性分析

在测试集中加入高斯白噪声(SNR = 10dB),所提模型准确率仍保持在97.5%以上,优于其他模型,证明其具有较强抗噪能力。

5 结语

本文系统研究基于深度学习的轴承故障诊断方法,提出融合一维卷积神经网络与多头自注意力机制的新型诊断模型1D-CNN-MHA,该模型通过1D-CNN提取局部时域特征,借助多头自注意力机制建模全局上下文依赖,在CWRU标准数据集上平均诊断准确率达99.23%,为构建智能故障诊断系统提供有效路径。不过,研究存在局限,实验仅基于实验室可控环境下的CWRU数据,未在真实工业设备部署验证,未考虑变工况影响,且模型参数量大,在边缘计算设备部署有实时性挑战。未来,可探索跨工况迁移学习提升适应能力,结合模型压缩技术设计轻量化网络,融合多源异构信息构建多模态诊断框架,引入可解释性分析工具增强信任度。随着深度学习等深度融合,轴承故障诊断技术将向更高精度等方向演进,为智能制造和预测性维护提供支撑。

参考文献

- [1]王宏恩.小样本条件下基于深度学习的轴承故障诊断模型研究[D].东北林业大学,2025.
- [2]韩慧君.基于生成类深度学习模型的轴承故障诊断方法研究[D].西安理工大学,2024.
- [3]刘月文,刘文森,李永亭,等.生成式零样本深度学习模型的轴承故障诊断方法[J].中国农机化学报,2026,47(01):201-209.
- [4]王有道,张鹏.国内深度学习在轴承故障诊断领域的研究综述[J].产业创新研究,2025,(12):88-90.