

DOI:10.3969/j.issn.1001-4551.2024.02.002

基于卷积神经网络的滚动轴承故障诊断研究综述*

赖荣燊, 闫高强

(厦门理工学院 机械与汽车工程学院, 福建 厦门 361021)

摘要:随着机器学习技术的兴起,深度学习被用于故障诊断领域并得到迅速发展,其中,卷积神经网络是具有出色特征提取能力的深度学习模型,因其适用于处理图像数据和高维数据而成为故障诊断研究的热点。针对传统故障诊断方法难以解决轴承振动信号存在的特征提取困难和信号噪声污染的问题,为高效、准确地完成滚动轴承故障诊断工作,首先,对卷积神经网络的结构进行了简单介绍,并研究了近年来经典卷积神经网络模型用于滚动轴承故障诊断的重要进展;然后,从深度特征提取、超参数调整和网络结构优化等角度,对各种优化卷积神经网络的方法原理进行了简单介绍,详细探讨了将卷积神经网络应用于滚动轴承故障诊断的优化途径和已经取得的研究进展;最后,对几种典型优化方法的优势与不足进行了比较,并对不同角度优化卷积神经网络的途径进行了总结。研究结果表明:基于卷积神经网络的滚动轴承故障诊断方法还需要解决数据不平衡、模型特征提取能力不足和泛化性不强的问题,后续研究工作应聚焦于多源数据融合、模型性能优化以及多方技术结合等方向。

关键词:滚动轴承;故障识别;卷积神经网络;深度学习;深度特征提取;超参数调整;网络结构优化

中图分类号:TH133.3

文献标识码:A

文章编号:1001-4551(2024)02-0194-11

Review of rolling bearing fault diagnosis based on convolutional neural network

LAI Rongshen, YAN Gaoqiang

(School of Mechanical and Automotive Engineering, Xiamen University of Technology, Xiamen 361021, China)

Abstract: With the rise of machine learning technology, deep learning (DL) was utilized in the field of fault diagnosis and underwent rapid development. Among these developments, the convolutional neural network was a deep learning model with excellent feature extraction ability, which had become a hot spot in fault diagnosis research because it was suitable for processing image data and high-dimensional data. Aiming at the problem of the traditional fault diagnosis methods in addressing the difficulties of feature extraction from bearing vibration signals and the contamination of signals by noise, to efficiently and accurately accomplish the fault diagnosis of rolling bearings, firstly, the structure of convolutional neural network (CNN) was briefly introduced, and the important progress of classical convolutional neural network model for rolling bearing fault diagnosis in recent years was studied. Then, from the perspectives of deep feature extraction, hyperparameter adjustment and network structure optimization, various methods for optimizing convolutional neural networks were briefly introduced, and the optimization methods of applying convolutional neural networks to rolling bearing fault diagnosis and the research progress made were discussed in detail. Finally, the advantages and disadvantages of several typical optimization methods were compared, and the ways to optimize convolutional neural networks from different angles were summarized. The results show that the rolling bearing fault diagnosis method based on convolutional neural network also needs to solve the problems of data imbalance, insufficient model feature extraction ability and weak generalization, and the follow-up research work should focus on multi-source data fusion, model performance optimization and multi-party technology combination.

Key words: rolling bearing; fault identification; convolutional neural network (CNN); deep learning (DL); deep feature extraction; hyperparameter adjustment; network structure optimization

收稿日期:2023-05-29

基金项目:福建省自然科学基金资助项目(2022J011246);科技部创新方法工作专项(2019IM010300)

作者简介:赖荣燊(1983-),男,福建长汀人,博士,讲师,主要从事绿色产品族与科技创新方法方面的研究。E-mail:2016000053@xmut.edu.cn

0 引言

智能制造背景下,机械设备正在沿着一体化、自动化、智能化趋势不断向前发展。在机械设备的发展过程中,旋转部件的结构越来越精密。滚动轴承是旋转部件中最常见的零件,它经常因为长时间高速旋转而产生磨损,所以在生产活动中更容易发生故障。研究显示,滚动轴承产生的故障是很多重大安全事故的导火索,一旦出现故障,轻则使生产机器受损,重则可能造成生产人员伤亡。因此,滚动轴承故障诊断研究具有重大意义。

经过国内外研究学者的努力,滚动轴承故障诊断技术发生了巨大变革,从传统的人工提取数据并分析故障原因,到现在的依靠人工智能领域的深度学习进行自主诊断。40 年来的研究探索从未间断,为滚动轴承故障诊断贡献了大量实用方法。

在多种故障诊断研究中^[1-4],比较常见的一种方法是基于深度学习框架的滚动轴承故障诊断方法,它包括故障轴承数据采集、数据预处理、对故障数据特征提取和识别故障类型四部分。传统故障诊断技术需要依赖技术人员的经验和专业知识进行故障识别,这极大限制了滚动轴承故障诊断的发展。首先,特征提取必须依赖工程师的经验 and 专业知识,微小的故障特征易被误删或被噪音掩盖,存在较大的主观性和盲目性;其次,提取到的特征主要用于解决特定的故障问题,方法通用性较差;另外,在实际工作环境下,轴承通常是变负载、变转速的,如大货车载重和速度变化、水利发电机组水流速度变化等。这导致系统采集到的轴承振动信号存在脉冲间隔变化、特征提取困难、信号噪声污染等问题,仅靠人工进行故障诊断的传统方法无法解决这些条件下的轴承故障诊断问题。

2006 年,HINTON G E 等人^[5]提出了深度置信网络的方法,采用无监督预训练中间层的方法,使得深度学习(DL)不再受限于手动选择的特征;但该方法的泛化性较差,无法应用于其他方面。DL 利用深层神经网络结构对输入样本数据进行逐层特征提取,摆脱了对专家经验的依赖,实现了自主诊断和故障分类的目的。其中,卷积神经网络(CNN)因其强大的数据挖掘能力及特征自适应学习能力在机械状态监测领域受到研究人员的极大关注,将 CNN 应用到故障诊断领域的研究成果颇丰。

CNN 作为一种深度学习网络模型,可以自主学习不同故障信号的故障特征,实现高准确度滚动轴

承的故障诊断目的。曲建岭等人^[6]较早提出了一维 CNN 滚动轴承故障诊断方法,此后将 CNN 用于轴承故障诊断的研究成果大量问世,促进了轴承故障诊断技术的发展;但该方法存在诊断精度不高的缺点。目前,在 CNN 应用于滚动轴承故障诊断方面,还存在数据不平衡、信号噪声使模型性能减弱、模型特征提取能力不足以及泛化性不强等需要解决的问题。

笔者回顾近 5 年来 CNN 用于轴承故障诊断领域的研究进展,从深度特征提取、超参数调整、网络结构优化等角度阐述 CNN 应用于轴承故障诊断的优化路径,并对几种经典 CNN 模型、特征提取优化方法和超参数优化算法进行比较,最后,指明后续研究工作应聚焦于多源数据融合、模型性能优化以及多方技术结合等方向。

1 卷积神经网络

CNN 结构简单但具有强大的特征提取能力,通过构建多个卷积层和池化层可以将输入数据的深层特征提取出来,有效减少模型训练参数量,避免算法过拟合。此外,网络层数越深,非线性拟合能力越强,则能够处理更高维度的数据,因此,CNN 在轴承故障诊断领域得到了广泛应用。

1.1 网络结构

CNN 的网络结构主要由卷积层、激活函数、池化层、全连接层和输出层的 SoftMax 分类器五部分组成。通过组合交替和堆叠多个卷积层、激活函数和池化层就可以设计出更深层的 CNN 结构。

CNN 模型的基本架构如图 1 所示。




图 1 CNN 模型的基本架构

Fig. 1 Basic architecture of CNN model

卷积运算是 CNN 的核心部分,CNN 应用矩形卷积核遍历输入数据的每一个特征数值,将计算后的数值作为下一层卷积层的输入数据。激活函数引入非线性表达,增加了网络的表达能力和学习复杂模式的能力。池化层的主要功能是降低特征图的空间维度,提取主要特征并减少计算量。

全连接层是卷积网络部分与输出层(SoftMax 分类器)的连接过渡结构,全连接层通过进行特征融合和分类,将卷积层输出映射到最终的输出类别。全连接网络的层与层之间的所有神经元相互连接,负责将卷积输出的特征图转化成一维向量,实现 CNN 端到端的学习过程。SoftMax 分类器将网络输出转化为概率分布,用于多分类任务的概率预测和决策。

1.2 经典 CNN 模型

CNN 自被提出以来,经过不断的发展演变,产生了多种经典的模型,如 LeNet、AlexNet、GoogleNet、ResNet、Vgg 以及 DenseNet 等。这些模型具备稀疏交互、参数共享等特点,可以有效简化故障诊断流程,减少训练参数数量,提高边缘检测效率,既可降低训练难度,又可以提高识别准确率。由于这些出色的特性,CNN 的信号处理能力优于其他网络。

赵小强等人^[7]采用改进 LeNet-5 模型提出了不依赖预处理复杂信号的方法,改进卷积后的 LeNet-5 可以直接从原始信号中端到端高效地提取到更完整、更精准的深层特征信息。徐卫鹏等人^[8]采用经典 AlexNet 模型的方法,建立了一种由池化层和多级交替卷积层组成的一维 CNN 模型,采用滑窗法可完成对原始输入信号特征的自适应提取。姚齐水等人^[9]以 GoogleNet 经典模型为基础,改进了 Inception V2 对输入信号特征提取的过程,提出了一种改进 Inception V2 模块和 CBAM 注意力机制的滚动轴承故障诊断方法。姚立等人^[10]采用格拉姆角场编码的方法,将一维轴承振动信号进行了整合,将处理后的信号输入 Vgg16 模型,进行了充分的特征提取。姜家国等人^[11]提出了将马尔可夫转移场与 DenseNet 模型结合的方法,保留了原始振动信号时序信息之间的时间相关性,使得 DenseNet 转向更适合处理的图像数据。高峰等人^[12]提出了利用经典模型自身为特征提取器的方法,以原始振动数据为输入,充分发挥 CNN 的特征提取能力。樊星男等人^[13]认为 Hankel 矩阵可以和 CNN 模型互相取长补短,采用区间归一化方法,既保持了特征信号之间的连续性,又可以充分发挥经典模型的特征提取能力。

总体而言,经典 CNN 模型在轴承故障诊断问题上具有较好的表现,能够从原始数据中学习特征并进行故障分类。然而在实际应用中,需要根据具体的问题和数据集进行模型选择、数据处理和模型调优等步骤,以获得更准确和可靠的故障诊断结果。应用 CNN 处理滚动轴承故障诊断问题的过程如图 2 所示。

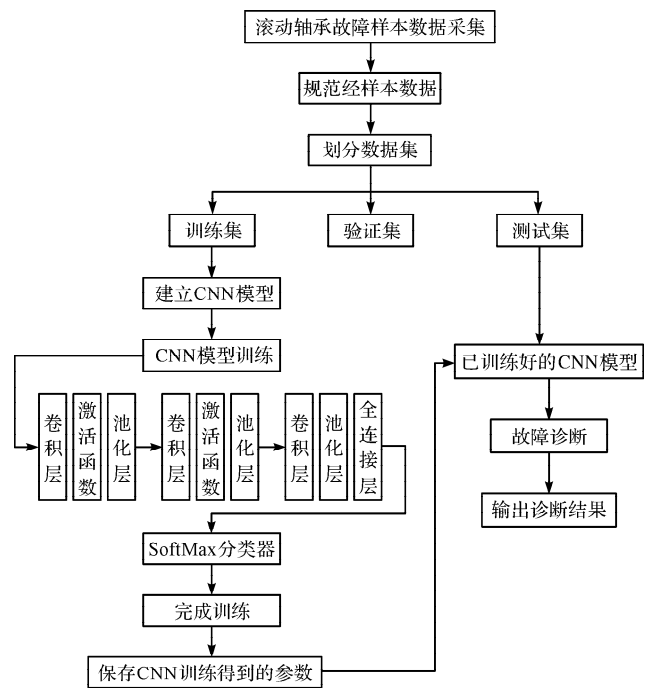


图 2 应用 CNN 处理滚动轴承故障诊断问题的过程
Fig.2 The process of applying CNN to deal with rolling bearing fault diagnosis

2 深度特征提取

特征提取质量的关键在于输入信息特征的优劣、信号处理方法的选择和模型自身的特征提取能力。通过对采集到的振动信号进行一系列处理、转换和分析,能够将原始振动信号转化为时域和频域信息,从而更好地理解 and 利用信号的信息。

这种信号处理过程能够深入挖掘振动信号中的特征和模式,为进一步的数据分析和应用提供了有力的基础。

经典 CNN 模型比较如表 1 所示。

表 1 经典 CNN 模型比较

Table 1 Comparison of classical CNN models

模型名称	特点	优点	局限性
LeNet	使用三个层作为一个系列:卷积,池化,非线性;层与层之间的稀疏连接避免大的计算成本	直观地了解卷积神经网络的构建方法,可以为分析、构建更复杂、更多层的卷积神经网络做准备	对于复杂问题的处理结果不理想
AlexNet	使用数据增强技术,加入 Dropout 层,解决过度拟合训练数据的问题	使用了新技术,优势显著,错误率较低,可以使用 GPU 运行	当输入值非常大或者非常小的时候会出现饱和现象

续表

模型名称	特点	优点	局限性
GoogleNet	同一层内使用不同尺寸的卷积核,提升感知力,通过填充实现输出特征面积一致	模型又准又轻,引入 Inception 模块,利用不同卷积核提取不同程度的信息	参数太多容易过拟合,计算的复杂度较高
ResNet	层间残差跳连,引入前方信息,减少梯度消失,使神经网络层数增加成为可能	前馈/反馈传播算法,结构更加简单,增加恒等映射基本不会降低网络的性能	增加深度会导致梯度弥散或梯度爆炸,训练速度十分缓慢
Vgg	使用小卷积核提高识别准确率;网络结构规整,适合并行加速	结构简单,小卷积核,小池化核	耗费资源,使用了更多的参数,训练时间过长,存储容量大
DenseNet	建立前层与后层之间的“短路连接”或“捷径”,从而能训练出更深的卷积神经网络	缓解梯度消失,减少计算量,参数量更少,性能更高	消耗内存过大,密集连接不佳

2.1 信号处理方法

当前,大多数对于优化特征提取的研究思路是应用信号分析和数值计算等方法对采集到的原始数据进行处理,再将其作为 CNN 卷积操作的输入数据,通过提高信号提取精度和减少模型计算量,进行滚动轴承故障的分类。特征提取中的时频分析可以揭示非平稳振动信号的动态特性,时频分析方法包括短时傅里叶变换(short-time Fourier transform, STFT)、经验模态分解(empirical mode decomposition, EMD)、变分模态分解(variational mode decomposition, VMD)、小波变换(wavelet transform, WT)和小波包分解(wavelet packet decomposition, WPD)等。

STFT 是一种线性的时频分析方法。朱沁玥等人^[14]在研究中采用 STFT 的方法来变换和估算旋转设备的转速信息。由于 STFT 的窗口大小固定,无法针对不同信号频率进行自适应,因此 STFT 无法从非平稳的信号中精确提取到瞬时信号特征,致使 STFT 的精确性相对较低。EMD 无需借助小波基函数,只针对信号本身进行分解,避免了 WT 的局限性。

此外,为解决小波基函数造成的信号降噪效果降低和信号有效成分丢失的问题,田少宁等人^[15]提出了

CNN 与 VMD 结合的方法,采用可变尺度的非递归信号处理方法提取了非平稳信号的特征信息,其具有较小的端点效应、较高的运算效率和良好的噪声鲁棒性。WT 的本质是采用小波基函数对信号进行各种加权和滤波操作,因此包含各种尺度下的信号特征信息,故能处理突变和非稳定信号。WPD 作为一种多时间分辨率的时频分析算法,通过对信号进行小波包变换,将其转化为低频带的近似系数和高频带的细节系数。

2.2 特征提取优化

信号的输入特征直接影响 CNN 的故障诊断和预测结果。信号特征提取的方法不同,获取的信息不同,同一信号提取到的特征参数不同,故障诊断的结果也会有所差异。

WANG H 等人^[16]针对信号特征精度提取困难的问题,提出了一种 STFT 与多同步压缩变换相结合的信号特征提取方法,建立了局部特征空间与故障空间之间的映射。BAI R 等人^[17]采用多尺度剪切融合数据增强的方法对故障信号进行了增强,通过 STFT 转化后利用多通道 CNN 进行了数据融合和故障分类。YAO P 等人^[18]采用梅尔频率倒谱技术的方法提取振动信号不同频段的特征,通过倒拍光谱举升技术的特征增强过程,提高了信号提取精度和方法的适应性。丁春嵘等人^[19]和陈晓雷等人^[20]提出了应用长短时记忆网络模型,考虑了 CNN 对于提取序列数据和信息数据的顺序性并在此基础上进行了优化,提高了信息的提取精度。董绍江等人^[21]和 DING C 等人^[22]为避免丢失微弱信号的故障细节特征,采用将带噪声信号经奇异值分解的方法,消除了噪声模态混叠后再将其用于分解原始振动信号,保证了 CNN 特征提取的适应性、全面性和多样性。李魁等人^[23]提出了一种融合 VMD 和 CNN 的滚动轴承故障诊断方法,该方法不仅去除了信号中的噪声成分,还将相关系数作为参考指标以优化模态分量选取个数。陈仁祥等人^[24]和王妮妮等人^[25]采用 WT 获取振动信号时频图的方法,将时频图像作为 CNN 的输入,充分提取了轴承振动信号的关键故障特征。LI J 等人^[26]认为故障信号中信息最丰富的部分只占时频域信号的小部分,提出了基于反向传播神经网络(back propagation, BP)的多尺度局部特征学习法。SONG X 等人^[27]提出了 BP 神经网络与粒子群算法结合的方法,先对振动信号进行了 EMD 分解,再利用算法优化的 BP 神经网络对滚动轴承故障进行了分类。

WPD 技术不仅可以根据需要调整时间分辨率的大小来提取不同频率的信号,还能够同时获取低频和

高频信号,从而更全面地分析振动信号的特征。

楼剑阳等人^[28]采用 WPD 对振动信号进行了预处理,获得了表征信号相似的小波系数的方法,再将其输入 CNN 进行特征提取,实现了轴承故障分类目的。杨蕊等人^[29]采用计算原始时域信号频谱在不同偏移点数下的相关峭度值,将其作为新的样本数据方法,使得数据之间的差异更加显著。牛锐祥等人^[30]构建了多尺度卷积层,充分捕捉了信号特征的过程,增强了特征的复用性。雷春丽等人^[31]则利用马尔可夫转移场编码方法,使振动信号的时间相关性特征得以保留。张珂等人^[32]提出的多模态注意力技术和丁雪等人^[33]提出的多尺度注意力方法,都使得 CNN 可以更加充分地完成故障信号的特征提取。刘伟等人^[34]提出了由两个通道组成的并行一维 CNN 模型,该模型可以用于分别获取轴承振动信号的时域信息和频域信息。赵小强等人^[35]采用带跳跃连接线的卷积模块融合 CNN 的方法,防止提取到的丰富信号特征在卷积层向前传递时丢失。古天龙等人^[36]利用深层多尺度卷积操作过程,提高了 CNN 对故障信号挖掘的深度和精度。蒙志强等人^[37]在 CNN 中采用多尺度卷积核并联的方法对轴承振动信号进行了更充分的故障信息提取。金江涛等人^[38]对信号处理方法进行了创新,提出了基于混沌理论的相空间重构法,进一步推动了轴承故障诊断研究。

特征提取的重要性是将滚动轴承的故障诊断问题聚焦为轴承故障特征信息的提取问题,采用各种信号处理方法可以减少噪声和干扰,CNN 可以提取有区分性的特征,并使模型能够更好地学习和识别轴承故障模式,解决了轴承故障诊断中信号包含噪声、数据难以采样和数据分布差异较大的问题。

然而,当轴承工况差异较大且信号含有高噪声时,特征提取性能会显著下降。

信号分析方法比较如表 2 所示。

表 2 信号分析方法比较

Table 2 Comparison of signal analysis methods

特征类别	分析方法	优点	局限性
时域特征	均值、方差、最大值、峰值、峭度、波形指标、脉冲指标等	使用波形比较不同信号,可以清楚看到振动信号	特征信息存在变化,不利于检测
频域特征	频率中心、特征频域等	降低系统复杂性,更好抑制噪声	降维后会丢失部分有效信息,降低预测精度

续表

特征类别	分析方法	优点	局限性
时频域特征	短时傅里叶变换、小波变换、小波包分解、经验模态分解、变分模态分解等	多尺度分析能力;能够将信号转化为直观的频谱、时频图或分解分量	经验模态分解和变分模态分解缺乏理论证明,小波变换高频细节信息在解析过程中易被丢失
图像特征	小波功率谱等	将时域和频域信息可视化,清晰显示故障特征	原始信号转化后会丢失一部分特征信息

3 超参数调整

CNN 的模型包含的参数通常可以分为一般参数与超参数。其中一般参数是模型经过不断地训练自动调整的,不需要人工进行设置。而对于超参数,模型无法通过训练来调整,一般是在模型训练前就设定好,如设置学习率 0.1、0.001 和训练批量大小 64、128。

超参数的设定值通常依赖过去的经验,但是依靠经验来设定数值的方法在用于解决具体问题时通常效果不佳,因此,对于超参数的优化调整是基于 CNN 的滚动轴承故障诊断研究的重要组成部分。

3.1 调整方法

近几年来,国内外研究学者开始以调整 CNN 中的最优超参数来进行 CNN 故障诊断的创新,随后各类算法的创新应用大量涌现。其中包含贝叶斯优化算法、差分进化算法、布谷鸟搜索算法、最大相关峭度反卷积算法以及稀疏搜索算法等,这些调整方法都为 CNN 用于滚动轴承故障诊断提供大量研究支持。

贝叶斯优化算法 (Bayesian optimization, BO) 是利用高斯回归过程搜寻目标函数最优值的算法。BO 不是使用穷举搜索算法,而是针对成本函数 $f(x)$ 值密度较高的区域进行搜索,这大大减少了计算工作量。采集函数和概率代理模型是贝叶斯优化的关键组成部分。采集函数由目标函数的后验概率组成,用于选择评估点以最小化总损失。

差分进化算法 (differential evolution algorithm, DE) 是一种基于种群的优化算法,相比其他优化算法,DE 具有较高的可操控性。它仅有三个控制参数需要调节,具有简单结构和易于实现的优势,同时具备良好的全局搜索能力。

布谷鸟搜索算法 (cuckoo search algorithm, CSA) 是一种模拟布谷鸟寄生孵化行为的优化算法,它被广

泛应用于解决各种优化问题。CSA 具有强大的全局搜索能力,可以发现最佳的超参数设定值,从而提升 CNN 的性能和效果。

参数优化的最大相关峭度反卷积算法(maximum correlated kurtosis deconvolution, MCKD)是通过迭代选择一个有限脉冲响应滤波器,滤波器利用故障的周期性,突出被强噪声覆盖的信号中的连续脉冲。MCKD 具有多个输入参数,并对它们有严格的要求。除原始信号和原始采样率外,滤波器长度、故障周期、最大迭代次数以及位移顺序等都对 MCKD 滤波器的函数有很大的影响。这些参数的选择必须合适和精确,以突出 MCKD 算法的优越性。

除此之外,还有稀疏搜索算法(sparse search algorithm, SSA),SSA 模仿麻雀觅食的过程对 CNN 的最优参数组合进行搜索,通过快速搜索和收敛的过程确定适合的参数,然后建立一个 CNN 故障诊断模型。

3.2 调整超参数

针对调整超参数的优化方法,LU Y 等人^[39]和汤亮等人^[40]提出了 BO 与 CNN 进行结合的诊断方法。该方法通过对 CNN 的学习率等超参数进行调整,提高了 CNN 对于故障类型的分类能力。孙祺淳等人^[41]采用 DE 算法的优势来调节 CNN 中的学习率、卷积核大小和数量等 6 个超参数,降低了网络波动,将模型的诊断精度和稳定性一并作为算法优化的目标。XIAO M 等人^[42]利用 CSA 的全局搜索能力,不断搜索 CNN 的输入层、隐层和输出节点数目的最优组合。GAO S 等人^[43]提出了 MCKD 和 CNN 的滚动轴承复合故障诊断方法,利用该算法对 CNN 的卷积核大小和迭代次数进行优化,最后,将处理后的信号输入 CNN 模型中进行训练和测试。DONG S 等人^[44]提出了与稀疏搜索算法相结合的新方法,利用 SSA 搜索出 CNN 的学习率等最优超参数集合,再利用预处理后的数据集作为 CNN 的训练和测试样本。ZHUO P C 等人^[45]提出了 Elman 神经网络模型,结合遗传算法的全局寻优与 Elman 神经网络的局部寻优能力,构建出了新超参数集合的 Elman 神经网络模型,提高了轴承故障诊断的精度。XU Q 等人^[46]通过预训练 Off-CNN 的过程得到了全连接层的源域特征和参数集合,再初始化 On-CNN 的批处理大小和学习率等超参数,提高了故障诊断的准确率。AN F 等人^[47]提出了重叠群稀疏模型,通过分析信号突出特征来设置 CNN 的卷积核数目等超系数,可以更快地判断出轴承的故障类型。王亚辉等人^[48]采用粒子群算法的方法搜索出 CNN 的层数、CNN 层的

类别、池化层的类型、卷积核的尺寸、卷积核的个数、全连接层神经元的个数等最优参数集合,提高了基于 CNN 进行轴承故障诊断的准确率。

利用调整 CNN 超参数的方法包括调整网络结构、学习率、批量大小、正则化方法、优化器选择、数据增强策略和交叉验证等,增强了网络模型特征提取精确度和抗干扰能力,为研究复杂工况下滚动轴承故障诊断增加了理论支持,进一步提高了滚动轴承故障诊断和 CNN 的研究精度与深度。

超参数优化算法比较如表 3 所示。

表 3 超参数优化算法比较

Table 3 Comparison of hyperparameter optimization algorithms

优化算法	算法特征	优点	局限性
贝叶斯优化算法	核心部分是概率代理模型和采集函数	减少计算量,损失较小	误差较大,对数据输入形式敏感
差分进化算法	只有三个控制参数,易于实现	可操作性强、结构简单	对高维、多目标等问题存在早熟、停滞
布谷鸟搜索算法	模拟布谷鸟寄生孵化	全局智能优化,搜索力强大	收敛速度慢,进化后期多样性差
参数优化的最大相关峰度反卷积算法	通过迭代选择有限脉冲响应滤波器,具有多个输入参数	参数选择合适精确,算法本身优越	滤波器长度、故障周期和位移顺序对滤波器的函数有很大的影响
稀疏搜索算法	模仿麻雀觅食过程,搜索最优参数	快速搜索和收敛	会产生庞大数据集

4 网络结构优化

在故障诊断应用中,为了解决 LeNet、AlexNet、GoogleNet 等经典网络模型在变工况复杂条件下诊断精度不高、泛化性差的问题,诸多学者从 CNN 模型结构出发,结合实际数据和训练效果,对经典网络模型进行了优化和创新,结合多种方法进行了滚动轴承故障诊断,挖掘轴承振动信号数据下隐含的故障特征,有效检测了轴承工作状态,使模型训练速度更快、诊断结果更可靠。

目前,优化网络结构的研究取得了许多突破性进展,HE D 等人^[49]提出了一种新型轻量级 CNN 模型,模型主体以倒残差块构建,通过嵌入挤压激励块和引入轻量化概念,大幅减少了模型计算量,减少了降维过

程中的特征损失。LIU X 等人^[50]提出了结合 1D-CNN 和 2D-CNN 构建故障诊断模型,在其双域特征信息中提取了故障特征。XUE F 等人^[51]采用 CNN 模型对故障信号特征提取的过程,将特征融合策略进行连接,使模型整体特征提取效率大大提高。XU Y 等人^[52]提出了一种轻量级梯度提升机制(light gradient boosting machine, LGBM),关键是结合基于梯度的单侧采样和排他性特征绑定两种新方法,利用 LGBM 代替 SoftMax 分类器,提高了模型诊断的稳定性。ZHAO X 等人^[53]采用基于多尺度学习的多尺度残余收缩层和残余收缩块的方法,叠加了多个多尺度残余收缩层,从输入数据中自主学习振动信号的特征。刘洋等人^[54]提出了双池化层取代传统 CNN 中的全连接层的方法,进行了故障信息整合和数据特征再提取,最后经过 SoftMax 层完成了轴承故障状态分类。朱奇先等人^[55]采用三个连续的卷积层代替残差神经网络的数据池化层的方法,不仅增强了特征信息在密集块中的流动,还增强了特征信息的重复利用。王琦等人^[56]采用 1×1 的卷积核的方法,在提高一维 CNN 非线性表达能力的同时,将传统 CNN 中的全连接层替换为全局平均池化层,大大降低了模型计算量,不仅防止了模型过拟合,还提高了故障诊断效率。LIU Y 等人^[57]采用优化网络结构的方法,用胶囊网络取代 CNN 中的部分功能层,保持模型训练过程的平稳性。金江涛等人^[58]提出了一种混沌特征融合方法,将支持向量机作为分类器代替全连接层。咎涛等人^[59]提出了基于多输入层 CNN 的滚动轴承故障诊断模型,相比传统 CNN 诊断模型具有多个输入层,使得该模型可以更充分地提取原始信号的特征信息。XING Z 等人^[60]提出了一个多通道并行 CNN 模型,将在各并行信道中引入注意机制,提取具有较强冲击特性的故障特征。宫文峰等人^[61]针对传统 CNN 模型全连接层存在训练参数量过多导致模型训练时间较长的缺点,提出了将传统 CNN 的全连接层部分引入全局平均池化的方法。CHAO Z 等人^[62]提出了多尺度级联中点残差 CNN 的方法,将网络的学习目标更改为使用中点剩余块中的快捷连接,解决了梯度消失和梯度爆炸问题。WU Z 等人^[63]提出了深度强化传递神经网络模型,利用深度 Q 网络的自学习能力来训练一个对轴承故障分类的智能诊断代理。金江涛等人^[64]采用引入支持向量机的方法,考虑到故障信号的时间和空间尺度,将故障信号的时间序列作为输入源,以挖掘振动信号中隐藏的非线性信息。

为解决基于卷积神经的滚动轴承故障诊断与分类问题,一些研究学者在原有 CNN 结构上进行大胆改进

和创新,构建新的深层次网络结构,使故障诊断有更高的效率和精确度^[65]。

在轴承故障诊断中,调整 CNN 结构是一种常见的方法。以下是对轴承故障诊断中调整 CNN 结构常用方法的总结:

1) 多尺度卷积层。引入多尺度卷积层可以同时提取不同尺度的特征,从而更全面地描述轴承信号。这种方法能够增强模型对不同频率故障的识别能力,提高诊断的准确性;

2) 注意力机制。通过引入注意力机制,可以自动学习和选择重要的特征,提高模型对故障信号中关键部分的关注度;

3) 全局平均池化层。使用全局平均池化层可以将特征图的空间维度压缩为一个单一的数值,减少模型的数量和计算复杂度。这种方法可以防止过拟合,并提高模型的泛化能力;

4) 残差连接。采用引入残差连接的方法可以直接将输入信号与输出信号相加,从而保留原始信号的信息,避免信息损失和梯度消失问题,有助于提高模型对轴承故障的捕捉能力和表示能力。

5 结束语

为高效准确地完成滚动轴承故障诊断工作,笔者首先对 CNN 的结构进行了简单介绍,并研究了近年来经典 CNN 模型用于滚动轴承故障诊断的重要进展;然后,从深度特征提取、超参数调整和网络结构优化等角度,对各种优化 CNN 的方法原理进行了简单介绍,详细探讨了将 CNN 应用于滚动轴承故障诊断的优化途径;最后对几种典型优化方法的优势与不足进行了比较。

通过笔者分析论述,得到的结论如下:

1) 早期经典模型存在一些局限性,如特征提取精度和效率较低、模型泛化性能较差以及学习率不高等问题^[66];

2) 采用基于深度特征提取的各种信号处理方法可以减少噪声的干扰和影响,更利于 CNN 提取差异性的特征;

3) 采用调整超参数提高模型学习率的方法可以将研究重点转移至模型自身的提取精度,通过调整超参数来提高模型的诊断准确率;

4) 采用优化模型结构的方法可以使模型的提取精度和泛化性能得到增强,提高了轴承故障诊断分类的准确率,但需要在数据量较大的情况下,模型的性能才能更佳。

尽管基于 CNN 的滚动轴承故障诊断研究取得了十分显著的进展,但仍有需要改进和发展的空间。例如,需要解决数据不平衡、模型特征提取能力不足和泛化性不强的问题。因此,后续的相关研究工作应聚焦于多源数据融合、模型性能优化以及多方技术结合等方向。

参考文献 (References):

- [1] 刘玉明,刘自然,王鹏博. 基于 ISSA-VMD 的滚动轴承早期故障诊断方法[J]. 机电工程,2023,40(9):1426-1432.
LIU Yu-ming, LIU Zi-ran, WANG Peng-bo. Early fault diagnosis method of rolling bearings based on ISSA-VMD [J]. Journal of Mechanical and Electrical Engineering, 2023,40(9):1426-1432.
- [2] ZHANG K, WANG J, SHI H, et al. Variable working condition rolling bearing fault diagnosis method based on improved triplet loss algorithm[J]. Automation and Systems, 2023,21(4):1361-1372.
- [3] 潘晓博,葛鲲鹏,钱孟浩,等. 基于改进联合分布适应的轴承故障诊断[J]. 机电工程,2023,40(9):1354-1362.
PAN Xiao-bo, GE Kun-peng, QIAN Meng-hao, et al. Bearing fault diagnosis based on improved joint distribution adaptation [J]. Journal of Mechanical and Electrical Engineering, 2023,40(9):1354-1362.
- [4] 王正奇,谷艳玲,陈长征,等. 基于多源信息融合的风电机组轴承故障诊断方法[J]. 机电工程,2023,40(9):1411-1418.
WANG Zheng-qi, GU Yan-ling, CHEN Chang-zheng, et al. Fault diagnosis method of wind turbine bearing based on multi-source information fusion [J]. Journal of Mechanical and Electrical Engineering, 2023,40(9):1411-1418.
- [5] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006,18(7):1527-1554.
- [6] 曲建岭,余路,袁涛,等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报,2018,39(7):134-143.
QU Jian-ling, YU Lu, YUAN Tao, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018,39(7):134-143.
- [7] 陈小强,罗维兰. 改进卷积 Lenet-5 神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报,2022,36(6):113-125.
CHEN Xiao-qiang, LUO Wei-lan. Bearing fault diagnosis method for improved convolutional Lenet-5 neural network [J]. Journal of Electronic Measurement and Instrumentation, 2022,36(6):113-125.
- [8] 徐卫鹏,徐冰. 基于卷积神经网络的轴承故障诊断研究[J]. 山东科技大学学报,2021,40(6):121-128.
XU Wei-peng, XU Bing. Research on bearing fault diagnosis based on convolutional neural network [J]. Journal of Shandong University of Science and Technology, 2021,40(6):121-128.
- [9] 姚齐水,别帅帅,余江鸿,等. 一种结合改进 Inception V2 模块和 CBAM 的轴承故障诊断方法[J]. 振动工程学报,2022,35(4):949-957.
YAO Qi-shui, BIE Shuai-shuai, YU Jiang-hong, et al. A bearing fault diagnosis method combining Improved Inception V2 Module and CBAM [J]. Journal of Vibration Engineering, 2022,35(4):949-957.
- [10] 姚立,孙见君,马晨波. 基于格拉姆角场和 CNN-RNN 的滚动轴承故障诊断方法[J]. 轴承,2022,64(2):61-67.
YAO Li, SUN Jian-jun, MA Chen-bo. Fault diagnosis method of rolling bearing based on gram angle field and CNN-RNN [J]. Bearing, 2022,64(2):61-67.
- [11] 姜家国,郭曼利. 基于 MTF 和 DenseNet 的滚动轴承故障诊断方法[J]. 工矿自动化,2022,48(9):63-68.
JIANG Jia-guo, GUO Man-li. Fault diagnosis method of rolling bearing based on MTF and DenseNet [J]. Automation for Industry and Mining, 2022,48(9):63-68.
- [12] 高峰,曲建岭,余路,等. 基于卷积神经网络的滚动轴承故障诊断算法[J]. 信息技术,2019,43(4):68-72.
GAO Feng, QU Jian-ling, YU Lu, et al. Fault diagnosis algorithm for rolling bearings based on convolutional neural network [J]. Information Technology, 2019,43(4):68-72.
- [13] 樊星男,刘晓娟. 二维卷积神经网络在轴承故障诊断中的应用[J]. 机械设计与研究,2022,38(3):109-113.
FAN Xing-nan, LIU Xiao-juan. Application of two-dimensional convolutional neural network in bearing fault diagnosis [J]. Mechanical Design and Research, 2022,38(3):109-113.
- [14] 朱沁玥,何海昊,李锋,等. 基于短时傅里叶变换和深度卷积神经网络的直升机齿轮箱故障诊断方法[J]. 失效分析与预防,2022,17(1):1-8.
ZHU Qin-yue, HE Hai-hao, LI Feng, et al. Fault diagnosis method of helicopter gearbox based on short-time Fourier transform and deep convolutional neural network [J]. Failure Analysis and Prevention, 2022,17(1):1-8.
- [15] 田少宁,甄冬,李海洋,等. 基于自适应变分模态分解和调制信号双谱的滚动轴承故障诊断方法[J]. 轴承,2023,65(2):39-45,53.
TIAN Shao-ning, ZHEN Dong, LI Hai-yang, et al. Fault diagnosis method of rolling bearings based on adaptive variational mode decomposition and modulation signal double spectrum [J]. Bearings, 2023,65(2):39-45,53.
- [16] WANG H, DU W. Multi-source information deep fusion for rolling bearing fault diagnosis based on deep residual

- convolution neural network [J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2022, 236 (13): 7576-7589.
- [17] BAI R, XU Q, MENG Z, et al. Rolling bearing fault diagnosis based on multi-channel convolution neural network and multi-scale clipping fusion data augmentation [J]. Measurement, 2021, 184(11):109885.
- [18] YAO P, WANG J, ZGAN F, et al. Intelligent rolling bearing imbalanced fault diagnosis based on mel-frequency cepstrum coefficient and convolutional neural networks[J]. Measurement, 2022, 205(12):112143.
- [19] 丁春嵘,周雨轩,胡 浩,等. 基于深度特征提取神经网络的滚动轴承故障诊断[J]. 北京化工大学学报, 2022, 49(1):106-112.
DING Chun-rong, ZHOU Yu-xuan, HU Hao, et al. Fault diagnosis of rolling bearings based on deep feature extraction neural network[J]. Journal of Beijing University of Chemical Technology, 2022, 49(1):106-112.
- [20] 陈晓雷,孙永峰,李 策,等. 基于卷积神经网络和双向长短时记忆网络稳定抗噪声滚动轴承故障诊断[J]. 吉林大学学报, 2022, 52(2):296-309.
CHEN Xiao-lei, SUN Yong-feng, LI Ce, et al. Stable anti-noise fault diagnosis of rolling bearing based on CNN-BiLSTM[J]. Journal of Jilin University, 2022, 52 (2): 296-309.
- [21] 董绍江,裴雪武,吴文亮,等. 基于多层降噪技术及改进卷积神经网络的滚动轴承诊断方法[J]. 机械工程学报, 2020, 57(1):148-156.
DONG Shao-jiang, PEI Xue-wu, WU Wen-liang, et al. Rolling bearing diagnosis method based on multilayer noise reduction technology and improved convolutional neural network[J]. Journal of Mechanical Engineering, 2020, 57 (1):148-156.
- [22] DING C, FENG Y, WANG M. Rolling bearing fault diagnosis based on variational mode decomposition and deep convolutional neural network [J]. Vibration and Shock, 2021, 40(2):287-296.
- [23] 李 魁,隋 新,刘春阳,等. 基于变分模态分解和卷积神经网络融合的滚动轴承故障诊断方法[J]. 机械传动, 2022, 46(11):134-140.
LI Kui, SUI Xin, LIU Chun-Yang, et al. Fault diagnosis method of rolling bearings based on variational modal decomposition and convolutional neural network fusion[J]. Mechanical Transmission, 2022, 46(11):134-140.
- [24] 陈仁祥,唐林林,胡小林,等. 不同转速下基于深度注意力迁移学习的轴承诊断方法[J]. 振动与冲击, 2022, 41(12):92-101.
CHEN Ren-Xiang, TANG Lin-Lin, HU Xiao-Lin, et al. Bearing diagnosis method based on deep attention transfer learning at different speeds [J]. Journal of Vibration and Shock, 2022, 41(12):92-101.
- [25] 王妮妮,马 萍,张宏立,等. 基于多尺度深度卷积网络特征融合的滚动轴承故障诊断[J]. 太阳能学报, 2022, 43(4):351-358.
WANG Ni-ni, MA Ping, ZHANG Hong-li, et al. Fault diagnosis of rolling bearings based on feature fusion of multi-scale deep convolutional network[J]. Journal of Solar Energy, 2022, 43(4):351-358.
- [26] LI J, YAO X, WANG X, et al. Multiscale local features learning based on BP neural network for rolling bearing intelligent fault diagnosis [J]. Measurement, 2020, 153 (C):107419.
- [27] SONG X, WANG H, LIU Y, et al. A fault diagnosis method of rolling element bearing based on improved PSO and BP neural network [J]. Journal of Intelligent & Fuzzy Systems, 2022, 43(5):5965-5971.
- [28] 楼剑阳,南国防,宋传冲. 基于小波包分解和卷积神经网络的滚动轴承故障诊断[J]. 轻工学报, 2021, 36(3):79-87.
LOU Jian-yang, NAN Guo-fang, SONG Chuan-chong. Fault diagnosis of rolling bearings based on wavelet packet decomposition and convolutional neural network [J]. Journal of Light Industry, 2021, 36(3):79-87.
- [29] 杨 蕊,李宏坤,王朝阁,等. 利用 FCKT 以及深度自编码神经网络的滚动轴承故障智能诊断[J]. 机械工程学报, 2019, 55(7):65-72.
YANG Rui, LI Hong-kun, WANG Chao-ge, et al. Using FCKT and deep self-coding intelligent fault diagnosis of rolling bearings in neural network [J]. Journal of Mechanical Engineering, 2019, 55(7):65-72.
- [30] 牛锐祥,丁 华,施 瑞,等. 改进密集连接卷积网络的滚动轴承故障诊断方法 [J]. 振动与冲击, 2022, 41(11):252-258.
NIU Rui-xiang, DING Hua, SHI Run, et al. Fault diagnosis method of rolling bearings with improved dense connection convolutional network [J]. Journal of Vibration and Shock, 2022, 41(11):252-258.
- [31] 雷春丽,夏奔锋,薛林林,等. 基于 MTF-CNN 的滚动轴承故障诊断方法[J]. 振动与冲击, 2022, 41(9):151-158.
LEI Chun-li, XIA Ben-feng, XUE Lin-lin, et al. Fault diagnosis method of rolling bearing based on MTF-CNN [J]. Journal of Vibration and Shock, 2022, 41 (9): 151-158.
- [32] 张 珂,王竞禹,石怀涛,等. 基于 CNN 的变工况滚动轴承故障诊断研究[J]. 控制工程, 2022, 29(2):254-262.
ZHANG Ke, WANG Jing-yu, SHI Huai-tao, et al. Fault diagnosis of rolling bearings under variable working

- conditions based on CNN[J]. *Control Engineering*,2022,29(2):254-262.
- [33] 丁雪,邓艾东,李晶,等.基于多尺度和注意力机制的滚动轴承故障诊断[J].*东南大学学报*,2022,52(1):172-178.
DING Xue, DENG Ai-dong, LI Jing, et al. Fault diagnosis of rolling bearings based on multi-scale and attention mechanism[J]. *Journal of Southeast University*, 2022, 52(1):172-178.
- [34] 刘伟,单雪垠,李双喜,等.基于并行1DCNN的滚动轴承故障诊断研究[J].*机电工程*,2021,38(12):1572-1578.
LIU Wei, SAN Xue-yin, LI Shuang-xi, et al. Research on fault diagnosis of rolling bearings based on parallel 1DCNN [J]. *Journal of Mechanical and Electrical Engineering*, 2021, 38(12):1572-1578.
- [35] 赵小强,张亚洲.利用改进卷积神经网络的滚动轴承变工况故障诊断方法[J].*西安交通大学学报*,2021,55(12):108-118.
ZHAO Xiao-qiang, ZHANG Ya-zhou. Fault diagnosis method of rolling bearing variable working condition using improved convolutional neural network[J]. *Journal of Xi'an Jiaotong University*, 2021, 55(12):108-118.
- [36] 古天龙,孙镇海,宾辰忠,等.基于多尺度卷积神经网络的滚动轴承智能诊断算法[J].*机械设计与制造*,2021,375(5):20-23.
GU Tian-long, SUN Zhen-hai, BIN Chen-zhong, et al. Intelligent diagnosis algorithm of rolling bearings based on multi-scale convolutional neural network [J]. *Machinery Design and Manufacturing*, 2021, 375(5):20-23.
- [37] 蒙志强,董绍江,潘雪娇,等.基于改进卷积神经网络的滚动轴承故障诊断[J].*组合机床与自动化加工技术*,2020,62(2):79-83.
MENG Zhi-qiang, DONG Shao-jiang, PAN Xue-jiao, et al. Fault diagnosis of rolling bearings based on improved convolutional neural network[J]. *Combined Machine Tool and Automatic Processing Technology*, 2020, 62(2):79-83.
- [38] 金江涛,许子非,李春,等.卷积神经网络与混沌理论在滚动轴承故障诊断中的应用[J].*机械强度*,2022,44(2):287-293.
JIN Jiang-tao, XU Zi-fei, LI Chun, et al. Application of convolutional neural network and chaos theory in fault diagnosis of rolling bearings [J]. *Journal of Mechanical Strength*, 2022, 44(2):287-293.
- [39] LU Y, WANG Z, XIE R, et al. Bayesian optimized deep convolutional network for bearing diagnosis [J]. *The International Journal of Advanced Manufacturing Technology*, 2020, 108(2):313-322.
- [40] 汤亮,凡焱峰,徐适斐,等.基于贝叶斯优化与改进LeNet-5的滚动轴承故障诊断[J].*计量学报*,2022,43(7):913-919.
TANG Liang, FAN Yan-feng, XU Shi-fei, et al. Fault diagnosis of rolling bearings based on Bayesian optimization and improvement of LeNet-5 [J]. *Journal of Metrology*, 2022, 43(7):913-919.
- [41] 孙祺淳,李媛媛. DE 算法优化 CNN 的滚动轴承故障诊断研究[J].*噪声与振动工程*,2022,42(4):165-171.
SUN Qi-chun, LI Yuan-yuan. Research on rolling bearing fault diagnosis of CNN optimized by DE algorithm [J]. *Noise and Vibration Engineering*, 2022, 42(4):165-171.
- [42] XIAO M, LIAO Y, BARTOS P, et al. Fault diagnosis of rolling bearing based on back propagation neural network optimized by cuckoo search algorithm[J]. *Multimedia Tools and Applications*, 2021, 81(2):1567-1587.
- [43] GAO S, SHI S, ZHANG Y. Rolling bearing compound fault diagnosis based on parameter optimization MCKD and convolutional neural network [J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71(1):1-8.
- [44] DONG S, GUPTA P. An integrated method of rolling bearing fault diagnosis based on convolutional neural network optimized by sparrow optimization algorithm [J]. *Scientific Programming*, 2022, 2022(8):1-4.
- [45] ZHUO P C. GA-OIHF Elman neural network algorithm for full life cycle fault diagnosis of rolling bearings [J]. *Shanghai Jiao Tong University*, 2021, 55(10):71-78.
- [46] XU Q, ZHU B, HUO H, et al. Fault diagnosis of rolling bearing based on online transfer convolutional neural network[J]. *Applied Acoustics*, 2022, 192(4):108703.
- [47] AN F, WANG J. Rolling bearing fault diagnosis algorithm using overlapping group sparse-deep complex convolutional neural network [J]. *Nonlinear Dynamics*, 2022, 108(3):2353-2368.
- [48] 王亚辉,刘德平,王宇.基于GSA-VMD和自适应CNN的滚动轴承故障诊断[J].*组合机床与自动化加工技术*,2022,64(7):85-89.
WANG Ya-hui, LIU De-ping, WANG Yu. Fault diagnosis of rolling bearings based on GSA-VMD and adaptive CNN [J]. *Combined Machine Tool and Automated Machining*, 2022, 64(7):85-89.
- [49] HE D, LIU C, CHEN Y, et al. A rolling bearing fault diagnosis method using novel lightweight neural network [J]. *Measurement Science and Technology*, 2021, 32(12):125102.
- [50] LIU X, SUN W, LI H, et al. The method of rolling bearing fault diagnosis based on multi-domain supervised learning of convolution neural network[J]. *Energies*, 2022, 15(13):4616.

- [51] XUE F, ZHANG W, XUE F, et al. A novel intelligent fault diagnosis method of rolling bearing based on two-stream feature fusion convolutional neural network [J]. Measurement, 2021, 176(5):109226.
- [52] XU Y, CAI W, WANG L, et al. Intelligent diagnosis of rolling bearing fault based on improved convolutional neural network and LightGBM [J]. Shock and Vibration, 2021(24):1-8.
- [53] ZHAO X, ZHANG Y. An intelligent diagnosis method of rolling bearing based on multi-scale residual shrinkage convolutional neural network [J]. Measurement Science and Technology, 2022, 33(8):085103.
- [54] 刘洋,程强,史曜炜,等.基于注意力模块及1D-CNN的滚动轴承故障诊断[J].太阳能学报,2022,43(3):462-468.
LIU Yang, CHENG Qiang, SHI Yao-wei, et al. Fault diagnosis of rolling bearings based on attention module and 1D-CNN [J]. Journal of Solar Energy, 2022, 43(3):462-468.
- [55] 朱奇先,梁浩鹏,赵小强,等.基于残差神经网络的滚动轴承故障诊断方法[J].兰州理工大学学报,2022,48(3):86-93.
ZHU Qi-xian, LIANG Hao-peng, ZHAO Xiao-qiang, et al. Fault diagnosis method of rolling bearing based on residual neural network [J]. Journal of Lanzhou University of Technology, 2022, 48(3):86-93.
- [56] 王琦,邓林峰,赵荣珍.基于改进一维卷积神经网络的滚动轴承故障识别[J].振动与冲击,2022,41(3):216-223.
WANG Qi, DENG Lin-feng, ZHAO Rong-zhen. Fault identification of rolling bearings based on improved one-dimensional convolutional neural network [J]. Journal of Vibration and Shock, 2022, 41(3):216-223.
- [57] LIU Y, JIANG H, LIU C, et al. Data-augmented wavelet capsule generative adversarial network for rolling bearing fault diagnosis [J]. Knowledge-Based Systems, 2022, 252(27):109439.
- [58] 金江涛,许子非,李春,等.基于深度学习与混沌特征融合的滚动轴承故障诊断[J].控制理论与应用,2022,39(1):109-116.
JIN Jiang-tao, XU Zi-fei, LI Chun, et al. Rolling bearing fault diagnosis based on deep learning and chaotic feature fusion [J]. Control Theory and Applications, 2022, 39(1):109-116.
- [59] 管涛,王辉,刘智豪,等.基于多输入层卷积神经网络的滚动轴承故障诊断模型[J].振动与冲击,2020,39(12):142-149,163.
ZAN Tao, WANG Hui, LIU Zhi-hao, et al. Fault diagnosis model of rolling bearing based on multi-input layer convolutional neural network [J]. Journal of Vibration and Shock, 2020, 39(12):142-149,163.
- [60] XING Z, LIU Y, WANG Q, et al. Multi-sensor signals with parallel attention convolutional neural network for bearing fault diagnosis [J]. AIP. Advances, 2022, 12(7):075020.
- [61] 宫文峰,陈辉,张泽辉,等.基于改进卷积神经网络的滚动轴承智能故障诊断研究[J].振动工程学报,2020,33(2):400-413.
GONG Wen-feng, CHEN Hui, ZHANG Ze-hui, et al. Research on intelligent fault diagnosis of rolling bearings based on improved convolutional neural network [J]. Journal of Vibration Engineering, 2020, 33(2):400-413.
- [62] CHAO Z, HAN T. A novel convolutional neural network with multiscale cascade midpoint residual for fault diagnosis of rolling bearings [J]. Neurocomputing, 2022, 506(28):213-227.
- [63] WU Z, JIANG H, LIU S, et al. A deep reinforcement transfer convolutional neural network for rolling bearing fault diagnosis [J]. ISA. Transactions, 2022, 129(B):505-524.
- [64] 金江涛,许子非,李春,等.基于深度学习与支持向量机的滚动轴承故障诊断研究[J].热能动力工程,2022,37(6):176-184.
JIN Jiang-tao, XU Zi-fei, LI Chun, et al. Research on fault diagnosis of rolling bearings based on deep learning and support vector machine [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(6):176-184.
- [65] ZHOU Z, WANG H, LI Z, et al. Fault diagnosis of rolling bearing based on deep convolutional neural network and gated recurrent unit [J]. Journal of Advanced Mechanical Design, Systems, and Manufacturing, 2023, 17(2):JAMDSM0017.

本文引用格式:

赖荣森,闫高强.基于卷积神经网络的滚动轴承故障诊断研究综述[J].机电工程,2024,40(2):194-204.

LAI Rongshen, YAN Gaoqiang. Review of rolling bearing fault diagnosis based on convolutional neural network [J]. Journal of Mechanical & Electrical Engineering, 2024, 40(2):194-204.

《机电工程》杂志: <http://www.meem.com.cn>