

# 注意力机制结合 CNN 卷积网络的滚动轴承复合故障诊断

陈其

(商洛职业技术学院, 陕西 商洛 726099)

**摘要:**针对滚动轴承复合故障诊断精度低的问题,运用注意力机制对滚动轴承振动信号不同特征进行自动权重分配,以强化重要特征,弱化冗余特征;采用 CNN 卷积神经网络对滚动轴承故障进行诊断;在公开的滚动轴承数据集上对 ATT-CNN 模型进行验证。结果表明:ATT-CNN 模型可准确诊断 0 kW~3 kW 负载和单一工况、多工况下的滚动轴承故障,对单一工况滚动轴承故障诊断的平均准确率可达 97.23%,对两种或三种多工况滚动轴承故障诊断的平均准确率可分别达 96.48%和 83.40%。

**关键词:**滚动轴承;故障诊断;复合故障;注意力机制

**中图分类号:**TP399 **文献标志码:**A **文章编号:**1671-5276(2023)05-0134-05

## Composite Fault Diagnosis of Rolling Bearing Based on Attention Mechanism and CNN Convolution Network

CHEN Qi

(Shangluo Vocational and Technical College, Shangluo 726099, China)

**Abstract:** In view of the low accuracy of composite fault diagnosis of rolling bearing faults, attention mechanism is applied to perform automatic weight allocation on different characteristics of rolling bearing vibration signals for important feature enhancement and redundant feature weakening. CNN convolution network is adopted to diagnose rolling bearing faults. Based on the rolling bearing data set published, ATT-CNN model is tested and verified. The results show that the model can accurately diagnose the single working condition and multi working condition rolling bearing faults under 0 kW-3 kW load, among which average accuracy of single working condition rolling bearing fault diagnosis can reach 97.23%, while the average accuracy of two or three multi working condition rolling bearing fault diagnosis is 96.48% and 83.40% respectively.

**Keywords:** rolling bearing; fault diagnosis; compound fault; attention mechanism

## 0 引言

滚动轴承作为各类机械的重要零部件,广泛应用于各个行业。然而由于滚动轴承较易损坏,且故障具有多发性、复杂性的特点,因此故障诊断一直是困扰相关研究人员和技术人员的难题。近年来,随着人工智能技术和深度学习的发展与其在故障诊断领域的发展,滚动轴承的故障诊断进入一个全新的智能化阶段。徐其春等基于人工智能技术,采用大数据分析方法和 CNN 网络,实现了变压器绕组形变故障诊断<sup>[1]</sup>;白雲杰等通过对柴油发动机多传感器振动信号分别进行特征提取,并利用深度卷积神经网络(DCNN)进行机械故障诊断,可解决复杂机械系统故障诊断的多传感器信息融合问题,具有更高的故障分类与辨识能力<sup>[2]</sup>;肖娜等基于卷积自编码神经网络,实现了航空发动机轴承故障诊断准确率的提升<sup>[3]</sup>;张西宁等在 CNN 网络的基础上,叠加反卷积重构信号,然后提出一种深度卷积自编码网络,提高了滚动轴承故障的识别准确率<sup>[4]</sup>。上述研究成果表明,CNN 网络在机械故障诊断方面,具有一定的有效性和优势。但在故障特征提取时存在特征数

量冗余的问题。因此,通过引入注意力机制(attention mechanism)改进 CNN 网络特征提取层,进而期望提高对滚动轴承故障诊断的准确率模型。

## 1 CNN 卷积神经网络改进

CNN 网络是深度学习的一种典型算法,由输入层、卷积层、池化层、全连接层、softmax 分类层组成<sup>[5]</sup>。其中,输入层主要负责对输入数据进行预处理;卷积层负责学习与提取输入数据样本特征、过滤无效数据样本特征;池化层包括平均池化和最大池化两种操作,负责减少数据量;全连接层即为 CNN 网络的输出层,最后一层全连接层通常为 softmax 分类层,起到分类器的作用。CNN 网络具有时域不变性和参数共享的特点,可通过减少非必要参数达到更好学习效果,且提取的特征信息在不同网络层传递具有平移的特征,因此常用于图像分类识别与故障诊断。但传统 CNN 网络在特征提取时,不同特征的重要程度默认为一致。但是在实际应用中,不同特征的重要程度不同。因此,引入注意力机制分配不同特征权重,实现对 CNN 网络

**基金项目:**商洛职业技术学院 2019 年度重大课题项目(JXKT2019006)

**作者简介:**陈其(1990—),男,陕西商洛人,讲师,硕士,研究方向为机电一体化,chengqi9965@126.com。

进行改进。具体改进步骤如下。

1) 对通过 CNN 网络卷积层的每个特征聚合为特征向量, 确保特征输出维度与输入特征映射数量相同。具体特征向量聚合如式(1)所示。

$$c_j = \frac{1}{N_j} \sum_i Z_j^i \quad (1)$$

式中:  $c_j$  表示特征  $j$  映射聚合的特征向量;  $Z_j^i$  表示特征  $j$  的第  $i$  个特征向量;  $N_j$  表示特征映射长度。

2) 利用 CNN 网络中的两层全连接层对每个特征通道生成权重<sup>[6-7]</sup>。

$$\hat{c}_j = \sigma(K_1 c_j) \quad (2)$$

$$a_j = \delta(K_2 \hat{c}_j) \quad (3)$$

式中:  $\sigma, \delta$  表示 relu 和 sigmoid 激活函数;  $K_1, K_2$  为全连接层权重向量;  $\hat{c}_j$  为第一个全连接输出;  $a_j$  为权重向量集合。

3) 将  $a_j$  分别与该卷积层的特征映射进行匹配相乘, 得到引入注意力机制后的 CNN 网络学习的新特征  $N'_j$ :

$$N'_j = a_j \times N_j \quad (4)$$

通过上述操作, 即可实现利用 CNN 网络学习训练自动分配不同特征权重, 进而区分不同特征对故障诊断贡献的重要程度, 强化重要特征, 弱化冗余特征<sup>[8]</sup>。最后, 将注意力机制分配的特征权重与 CNN 卷积层进行融合, 形成特征提取层, 依次通过池化层、全连接层和 softmax, 即可实现改进 CNN 的网络模型构建, 其基本结构如图 1 所示。

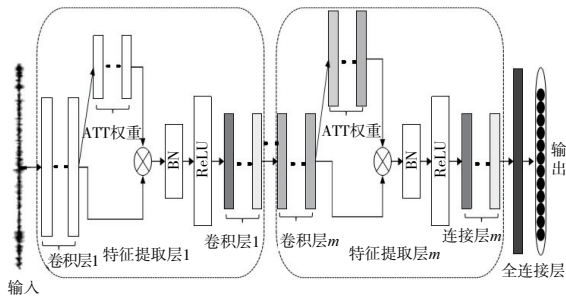


图1 基于注意力机制的 CNN 网络结构

## 2 基于改进 CNN 网络结构的滚动轴承故障诊断

基于上述改进, 将 ATT-CNN 的滚动轴承故障诊断流程分为滚动轴承故障振动信号数据获取、数据预处理、模型训练、模型测试、故障识别, 具体如图 2 所示。

1) 振动信号数据获取。滚动轴承振动信号数据反映了滚动轴承状态, 因此滚动轴承故障振动信号数据获取是实现滚动轴承故障诊断的前提。

2) 数据预处理。考虑到故障诊断模型训练需要的数据样本量通常较大, 而收集的滚动轴承振动信号数据样本量通常不能满足该要求, 因此需要对收集的数据样本进行扩充预处理<sup>[9]</sup>。

3) 模型训练。初始化改进 CNN 模型的迭代次数、卷

积核大小、全连接层权值、注意力机制权值等网络参数, 并利用注意力机制调整特征权重, 然后利用部分预处理后的数据进行训练, 根据损失函数计算的误差反向传播, 调整网络权值及偏置, 获取最佳改进 CNN 故障诊断模型。

4) 模型测试。将剩余的预处理数据输入训练得到的改进 CNN 故障诊断模型进行识别, 输出其故障类型并与其实际故障类别进行比较, 计算模型故障诊断准确率。

5) 故障诊断。将待测滚动轴承故障振动信号数据样本输入模型, 输出故障类型即实现了滚动轴承的故障诊断。

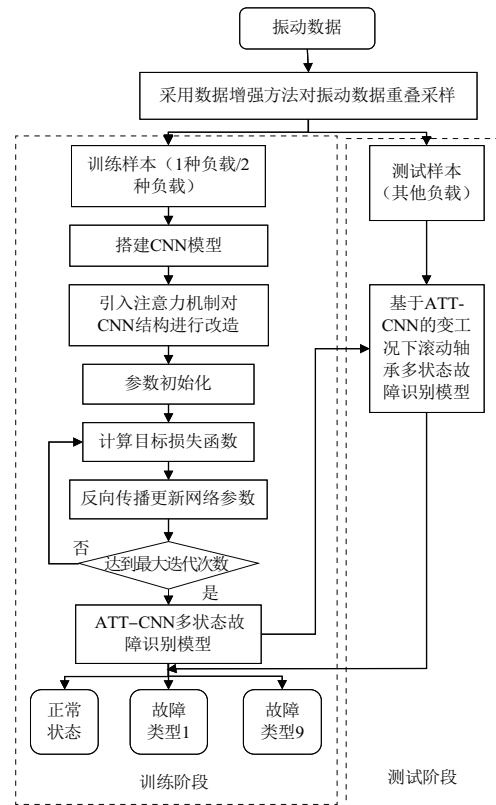


图2 基于改进 CNN 的滚动轴承故障诊断流程

## 3 仿真实验

### 3.1 实验环境搭建

本次实验结合 tensorflow 和 keras 深度学习框架搭建仿真模型, 并在 64 位 Windows7 操作系统上运行。系统配置 Intel Core i7 CPU, GEFORCE GTX 1070M GPU, 8 G 内存<sup>[10]</sup>。

### 3.2 数据来源及预处理

本次实验数据集来自西储大学公开的滚动轴承数据集。该数据集由采样频率为 48 kHz, 在 0kW ~ 3kW 这 4 种负载条件下, 采集的正常、内环故障、外环故障、滚动体故障 4 种轴承状态<sup>[11]</sup>。图 3 为 0 负载条件下滚动轴承状态时域振动信号波形图。图 3 中, N 表示正常, B 表示滚动体故障, IR、OR 分别表示内环和外环故障。由图 3 可知, 正常状态下, 滚动轴承的时域振动信号较为平稳, 当发生故障后, 不同故障的时域振动信号均出现波动甚至局部突变, 但由于故障位置和故障程度不同, 时域振动信号波动区域也不同。




图3 滚动轴承状态时域振动信号波形示例

考虑到该数据集样本数量有限,为获取更多的训练数据,提高模型对滚动轴承故障诊断效果,本文采用数据重叠分割法对实验数据集进行了数据增强处理<sup>[12]</sup>。将存在重叠的样本以固定步长分割成两个相邻样本,可获得新样本数量  $N$  为

$$N = \frac{L_1 \cdot L_2}{D} + 1 \quad (5)$$

式中: $L_1$  和  $L_2$  分别表示样本总长度和单个样本长度; $D$  为步长。

通过上述数据增强处理,最终本次实验共获取每种故障状态数据样本 2 000 个,每种负载数据样本 20 000 个,共 80 000 个数据样本。为减少随机性对模型性能的影响,本文选用 10 次实验平均值作为最终结果。

### 3.3 评价指标

本次实验选用准确率 (acc) 和误差损失值作为评估模型性能的指标。其中,准确率的计算方法如式 (6) 所示。准确率越高,误差损失值越趋近于 0,模型性能越好<sup>[13]</sup>。

$$a_{cc} = (T_p + T_N) / (P + N) \quad (6)$$

式中: $T_p$  表示真正例; $T_N$  表示真负例; $P$  表示所有正例; $N$  表示所有负例。

### 3.4 参数设置

模型超参数设置对模型性能具有较大的影响,为使模型达到最佳诊断效果,本文根据滚动轴承振动信号具有周期性的特点以及 ATT-CNN 模型学习提取特征对信号位移具有不变性的特点,确定模型最后一层池化层神经元输入信号感受野  $RF^{(0)}$  应大于振动信号的一个周期  $T^{[14]}$ 。

基于以上规则,将 ATT-CNN 故障诊断模型每一层网络参数设置为表 1。

表 1 模型参数设置

序号	名称	核尺寸	数量	输出尺寸	激活函数
1	输入层	2 048×1	—	—	—
2	卷积层 1	129×1	8	1 920×8	ReLU
3	池化层 1	4×1	8	480×8	—
4	卷积层 2	33×1	16	448×16	ReLU
5	池化层 2	4×1	16	112×16	—
6	卷积层 3	9×1	32	104×32	ReLU
7	池化层 3	4×1	32	26×32	—
8	卷积层 4	3×1	64	24×64	ReLU
9	池化层 4	4×1	64	6×64	—
10	全连接层	128	1	128×1	ReLU
11	输出层	—	—	10×1	Softmax

### 3.5 结果与分析

#### 1) 单一工况故障诊断结果

为验证 ATT-CNN 模型的有效性,以 0.75 kW ~ 2.25 kW 负载其中一种负载数据作为训练集,另一种负载数据作为测试集,并与标准 CNN 故障诊断模型的诊断结果进行对比,结果如图 4 所示。由图 4 可知,当以 0.75 kW 负载数据集为训练集,1.5 kW 负载数据为测试集时,ATT-CNN 故障诊断模型的故障诊断准确率最高可达 99.82%;当以 2.25 kW 负载数据作为训练集,0.75 kW 负载数据作为测试集时,ATT-CNN 故障诊断模型的故障准确率最低可达到 89.81%。传统 CNN 模型的平均故障诊断准确率为 94.41%,本文所提的 ATT-CNN 模型的平均故障诊断准确率为 97.23%。由此说明,所提的 ATT-CNN 故障诊断模型具有较高的滚动轴承故障诊断准确率,相较于对比模型滚动轴承的故障诊断准确率均有不同程度地提升,即改进有效,具有一定优越性。




图 4 不同模型故障诊断准确率对比 (一)

为了更直观地反映 ATT-CNN 模型的训练与测试过程,实验以 0.75 kW 负载数据为训练集和 1.5 kW 负载数据为测试集的训练与测试过程为例,将其训练过程与测试结果与标准 CNN 的训练过程和测试结果进行对比分析。图

5 为 ATT-CNN 模型训练与测试的故障诊断准确率和误差损失值,图 6 为标准 CNN 模型训练与测试的故障诊断准确率和误差损失值。由图 5(a)可知,随着模型训练的进行,训练准确率均逐渐提升并稳定在 100%,测试集准确率在训练前期处于振荡状态,当迭代到 120 次后,准确率基本维持稳定;当模型迭代到 150 次时,模型训练结束。由图 5(b)可知,模型训练损失值随着训练进行逐渐趋于 0,测试损失值先振荡后趋于 0.5;当模型迭代到 150 次后,模型训练结束。综合来看,模型准确率与误差损失值呈反比关系,当模型准确率高时,误差损失值较低;模型准确率出现振荡时,误差损失值相应振荡。由此说明,模型训练中参数变化与数据拟合状态一致。




图 5 ATT-CNN 模型训练过程示意图

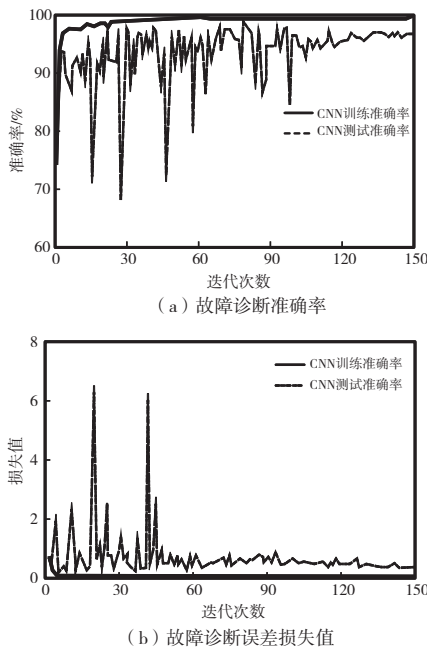


图 6 CNN 模型训练过程示意图

由图 6 可知,标准 CNN 网络模型故障诊断准确率稳定在 97%,略低于 ATT-CNN 模型故障诊断准确率,且故

障损失值稳定在 1.5 附近,高于 ATT-CNN 模型。

对比图 5 和图 6 可知,引入注意力机制可提高 CNN 模型的故障诊断准确率,减小诊断误差,其原因是注意力机制对不同特征进行了权重分配,改善了特征的分布表示。

2) 多工况故障诊断结果

为了验证模型对多工况滚动轴承故障诊断的泛化能力,实验以两种负载数据为训练集,其余两种负载数据为测试集,采用所提 ATT-CNN 模型与标准 CNN 模型进行故障诊断,结果如图 7 所示。由图 7 可知,ATT-CNN 模型对多工况滚动轴承的故障诊断平均准确率为 96.48%,相较于改进前标准 CNN 模型的平均故障诊断准确率提高了 3.29%,说明 ATT-CNN 模型对 CNN 网络的改进有效,优于一般故障诊断模型,可良好地适应数据分布变化,并对复杂的多工况滚动轴承故障进行诊断,具有较强的适应性。






图 7 不同模型故障诊断准确率对比(二)

图 8 和图 9 是以 0 kW+0.75 kW 负载数据为训练集,1.5 kW+2.25 kW 负载数据为测试集时,ATT-CNN 模型与标准 CNN 模型的故障诊断准确率与损失值对比。由图 8 可知,ATT-CNN 模型与标准 CNN 模型的训练故障诊断准确率均在迭代到 5 次时达到 100%,而 ATT-CNN 模型的测试准确率整体高于标准 CNN。由图 9 可知,ATT-CNN 模型与标准 CNN 模型测试集上的故障诊断误差损失值均在迭代到 5 次时开始收敛,逐渐趋于 0;ATT-CNN 模型的测试损失值最终稳定在 0.5,标准 CNN 测试损失值稳定在 1.5,远高于 ATT-CNN 模型的测试损失值。综合图 8 和图 9 可知,ATT-CNN 模型对 CNN 的改进有效,可更好拟合数据,更准确地识别不同工况下的滚动轴承故障。分析其原因是,ATT-CNN 模型通过引入注意力机制,改善了标准 CNN 中特征的权重,减小了测试误差。




(a) ATT-CNN 故障诊断准确率






(b) CNN故障诊断准确率

图8 故障诊断准确率对比



(a) ATT-CNN故障诊断损失值



(b) CNN故障诊断损失值

图9 故障诊断损失值对比

为了进一步验证模型对多工况滚动轴承故障诊断的泛化能力,实验以1种负载数据为训练集,其余3种负载数据为测试集,采用ATT-CNN模型与标准CNN模型进行故障诊断,结果如图10所示。由图10可知,ATT-CNN模型的平均故障诊断准确率为83.40%,相较于标准CNN模型提高了5.42%,但相较于单一工况及两种工况下,故障诊断的准确率较低。分析其原因是,3种复杂工况下对模型的泛化性能要求较高,而训练集较为单一,多样性较差,导致模型拟合能力有限。整体来看,ATT-CNN模型相较于对比模型对多工况复杂滚动轴承故障诊断具有一定优越性,但诊断准确率仍待提高。

## 4 结语

综上所述,所提的基于改进CNN网络结构的滚动轴承故障诊断模型,通过在标准CNN网络结构的基础上引入注意力机制对不同特征自动分配权重,可提高CNN网络对滚动轴承故障诊断的准确率。单一工况滚动轴承故障下,ATT-CNN模型相较于标准CNN网络模型,平均故障诊断准确率提高了2.82%,达到97.23%;两种工况滚动轴承故障下,ATT-CNN模型相较于标准CNN网络模型,平均诊断准确率提高了3.29%,达到96.48%;3种工况滚动轴承故障下,ATT-CNN模型相较于标准CNN网络模型的平均诊断准确率提高5.42%,达到83.40%,具有一定的有效性和优越性。




图10 不同模型故障诊断准确率对比(三)

## 参考文献:

- [1] 徐其春,肖志国,陈昕. 基于大数据采集模块的变压器绕组组形变故障诊断方法[J]. 变压器,2021,58(12):25-29.
- [2] 白云杰,贾希胜,梁庆海,等. 基于1DCNN与双通道信息融合的柴油发动机故障诊断[J]. 车用发动机,2021(6):76-81.
- [3] 肖娜,周孟申. 基于卷积自编码神经网络的航空发动机轴承故障诊断方法研究[J]. 计算机测量与控制,2021,29(12):84-88,119.
- [4] 张西宁,向宙,唐春华. 一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用[J]. 西安交通大学学报,2018,52(7):1-8,59.
- [5] 宋丹,汪浩. 基于IBOA-PNN的道岔控制电路故障诊断方法[J]. 铁路通信信号工程技术,2021,18(12):1-6.
- [6] 黄伟,陈瑶,华月存,等. 煤矿安全监控系统层级故障自诊断技术[J]. 煤矿安全,2021,52(12):133-137.
- [7] 李珍辉,鲁静文,陈镜伊,等. 基于InceptionV3卷积神经网络森林火灾检测方法[J]. 湖南工程学院学报(自然科学版),2021,31(4):44-49.
- [8] 贾澎涛,张智远,梁荣,等. 基于PSO-CNN-aBiGRU的瓦斯浓度预测方法[J]. 矿业研究与开发,2021,41(12):76-81.
- [9] 邱衍江,张超,张新燕,等. 基于双窗apDFT的高精度电容器介损角辨识算法[J]. 电力电容器与无功补偿,2021,42(6):81-87.
- [10] 甄荣,邵哲平,潘家财. 基于AIS数据的船舶行为特征挖掘与预测:研究进展与展望[J]. 地球信息科学学报,2021,23(12):2111-2127.
- [11] 付学佳. 基于深度学习的多特征彩色图像边缘特征提取[J]. 自动化技术与应用,2021,40(12):89-93.
- [12] 梁敏健,彭晓军,刘德阳. 基于LSTM算法的门座式起重机减速箱故障诊断研究[J]. 计算机测量与控制,2021,29(12):67-72.
- [13] 李军宁,罗文广,陈武阁. 面向振动信号的滚动轴承故障诊断算法综述[J]. 西安工业大学学报,2022,42(2):105-122.
- [14] 刁英,王亚慧. 煤炭运输设备故障自动识别系统研究[J]. 能源与环保,2022,44(4):228-233.

收稿日期:2022-04-06