

基于改进ConvNeXt的轴承故障诊断研究

张亦辰, 倪静

上海理工大学管理学院, 上海

收稿日期: 2024年4月20日; 录用日期: 2024年5月20日; 发布日期: 2024年5月27日

摘要

根据现有的网络模型(ConvNeXt)在处理小样本任务过程中, 无法完全提供故障信息、所需样本数据量过大、泛化性能不足和鲁棒性能较低的特点, 提出一种改进型ConvNeXt网络模型的轴承故障诊断方法。首先使用格拉姆角差场图像编码技术将故障样本进行解码得到相应的故障特征图; 然后通过随机裁剪、旋转等方法, 对数据增强模块进行改进; 其次利用非对称卷积思想对ConvNeXt模型的大卷积核进行重构, 增强模型对小样本任务的处理能力; 最后融入CBAM注意力机制, 提高模型对信号特征的通道和空间方面的提取能力。实验表明, 改进型ConvNeXt网络模型对滚动轴承不同故障直径的识别准确率达到98.3%, 相比较GADF + VggNet, GADF + ResNet, GADF + ConvNeXt等网络模型, 分别提高了16.7%, 1.4%和4.05%。结果表明, 所改进模型提升了原始模型在处理小样本条件下故障诊断效果, 并且在不同故障直径滚动轴承条件下, 故障诊断的准确率优于其他模型, 且具有较强的泛化性和鲁棒性。

关键词

故障诊断, 注意力机制, ConvNeXt模型, 非对称卷积块, 格拉姆角差场

Research on Bearing Fault Diagnosis Based on Improved ConvNeXt

Yichen Zhang, Jing Ni

Business School, University of Shanghai for Science and Technology, Shanghai

Received: Apr. 20th, 2024; accepted: May 20th, 2024; published: May 27th, 2024

Abstract

Based on the characteristics of existing network models (ConvNeXt) that cannot fully provide fault information, require a large amount of sample data, have insufficient generalization performance, and low robustness in processing small sample tasks, an improved ConvNeXt network model for

bearing fault diagnosis is proposed. Firstly, the Gram angle difference field image encoding technique is used to decode the fault samples and obtain the corresponding fault feature maps; Then, by using methods such as random cropping and rotation, the data augmentation module is improved; Secondly, the ConvNeXt model is reconstructed using asymmetric convolution to enhance its ability to handle small sample tasks; Finally, incorporating the CBAM attention mechanism enhances the model's ability to extract signal features in both channel and spatial aspects. The experiment showed that the improved ConvNeXt network model achieved a recognition accuracy of 98.3% for different fault diameters of rolling bearings. Compared with other network models such as GADF + VggNet, GADF + ResNet, and GADF + ConvNeXt, it improved by 16.7%, 1.4%, and 4.05%, respectively. The results showed that the improved model improved the fault diagnosis performance of the original model under small sample conditions, and the accuracy of fault diagnosis was better than other models under different fault diameter rolling bearing conditions, with strong generalization and robustness.

Keywords

Fault Diagnosis, Attention Mechanism, ConvNeXt Model, Asymmetric Convolution Block, Gram Angle Difference Field

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着工业发展的日益复杂和自动化程度的提高,由于各种原因导致机械设备故障的情况也越来越普遍。故障诊断作为解决上述问题的重要途径,已经成为了工业自动化领域中的一个核心问题[1]。

传统的故障检测技术主要依赖于从振动信号的时间和空间特性来探究问题的原因,这些技术涵盖了短期傅里叶变换[2]、小波变换[3]、变分模式分解[4]等常见的故障检测手段。尽管如此,这些手段依旧依赖于先抽取问题的特性,然后根据自身的经验来对问题进行归类,因此总的来说,它们的效能并不够优秀。

伴随着计算能力的显著增强以及计算机视觉行业的飞速进步,诸如深度学习这样的人工智能科技已经实现了巨大的进步。在故障诊断领域,越来越多的方法实现了端到端的故障诊断,通过对振动信号的处理,将处理后的信号传入模型中进行诊断。谢星怡等[5]基于信号特征提取获取有效故障特征值,并使用卷积神经网络对提取特征值完成故障分类。程亮等[6]通过对一维卷积神经网络的改进,与注意力机制相结合提高了故障诊断的识别精度。陆浩博[7]使用二维卷积神经,通过图像识别技术应用于时间序列分类,完成逆变器故障诊断研究。李超[8]基于时频图的 2DCNN 模型并引入改进 EMD 算法,解决了传统模型精度较低、收敛过程波动较大等一系列问题,最终提高了故障诊断准确率。宋乾坤等[9]针对滚动轴承传统故障诊断方法训练收敛速度慢、识别准确率不高、抗噪性能差等问题,提出 CWT-CNN 的轴承故障诊断模型,解决了原始模型抗噪能力差的问题。陈向民等[10]为解决旋转机械设备在多工况、小样本状态下故障诊断精度不高的问题,将 VMD 信号分解方法与多尺度一维卷积神经网络相结合。所构造的网络模型能够更好的提取深层次的特征,从而提高模型在多工况及小样本状态下的诊断准确率。

以上研究方法虽然在一定场景下诊断效果比较好,但仍存在以下不足:1) 编码图像技术不能充分表示隐藏特征信息;2) 网络模型训练样本需求量大且鲁棒性差;3) 针对与不同工况条件下的故障诊断泛化

能力和鲁棒性差, 训练准确率不高。

ConvNeXt 模型[11]是一种基于 ResNet 模型, 仿照 Swin Transformer [12]的结构进行改进而得到的纯卷积模型, 并结合基础模型的优势[13], 大大提高了模型在故障特征提取方面的能力。杨文哲等[14]使用一维 ConvNeXt 网络对齿轮箱进行了故障诊断, 网络模型参数量得到了降低且拥有了较高的识别精度。查世康等[15]基于 ConvNeXt 模型和注意力机制, 使用跨阶段局部连接结构以及卷积注意力机制, 对架空线路绝缘子的自爆故障进行了有效识别与检测。但该模型存在以下缺点: 1) 为了模型训练速度的提高, 使用大卷积核进行特征提取[16], 但在滚动轴承故障诊断的小样本分类任务中, 大卷积核的特征提取性能不佳; 2) 在实际工况的轴承故障诊断的任务中, 模型中的数据增强模块会影响该网络的鲁棒性和泛化性能。

针对滚动轴承实际故障诊断任务中, 现有 ConvNeXt 网络模型存在的一些缺点, 本文提出一种改进型 ConvNeXt 网络模型。通过融入注意力机制、编码技术、改进深度卷积层结构以及数据增强模块, 提高模型在轴承故障诊断任务中特征提取能力。最后, 利用 CWRU 滚动轴承数据集进行试验, 在不同故障直径条件下, 所改进模型在特征提取能力上有所提高, 并且模型的鲁棒性和泛化能力得到改善。

2. 基本原理

2.1. 格拉姆角差场

格拉姆角差场(Gramian Angular Difference Field, GADF)编码图像(如图 1(b)所示)是一种用于时间序列数据分析的方法, 它可以在故障诊断方向上发挥重要作用, 通常应用于机械故障诊断、信号处理和模式识别等领域。格拉姆角差场的核心思想是通过将时间序列数据转换为格拉姆矩阵, 然后计算其角差场, 可以获得一种图像表示[17]。GADF 提取的图像特征可以捕捉到时间序列数据中的频谱信息和模式(如图 1(a)所示), 有助于揭示潜在的故障特征。




Figure 1. Time domain signal waveform and GADF encoded image

图 1. 时域信号波形图及 GADF 编码图像

2.2. ConvNeXt 模型

ConvNeXt 是一种基于 ResNet 模型, 仿照 Swin Transformer 的结构进行改进而得到的纯卷积模型,

基本结构采用了多分支结构, 其中每个分支是由一组卷积层组成。这些分支具有相同的结构, 但其卷积核的大小在水平和垂直方向上是不同的, 这种非对称卷积核的设计允许模型捕捉不同方向上的特征[18]。此外, ConvNeXt 模型还采用了并行卷积操作, 通过特征融合的方式, 将各个分支的特征进行融合, 以得到最终的输出特征图。所以 ConvNeXt 模型不仅减少了参数数量, 还提高了分类性能。因此, 其在机械故障状态的分类应用中, 发挥着重要的作用。

3. 改进型 ConvNeXt 模型

3.1. 改进数据增强模块

为了解决 ConvNeXt 网络模型在训练过程中存在的一些问题, 例如模型鲁棒性能差、泛化能力不足。对原始模型中的数据增强模块进行改进。通过对滚动轴承 GADF 编码图像采用随机裁剪、随机水平翻转、旋转及高斯模糊等方式, 从而生成多样化的数据样本并提高模型在小样本训练下的鲁棒性和泛化能力, 如图 2 所示。

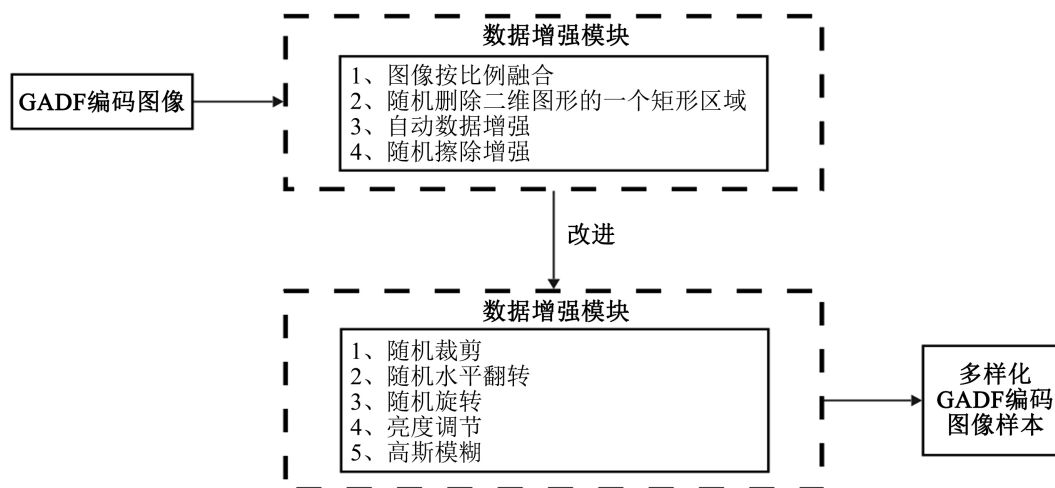


Figure 2. Improvement of data augmentation module
图 2. 数据增强模块改进

3.2. 非对称卷积网络模块

3.2.1. 非对称卷积神经网络模型(ACNet)

目前现有网络模型的计算量较多以及特征提取能力不强, 针对这些原因, Ding 等[19]在其论文中提出了一种名为 ACNet 的非对称卷积神经网络模型。该网络模型对传统卷积神经网络的卷积核进行重构分解, 得到三个不同形状的卷积核叠加, 具体为 1×3 卷积核、 3×1 卷积核和 3×3 卷积核。

较小的卷积核能够更好地捕捉局部特征, 而较大的卷积核则有助于提取更全局的特征。这种组合可以增强网络对样本中的细节和整体信息的感知能力, 从而提高分类准确性。大量实验证实了 ACNet 网络模型中非对称卷积结构的有效性, 证明其在特征提取方面具有显著的优势[19]。

3.2.2. ConvNeXt 深度卷积层结构改进

ConvNeXt 网络基础模型在进行特征提取时采用大卷积核, 以此来提高模型训练速度, 减少数据的计算量[20]。在实际滚动轴承故障诊断中却面临的是小样本图像数据任务, 会导致模型的深度卷积层 (Depthwise Conv2D) 的特征提取性能不佳。为了解决这一问题, 本文结合 ACNet 网络模型的思想, 对

ConvNeXt 网络模型深度卷积层进行了以下改进:

首先, 基于卷积可加性原理, 将原 ConvNeXt 模型深度卷积层里的 7×7 大卷积核进行分解重构, 得到如图 3 所示的非对称卷积结构, 这种非对称卷积结构保留了原本模型的优势, 但在计算量和参数量上得到了优化。




Figure 3. Asymmetric convolutional structure
图 3. 非对称卷积结构

原 ConvNeXt 网络模型里的 ConvNeXt Block 如图 4 所示, 由于采用非对称卷积结构, 虽然可以增加深度卷积层的深度, 但同时也会引发梯度弥散问题, 从而导致模型的特征提取性能下降[21]。为了解决这个问题, 本文采用了以下方法。

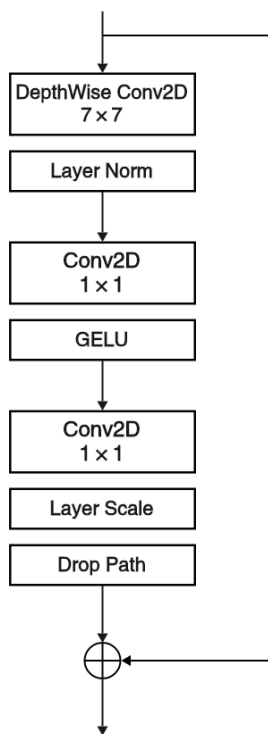


Figure 4. ConvNeXt Block structure diagram
图 4. ConvNeXt Block 结构图

首先, 对于归一化层(Layer Normalization, LN)和激活函数 GELU 的替换, 可以选择使用批量标准化层(Batch Normalization, BN)和 ReLU 函数; 其次, 可以在每个 3×3 、 1×3 、 3×1 和 1×1 的小卷积核之后添加 BN 层和 ReLU 激活函数。通过引入 BN 层, 可以加快神经网络的训练和收敛速度, 提升网络的特征提取效率。同时, 激活函数 ReLU 的应用有助于增强网络的非线性表示能力, 有效防止模型出现梯度弥散问题[22]。通过以上方法的改进, 得到如图 5 所示的 ACNext Block。

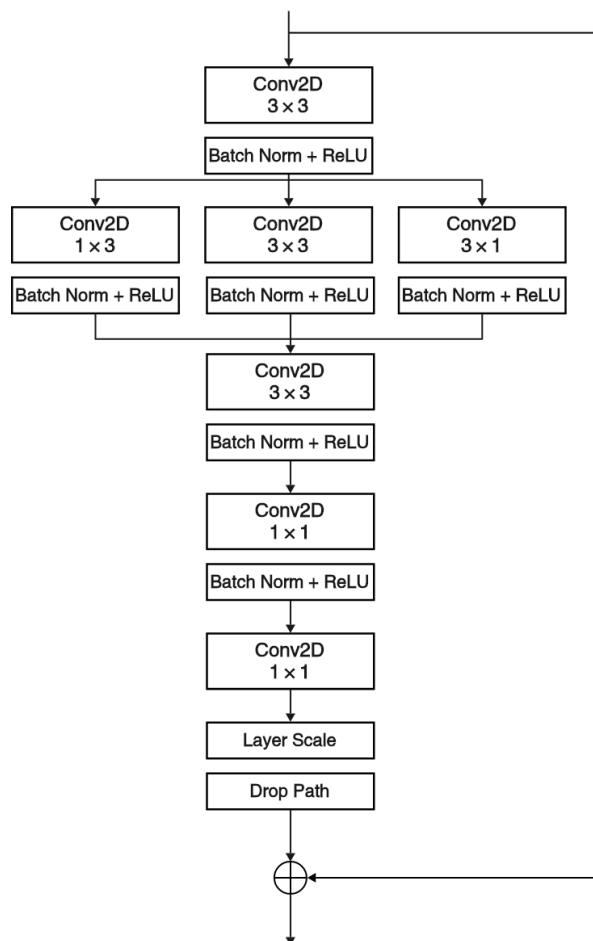


Figure 5. ACNext Block structure diagram

图 5. ACNext Block 结构图

3.3. CBAM 注意力机制

注意力机制(attention mechanism)是一种通过参数更新来确定重要特征的方法, 以高效准确地完成任务[23]。在各个领域中, 注意力机制被广泛应用, 其中常见的注意力机制包括 SK-Net [24] (Selective Kernel Networks)、ECA-Net [25] (Efficient Channel Attention)、SE-Net [26] (Squeeze and Excitation)和 CBAM [27] (Convolutional Block Attention Module)等。

在故障诊断任务中, 注意力机制可以应用于神经网络的不同层级, 提高网络模型对故障特征提取的能力。通过对常见的注意力机制进行实验对比, 实验结果表明 CBAM 注意力机制能更好地与 ConvNeXt 网络相融合, 提升网络模型的准确率, 故最终选用 CBAM 注意力机制作为本模型的注意力模块(Attention Block) [28], CBAM 的核心目标是利用通道注意力模块(CAM, Channel Attention Module)和空间注意力模

块(SAM, Spatial Attention Module)来提升模型的感知能力, 同时不增加网络的复杂性, 从而提高性能。CBAM 整体结构如图 6 所示。

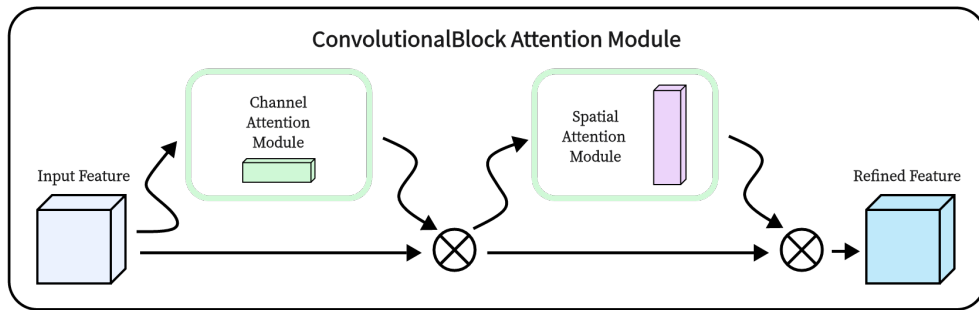


Figure 6. Overall structure of CBAM
图 6. CBAM 整体结构

3.4. 改进型 ConvNeXt 网络模型设计

3.4.1. 改进型 ConvNeXt 模型整体结构

所改进型 ConvNeXt 模型结构如图 7 所示, 整体结构主要由改进数据增强模块(Data augmentation module)、非对称卷积网络模块(ACNext Block)、CBAM 注意力模块(Attention Block)以及下采样模块(Downsample)4 部分构成。

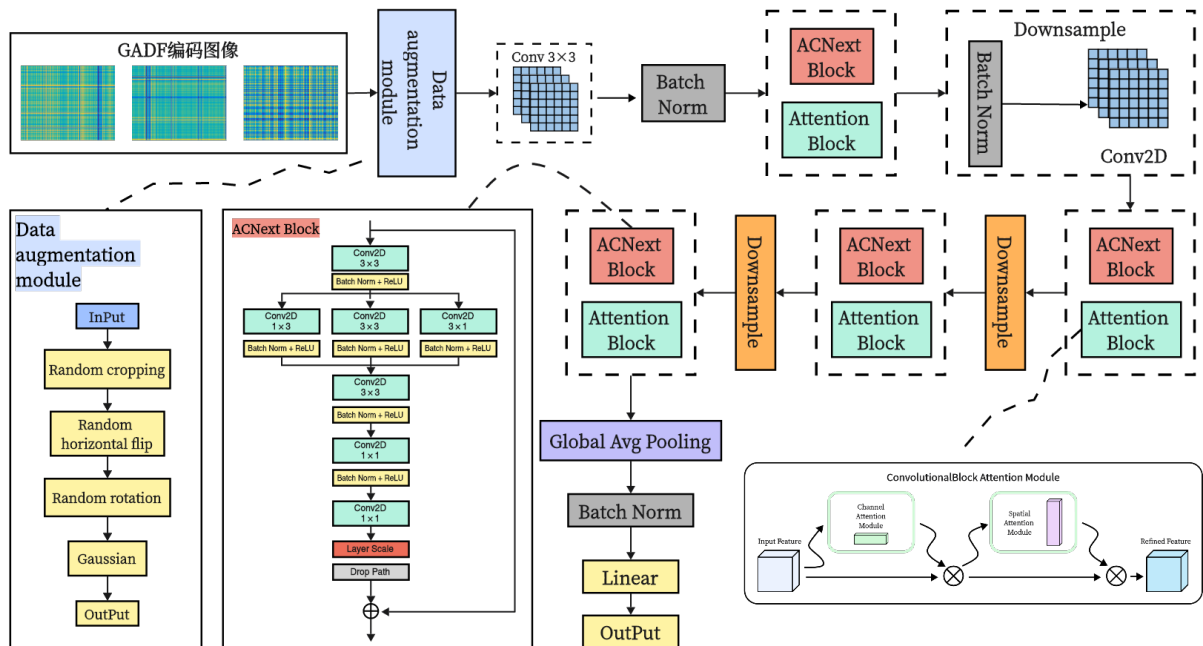


Figure 7. The overall structure of the improved ConvNeXt model
图 7. 改进型 ConvNeXt 模型整体结构

3.4.2. 改进型 ConvNeXt 模型故障诊断流程

本文所提方法结合 GADF 图像编码技术和改进型 ConvNeXt 模型的强大特征提取优势, 从而高效地完成故障诊断任务。改进型 ConvNeXt 模型故障诊断方法流程如图 8 所示。

首先, 根据故障模拟实验台的电机转速和采样频率, 将采集到的时域信号截取构造样本。然后, 通过 GADF 编码技术将构造的样本转换为二维特征图像, 并按照 6:2:2 的比例划分训练集、验证集和测试集; 为了验证改进型 ConvNeXt 模型的性能, 将训练集输入到模型中进行训练, 通过验证集对模型进行调整, 最后将测试集输入训练好的模型中输出最终的分类结果。

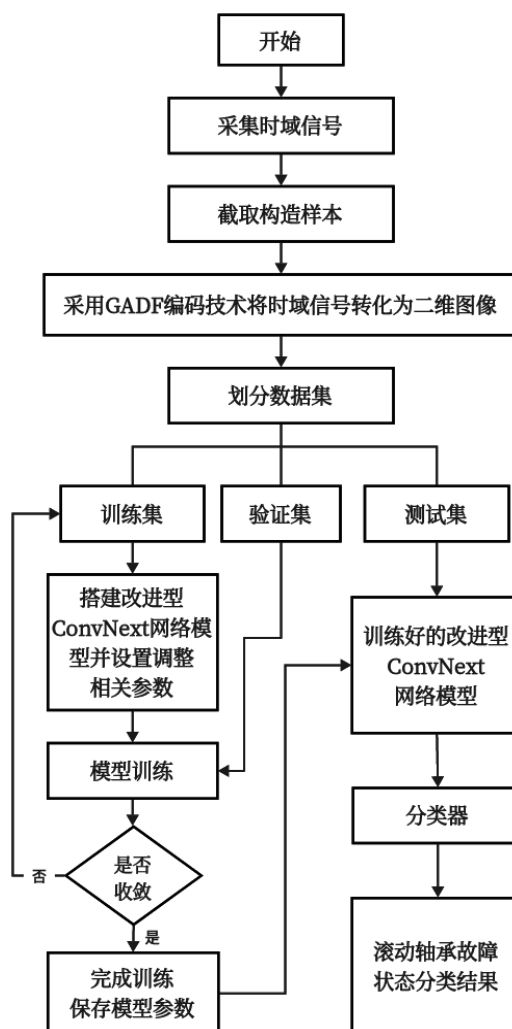


Figure 8. Improved ConvNeXt model fault diagnosis flowchart

图 8. 改进型 ConvNeXt 模型故障诊断流程图

4. 实验设置与结果分析

4.1. 实验运行硬件环境

操作系统为 Windows10 64 位, CPU 为 13th Gen Intel(R) Core(TM) i5-13600K, NVIDIA GeForce RTX 3060 Ti, 显存 8G, 内存 32G, python 版本为 3.8.16, 深度学习框架为 PyTorch。

4.2. 实验数据集

本实验采用网上公开的凯斯西储大学(CWRU)滚动轴承数据[29]进行实验验证。使用采样仪器采集滚动轴承的振动信号, 本文采用轴承驱动端的数据进行实验, 其中电机载荷为 3 马力, 故障直径分别为 0.1778


mm, 0.3556 mm, 0.5334 mm, 总共包含 9 种故障类型以及 1 种健康状态。

根据获取的 CWRU 数据集的采样频率和电机转速, 我们可以截取构造出长度为 416 的样本。通过 GADF 图像编码技术将截取到的每个样本进行二维图像转换。按照 6:2:2 的比例, 将每种类型的 230 张二维图像样本划分为训练集、验证集和测试集。表 1 展示了 10 种不同状态样本的构成情况。


Table 1. Construction of 2D image samples

表 1. 二维图像样本构造


样本类型	样本长度	图像样本数目	标签	训练集	验证集	测试集
正常	416	230	0	138	46	46
内圈故障 0.1778 mm	416	230	1	138	46	46
内圈故障 0.3556 mm	416	230	2	138	46	46
内圈故障 0.5334 mm	416	230	3	138	46	46
外圈故障 0.1778 mm	416	230	4	138	46	46
外圈故障 0.3556 mm	416	230	5	138	46	46
外圈故障 0.5334 mm	416	230	6	138	46	46
滚动体故障 0.1778 mm	416	230	7	138	46	46
滚动体故障 0.3556 mm	416	230	8	138	46	46
滚动体故障 0.5334 mm	416	230	9	138	46	46




(a) 正常轴承




(b) 内圈故障 0.1778 mm




(c) 内圈故障 0.3556 mm




(d) 内圈故障 0.5334 mm




(e) 外圈故障 0.1778 mm




(f) 外圈故障 0.3556 mm




(g) 外圈故障 0.5334 mm



(h) 滚动体故障 0.1778 mm



(i) 滚动体故障 0.3556 mm



(j) 滚动体故障 0.5334 mm

Figure 9. Bearing fault feature map generated using GADF encoding technology

图 9. 使用 GADF 编码技术生成的轴承故障特征图

图 9 展示的是使用 GADF 编码技术将 10 种不同故障状态样本生成对应的轴承故障特征图。通过故障特征图的对比, 我们可以发现滚动轴承振动信号中的故障信息, 基本能通过不同颜色的像素点进行表示。相较于传统的故障诊断方法, 这种编码方式减少了轴承振动信号去噪预处理的需求[30]。

4.3. 数据增强处理

为增加数据的多样性和泛化能力, 我们采用了一种改进的数据增强模块, 通过上述方法将滚动轴承的时域信号转换为二维特征图像并进行相应的数据增强。在具体实验中, 我们以轴承外圈故障二维特征图像为例, 如图 10 所示。




Figure 10. 2D image data augmentation of outer circle faults

图 10. 外圈故障二维图像数据增强

4.4. 模型训练

将表 1 中构造的二维图像样本, 输入进改进型 ConvNeXt 网络模型中, 经过 100 次的迭代训练, 得到如图 11 所示的故障识别准确率和损失函数(Loss)变化曲线图, 从图中可以观察到, 模型的训练集识别准确率基本已经达到了 100%, 最终在测试集上进行测试, 最终的平均准确率在 98.3%。由 Loss 函数图可知 Loss 函数值也降低到了 0.001 以下, 最终改进模型处于稳定的收敛状态。说明本文提出的改进型 ConvNeXt 网络模型对不同直径的滚动轴承故障状态具有良好的识别能力。




Figure 11. Curve chart of model classification recognition effect

图 11. 模型分类识别效果曲线图

图 12 展示了使用分类混淆矩阵和 T-SNE 可视化来表示改进型模型对滚动轴承故障状态的具体分类情况。

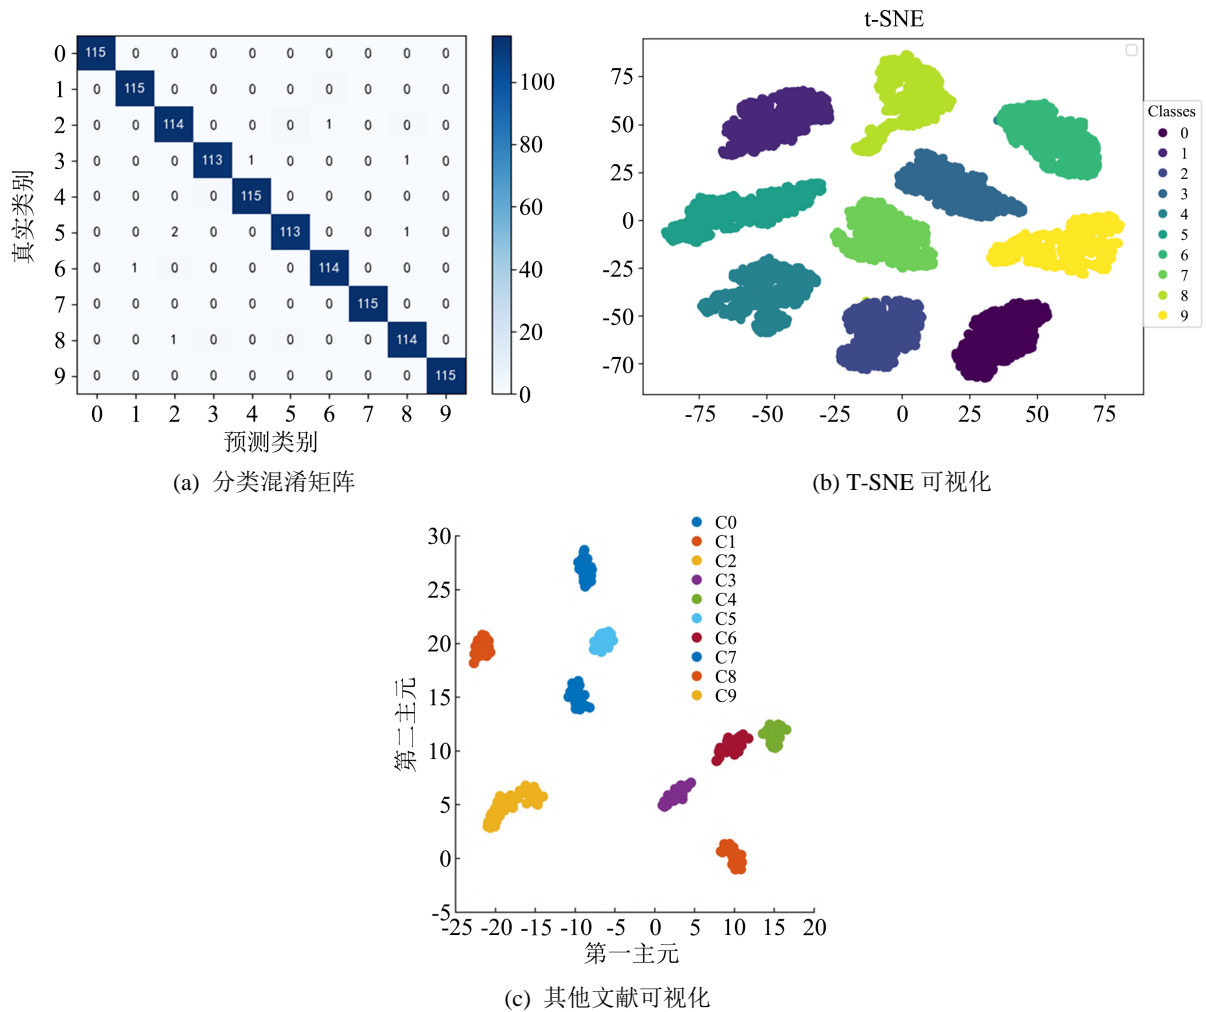


Figure 12. Model classification rendering

图 12. 模型分类效果图

综合图 11 和图 12 可以看出, 本研究提出的改进型 ConvNeXt 网络模型, 能够在短时间下高效收敛, 并具备优秀的识别准确率。它能够正确地识别和分类不同故障直径的滚动轴承状态特征。与之前使用相同的 CWRU 数据集的研究[9] (使用了 RP + ResNet 模型) 相比, 我们提出的改进型模型在不同故障直径的滚动轴承状态分类上表现更为优异。

4.5. 不同图像编码技术对诊断结果的影响

为了展示本文所采用的 GADF 编码技术结合改进的网络模型的优越性, 我们将同样实验数据分别使用 MTF 和 RP 编码技术编码, 生成相应的故障特征图输入至改进型 ConvNeXt 网络模型中进行实验。我们取 10 次测试集分类准确率的平均值作为最终结果[9]。如图 13 所示, 可以观察到使用 GADF 编码技术在故障识别上取得了最好的效果, 得到了最高的识别准确率。

4.6. 不同网络模型对诊断结果的影响

为了验证本文所改进网络模型的优越性, 我们将表 1 中的滚动轴承图像数据输入至 6 个具有代表性的网络模型及原始 ConvNeXt 模型中, 并取诊断 10 次的平均值作为对滚动轴承故障识别的最终准确率[9],

最终结果如表 2 所示。通过不同网络模型对比实验, 我们可以看到改进型 ConvNeXt 网络模型在不同故障直径的滚动轴承故障分类任务中效果更佳。

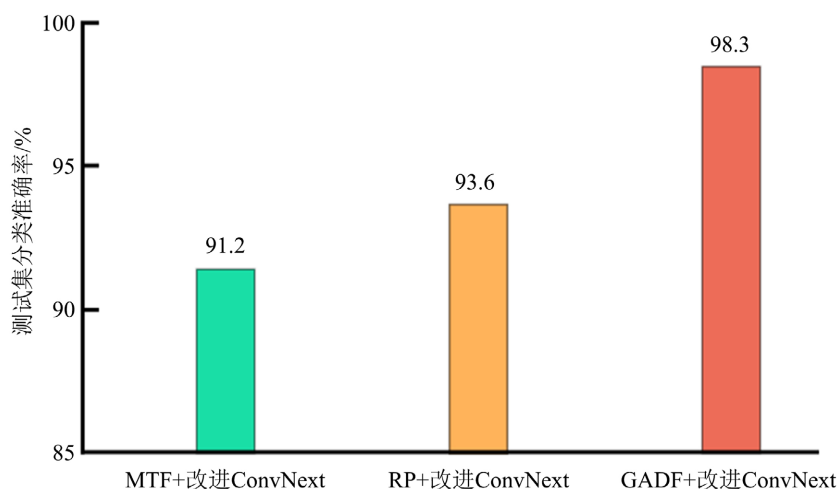


Figure 13. The impact of different image encoding techniques on model accuracy

图 13. 不同图像编码技术对模型准确率的影响

Table 2. Recognition accuracy of different network models

表 2. 不同网络模型的识别准确率

网络模型	平均准确率
GADF + ShuffleNet	50.2
GADF + GoogLeNet	53.6
GADF + AlexNet	73
GADF + MobileNet	79
GADF + VggNet	81.6
GADF + ResNet	96.9
GADF + ConvNeXt	94.25
GADF + 改进 ConvNeXt	98.3

5. 结论

本文为解决现有神经网络无法将滚动轴承深层次故障特征充分表示, 训练数据样本需求大, 模型整体鲁棒性和泛化能力不够, 基于 ConvNeXt 网络基础模型, 提出改进型模型。

首先使用格拉姆角差场图像编码技术将故障深层次特征充分表示, 生成相应的故障特征图, 相比较其他图像编码技术对于故障诊断准确率的提高有一定的优势。其次在原有 ConvNeXt 上改进数据增强模块, 从而提高数据的多样性和模型的鲁棒性。同时引入非对称卷积块来改进原有的 ConvNeXt Block 结构, 加入 CBAM 注意力机制, 更好地与 ConvNeXt 网络相融合, 提高了模型在处理故障诊断方面的特征提取能力。最后通过在 CWRU 滚动轴承数据上的实验验证, 改进型 ConvNeXt 网络模型对滚动轴承不同故障直径的识别准确率达到到了 98.3%, 相比较 GADF + VggNet, GADF + ResNet, GADF + ConvNeXt 等网络

模型, 分别提高了 16.7%, 1.4% 和 4.05%。结果表明, 改进型 ConvNeXt 网络模型在故障诊断的准确率以及鲁棒性上的表现都优于其他相同实验背景模型, 从而说明, 本文提出的改进型网络模型对故障诊断分类具有较好的效果。

基金项目

国家自然科学基金资助项目(72174121)。

参考文献

- [1] 陈剑, 阚东, 孙太华, 等. 基于 SVD-VMD 和 SVM 滚动轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(1): 220-226.
- [2] 杜航, 徐海巍, 楼文娟. 基于短时傅里叶变换的快速贝叶斯模态参数识别方法[J]. 建筑结构学报, 2023, 44(5): 305-314, 334.
- [3] 李治甫, 康帅, 王自法, 等. 基于时频变换和卷积神经网络的结构损伤识别[J]. 防灾减灾工程学报, 2023, 43(6): 1275-1283.
- [4] 李寿涛, 屈如意, 张宇, 等. 基于变分模态分解的冻结步态识别方法[J]. 东北大学学报(自然科学版), 2023, 44(11): 1543-1547, 1555.
- [5] 谢星怡, 张正江, 闫正兵, 等. 基于信号特征提取和卷积神经网络的轴承故障诊断研究[J]. 计算机测量与控制, 2023, 31(10): 21-27.
- [6] 程亮, 董子健, 王树民, 等. 基于改进一维卷积神经网络的滚动轴承故障诊断分析[J]. 机械设计与研究, 2023, 39(3): 126-130.
- [7] 陆浩博. 基于二维卷积神经网络的逆变器故障诊断研究[D]: [硕士学位论文]. 兰州: 兰州交通大学, 2024.
- [8] 李超. 基于时频图的 2DCNN 轴承故障诊断方法研究[D]: [硕士学位论文]. 大连: 大连交通大学, 2023.
- [9] 宋乾坤, 周孟然. 基于 CWT-CNN 的滚动轴承故障诊断[J]. 重庆工商大学学报(自然科学版), 2023, 40(3): 42-47.
- [10] 陈向民, 韩梦茹, 舒文伊, 等. 基于 VMD 与多尺度一维卷积神经网络的故障诊断方法[J]. 现代电子技术, 2023, 46(9): 103-109. <https://doi.org/10.16652/j.issn.1004-373x.2023.09.020>
- [11] Liu, Z., Mao, H.Z., Wu, C.Y., et al. (2022) A ConvNet for the 2020s. 2022 *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 18-24 June 2022, 11976-11986. <https://doi.org/10.1109/CVPR52688.2022.01167>
- [12] Liu, Z., Lin, Y., Cao, Y., et al. (2021) Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows. 2021 *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, 10-17 October 2021, 10012-10022. <https://doi.org/10.1109/ICCV48922.2021.00986>
- [13] Ma, X., Niu, T., Liu, X., et al. (2022) Remaining Useful Lifetime Prediction of Rolling Bearing Based on ConvNext and Multi-Feature Fusion. 2022 *International Conference on Computer Engineering and Artificial Intelligence (ICCEAI)*, Shijiazhuang, 22-24 July 2022, 299-304. <https://doi.org/10.1109/ICCEAI55464.2022.00069>
- [14] 杨文哲, 郝如江, 郭梓良, 等. 基于一维 ConvNeXt 网络的齿轮箱故障诊断[J]. 国防交通工程与技术, 2023, 21(4): 28-31, 61.
- [15] 查世康, 黄陈蓉. 基于 ConvNeXt 和注意力机制的绝缘子自爆故障检测方法[J]. 宁夏电力, 2023(3): 42-50.
- [16] 赵小强, 梁浩鹏. 使用改进残差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, 2020, 54(9): 23-31.
- [17] 占可, 王寅杰, 董路南, 等. 基于改进格拉姆角场和注意力的滚动轴承故障诊断[J/OL]. 轴承: 1-8. <http://kns.cnki.net/kcms/detail/41.1148.TH.20230112.1507.003.html>, 2024-05-22.
- [18] 李雷, 卢才武, 江松, 等. 基于改进 ConvNeXt 网络的矿物图像智能识别[J/OL]. 地质通报: 1-11. <http://kns.cnki.net/kcms/detail/11.4648.P.20230331.1254.002.html>, 2024-05-22.
- [19] Ding, X., Guo, Y., Ding, G., et al. (2019) ACNet: Strengthening the Kernel Skeletons for Powerful CNN via Asymmetric Convolution Blocks. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV)*, Seoul, 27 October-2 November 2019, 1911-1920. <https://doi.org/10.1109/ICCV.2019.00200>
- [20] 张帅, 张俊忠, 曹慧, 等. 基于 ConvNeXt 网络的新冠肺炎 X 射线图像诊断方法[J]. 激光与光电子学进展, 2023, 60(14): 20-28.

-
- [21] 李建威, 吕晓琪, 谷宇. 基于改进 ConvNeXt 的皮肤镜图像分类方法[J]. 计算机工程, 2023, 49(10): 239-246, 254.
- [22] 郑世杰, 王高才. 基于 ConvNeXt 热图定位和对比学习的细粒度图像分类研究[J]. 计算机科学, 2023, 50(10): 119-125.
- [23] 张宸嘉, 朱磊, 俞璐. 卷积神经网络中的注意力机制综述[J]. 计算机工程与应用, 2021, 57(20): 64-72.
- [24] Xu, Q., Su, J., Wang, Y., *et al.* (2022) Few-Shot Learning Based on Double Pooling Squeeze and Excitation Attention. *Electronics*, **12**, Article 27. <https://doi.org/10.3390/electronics12010027>
- [25] Aolei, L., Sunjie, Z., Zhe, W., *et al.* (2023) A Learnable Front-End Based Efficient Channel Attention Network for Heart Sound Classification. *Physiological Measurement*, **44**, Article 095003. <https://doi.org/10.1088/1361-6579/acf3cf>
- [26] Li, X., Wang, W., Hu, X., *et al.* (2019) Selective Kernel Networks. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 15-20 June 2019, 510-519. <https://doi.org/10.1109/CVPR.2019.00060>
- [27] 孙敏, 成倩, 丁希宁. 基于 CBAM-CGRU-SVM 的 Android 恶意软件检测方法[J/OL]. 计算机应用: 1-9. <http://kns.cnki.net/kcms/detail/51.1307.TP.20231212.1653.006.html>, 2024-05-22.
- [28] 马晓, 董天亮, 钟闻宇, 等. 基于改进 ConvNeXt 的大豆叶片病害分类研究[J]. 大豆科学, 2023, 42(6): 733-741.
- [29] CaseWestern Reserve University Bearing Data Center. Bearing Datafile. <https://engineering.case.edu/bearingdatacenter/download-data-file>
- [30] 骆家杭, 张旭, 汪靖翔. 基于格拉姆角场和多尺度 CNN 的轴承故障诊断[J]. 轴承, 2022(6): 73-78.