

基于GoogLeNet的多状态滚动轴承故障诊断可行性研究

张 维, 宋宇博*

兰州交通大学机电工程学院, 甘肃 兰州

收稿日期: 2025年9月9日; 录用日期: 2025年10月1日; 发布日期: 2025年10月9日

摘 要

轴承作为轨道交通车辆走行部的关键零部件, 由于车辆运行环境复杂, 载运工具运行工况不断变化, 因此对轴承进行实时的状态监测和智能诊断具有重要意义。本文以深度学习为基础, 使用快速谱峭度算法处理轴承振动信号数据, 引入GoogLeNet网络进行多状态轴承故障诊断, 提出一种基于快速谱峭度的信号-图像转换方法进行多状态滚动轴承数据处理, 对比分析了三种数据集和混合数据集下的多状态轴承故障诊断损失和准确度拟合曲线, 其准确度均高于77%, 由此得出该研究方法具有可行性。

关键词

滚动轴承, 故障诊断, 迁移学习, GoogLeNet

Feasibility Study on Multi-Condition Rolling Bearing Fault Diagnosis Based on GoogLeNet

Wei Zhang, Yubo Song*

School of Mechanical and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou Gansu

Received: September 9, 2025; accepted: October 1, 2025; published: October 9, 2025

Abstract

Bearings are critical components in the running gear of rail-transit vehicles. Because these vehicles operate in complex environments and under constantly changing service conditions, real-time condition monitoring and intelligent fault diagnosis of bearings are of paramount importance. In this paper, we adopt deep-learning techniques, apply the fast spectral kurtosis algorithm to process bearing-vibration data, and introduce GoogLeNet for multi-state bearing fault diagnosis. A signal-

*通讯作者。

to-image conversion method based on fast spectral kurtosis is proposed to handle multi-state rolling-element-bearing data. Comparative analyses of the loss and accuracy curves obtained with three individual datasets and a combined dataset show that all accuracies exceed 77%, confirming the feasibility of the proposed approach.

Keywords

Rolling Bearings, Fault Diagnosis, Transfer Learning, GoogLeNet

Copyright © 2025 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

滚动轴承故障诊断方法的研究主要分为基于信号处理和基于数据驱动两类故障诊断方法。其中基于信号处理类在数据采集、特性挖掘和分类决策等方面存在数据需要人工采集、数据维度解析不够深入和状态监测系统收集的海量数据人工处理困难等问题,因此该方法具有明显的局限性,诊断结果偏差较大。近年来,随着深度学习在图像识别、故障诊断和语音处理等领域的蓬勃发展,基于深度学习的诊断模型的循环神经网络、卷积神经网络也成为当下的研究热点并取得了丰硕的研究成果。Yang [1]等在 LetNet-5 经典神经网络中使用了一维大尺寸的卷积核,在旋转机械的故障诊断方面取得了比其他传统故障诊断方式更高的准确率。郭秀才等[2]出了一种基于多域特征融合与 DBN 的轴承故障诊断方法,采用核主成分分析(Kernel Principle Component Analysis, KPCA)对高维筛选特征进行降维融合,最终将融合特征作为初始值,输入至 DBN 中完成故障诊断。赵冬梅等[3]提出了改进的自编码器(BN-DAE),将批量标准化(Batch Normalization, BN)引入了传统自编码器,故障诊断效果优于传统的 AE。王应晨等[4]提出一种基于降噪自编码和 DBN 的融合诊断模型,结合 SVM 进行轴承故障模式识别,有效提高模型的诊断精度和收敛速度。Wen [5]提出了一种基于特征迁移的故障诊断方法,使用大规模图像数据集上预训练的 Resnet-50 深度学习网络,将一维振动信号转换为图像作为输入,通过轴承数据集进行测试,诊断结果比基准卷积神经网络和传统诊断方法更准确。Janssens 等[6]针对监测轴承状态时故障特征的提取问题,提出了一种基于 CNN 的特征学习模型,该模型能够自主学习与故障检测相关的特征。Yang 等[7]开发了一种基于长短期记忆循环神经网络的智能故障诊断技术,充分利用了时间上的依赖关系,从而实现了对故障的精准检测和对应故障类型的有效分类。李凤林[8]研究了多种冲击脉冲指标,提出了联合快速峭度图和快速包络谱峭度图的滚动轴承复合故障诊断方法。以往的研究主要集中于轴承单一运动状态下的不同模型深度学习神经网络故障诊断和传统的信息采集诊断,对于复杂工况条件下的滚动轴承故障研究相对较少。本文基于 GoogLeNet 卷积神经网络对高速列车走行部的滚动轴承的内圈故障、外圈故障和保持架故障的多状态故障进行分析,并对研究结果与参考数据进行对比讨论,研判 GoogLeNet 在滚动轴承故障诊断方面的可行性。

2. 滚动轴承故障机理

通常情况下,滚动轴承由内圈、外圈、滚动体和挡圈这四个部分组成,如下图 1 所示。内圈的功能是与轴相匹配并随其旋转,而外圈则支撑着轴承座。在保持器的辅助下,滚动体均匀地分布在内圈和外圈之间。保持器的作用是滚动体的均匀分布在内外圈之间,防止它们移位,并引导它们进行旋转,给滚

道润滑。

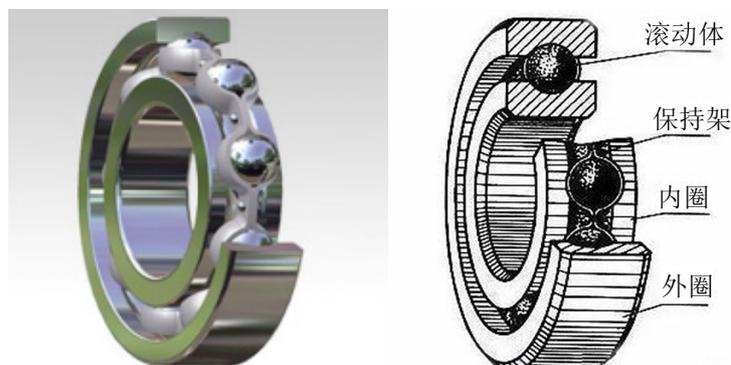


Figure 1. Schematic diagram and cross-sectional view of the bearing structure
图 1. 轴承结构示意图及剖面图

轨道交通车辆工作环境复杂, 运行过程中滚动轴承需要承担复杂多变的载荷, 长期运行和重载会导致滚动体和滚道表面的疲劳损伤, 最终导致裂纹形成和断裂。当裂纹形成后, 会逐渐扩展到接触面, 在接触表面形成剥落坑, 最终, 导致接触表面大片剥落, 形成疲劳剥落; 由于装配方式不正确导致保持架变形, 会使保持架与滚动体剧烈摩擦, 还会造成一些滚动体卡死, 也会导致保持架与内外圈发生摩擦, 保持架磨损后, 间隙变大, 与滚动体之间的撞击力增大, 以致使保持架断裂滚动轴承容易产生多种类型的故障常见故障类型如: 疲劳损伤、磨损、塑性变形、锈蚀、保持架损坏、胶合等。下图 2 为列举的常见滚动轴承不同状态下的故障情况图。



Figure 2. Three-state faults of rolling bearings
图 2. 滚动轴承“三态”故障

3. GoogLeNet 模型与快速峭度算法

深度学习神经网络能处理海量的信号数据, 其关键在于通过不断增大网络深度以提高训练效果, 如: AlexNet、VGG 等网络结构。但不断增加网络层数不仅对设备性能提出了更高要求, 同时也会带来许多不良后果, 如: 参数量太大, 当训练数据集有限的情况下, 容易产生拟合现象; 梯度弥散现象产生的概率激增, 模型优化困难。

为了解决上述问题, GoogLeNet 在初始神经网络模块内部嵌入了 Inception 结构进行算法改进。该结构通过堆叠 CNN 中常用的卷积操作、池化操作(卷积、池化后的尺寸相同, 将通道相加), 既能增加网络宽度, 又能提高网络的适应能力。原始版本的 Inception 模块, 所有的卷积核都在上一层的输出上计算,

这将会增大 5×5 卷积核的计算量, 使得特征图的厚度很大, 通过在 3×3 的卷积层前、 5×5 的卷积前层、最大集合层后分别加上了 1×1 的卷积核, 来降低特征图的厚度, 可以避免这种情况, 这也就产生了 Inception v1 的网络结构, 如图 3、图 4 所示。

1×1 卷积除了具有降低维度的作用, 还具有修正线性激活(ReLU)作用, 可以降低运算的复杂程度。如果上一层的输出先经过 1×1 卷积层, 然后经过 5×5 卷积层, 那么输出结果将会改变, 输出结果大约减少了 4 倍。在一个卷积层中, 如果输入了大量的特征信号, 则在该特征信号上做卷积操作计算量将会很大; 如果首先对输入进行维度降低处理, 然后在进行卷积运算, 那么可以大大降低特征数目。

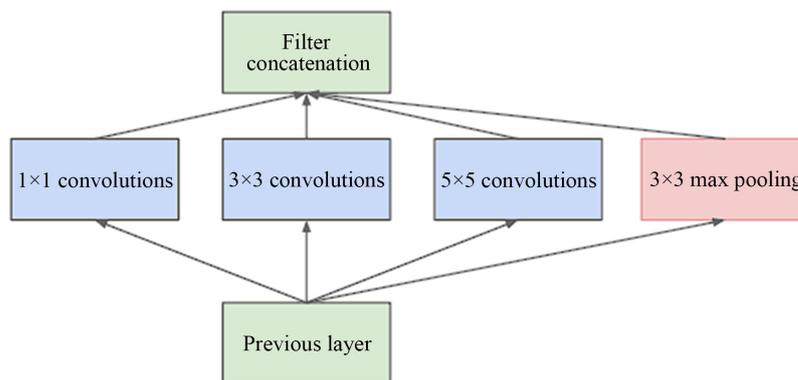


Figure 3. Initial GoogLeNet network model
图 3. 初始 GoogLeNet 网络模型

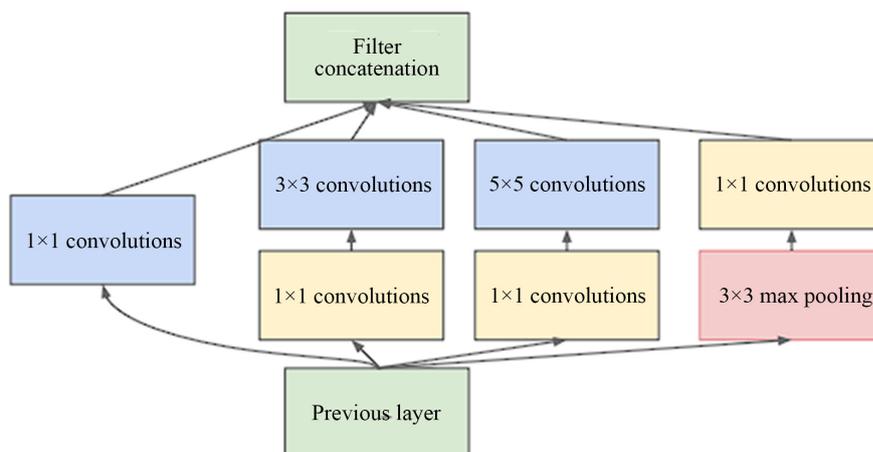


Figure 4. GoogLeNet network model with specific dimension-reduction modules
图 4. 具体降维模块的 GoogLeNet 网络模型

当滚动轴承产生冲击故障时, 把冲击信号作为不平稳信号, 其他信号当作占主要部分的平稳强噪声, 冲击信号往往会被其他信号淹没。快速谱峭度算法的基本思想是: 不平稳冲击信号在强噪声的干扰下, 谱峭度指标大小与短时傅里叶变换中频率及频率分辨率中时窗宽度的选取关系紧密。合理的选取频率及频率分辨率可以让不平稳信号的谱峭度指标达到最大值, 更好的表现出冲击故障特征。

图 5 展示的是一个深沟球滚动轴承的外圈故障仿真信号快速谱峭度图像, 信号在 12 kHz 采样频率下采集, 故障共振带为图像中颜色最亮(谱峭度最大)的色块, 其在 1 级别(最佳窗口长度 = 4)上最大谱峭度为 0.47897 , 中心频率为 1.5 kHz , 带宽为 3 kHz 。

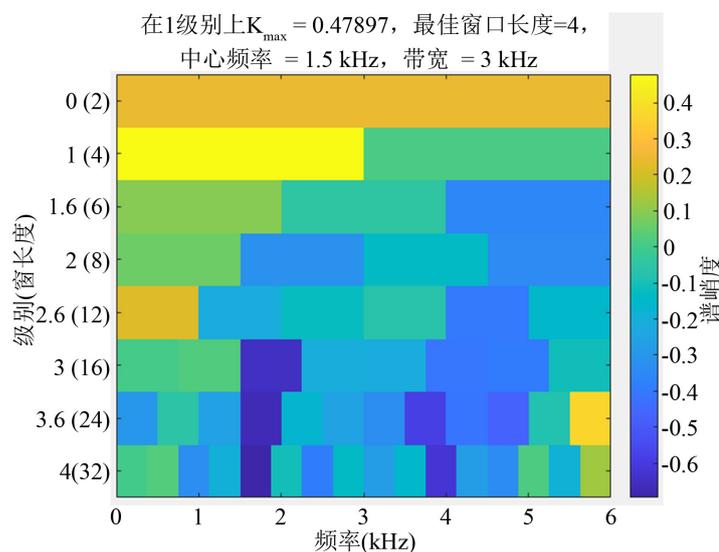


Figure 5. Fast spectral kurtosis image of simulated outer-ring fault signal
图 5. 外圈故障仿真信号相关快速谱峭度图像

4. 实验结果验证与可行性研究

本次实验采用凯斯西储大学、辛辛那提大学和江南大学的轴承数据集开展基于 GoogleLeNet 的多状态轴承故障诊断算法的设计可行性研究。具体设计流程为先对轴承数据进行处理, 本实验通过滑动窗口的数据分割方法将原始数据等距分割; 其次采用基于快速谱峭度的信号 - 图像转换方法将分割好的数据进行处理, 将数据转换为快速谱峭度图像并保存到相应文件夹; 然后根据文件夹名称自动标注图像, 将图像数据存储, 其中数据分为训练数据集和验证数据集(其中 80% 的图像用于训练, 20% 的图像用于验证)并对 GoogleLeNet 网络进行训练; 最后使用训练完成的 GoogleLeNet 网络对验证图像进行分类, 随机显示四个验证图像与预测的标签, 然后计算针对验证集图像的分类准确度。

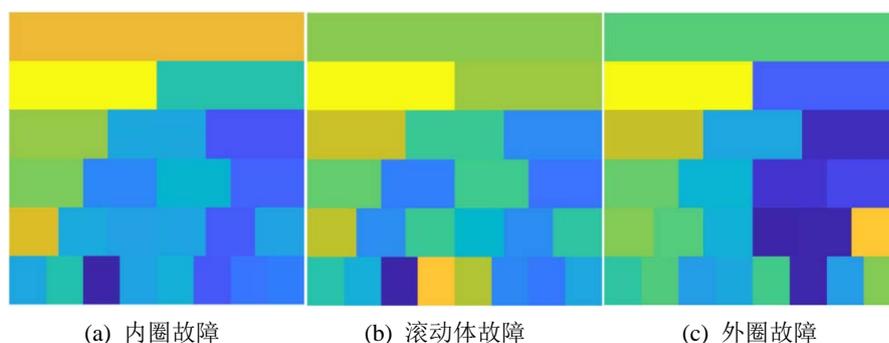


Figure 6. Fast spectral kurtosis images of the Case Western Reserve University (CWRU) bearing dataset
图 6. 凯斯西储数据集快速谱峭度图像

凯斯西储大学轴承实验台利用电火花加工技术对滚动轴承进行测试, 引入不同类型的单点故障。使用加速度传感器采集故障轴承的振动加速度信号, 使用扭矩传感器来采集电机功率和转速。数据集包括采样频率为 12 kHz 与 48 kHz 的驱动端轴承故障数据, 采样频率为 12 kHz 的风扇端轴承故障数据, 这些数据具有不同的故障直径(0.1778、0.3556 mm), 每一种故障直径对应着 3 种故障类型下的实验数据。将原始时域数据等距分割, 采用基于快速谱峭度的信号 - 图像转换方法进行数据预处理, 并将快速谱峭度

图像进行处理, 去除图中文字只保留图片, 轴承“三态”故障快速峭度图像如上图 6 所示。此时每种故障类型均生成 300 张快速谱峭度图, 最终生成的数据集包含两类直径数据的“三态”故障数据, 总计 1800 张快速谱峭度图。

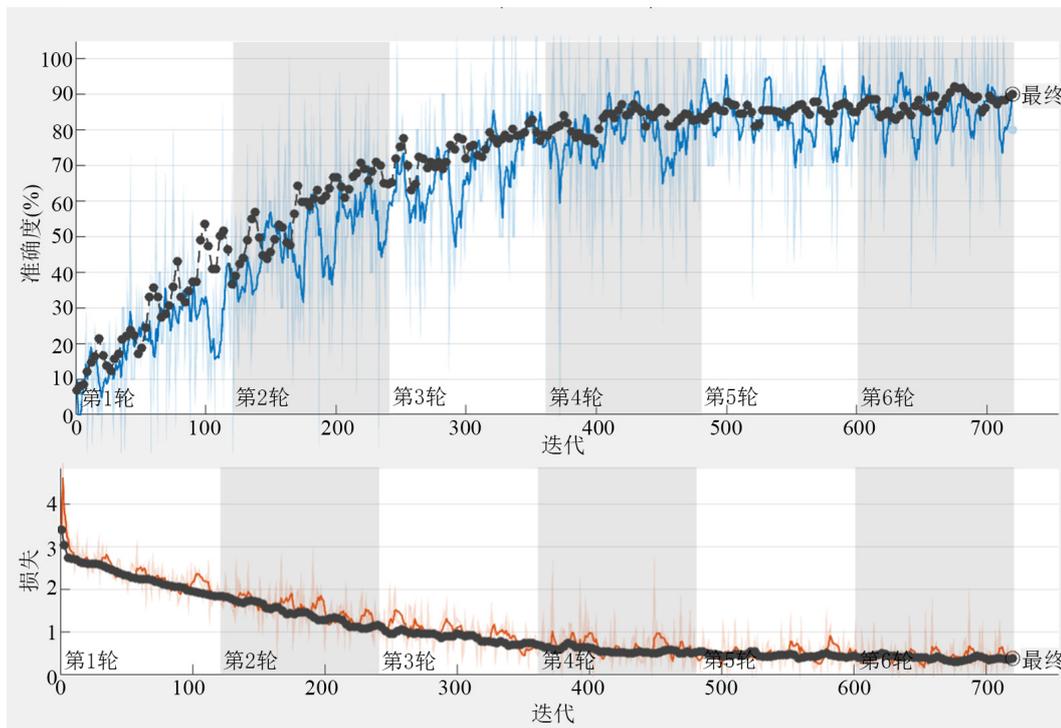


Figure 7. Training loss and accuracy curves for the Case Western Reserve University (CWRU) dataset
图 7. 凯斯西储数据集训练损失和准确度曲线

使用 1800 张快速谱峭度图进行 GoogLeNet 网络训练, 训练次数为 6 轮, 然后随机显示四个验证图像与预测的标签, 计算针对验证集图像的分类准确度。损失和准确度曲线显示分类准确度达到了 90%, 该卷积神经网络的故障诊断方法可行性较高。其对比结果如上图 7 所示。

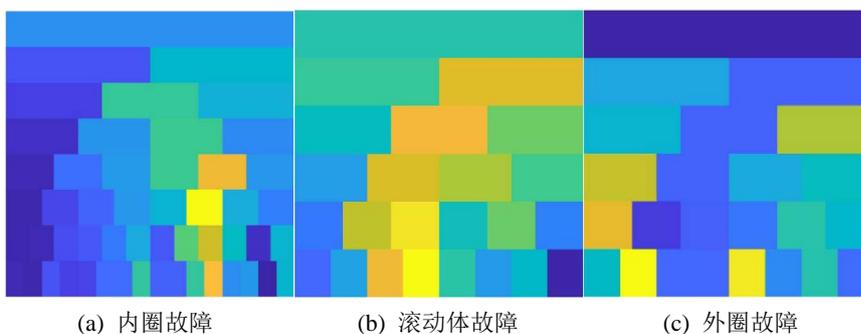


Figure 8. Fast spectral kurtosis images of the Cincinnati IMS bearing dataset
图 8. 辛辛那提 IMS 数据集快速谱峭度图像

辛辛那提轴承试验台数据文件包括了三套数据。每套数据记录了一个从测试到失效的实验且由单个文件构成, 每个文件由 20,480 个点构成, 采样频率为 20 kHz。这些文件记录了在特定时间间隔内的 1 秒振动信号快照, 将原始时域数据等距分割, 采用基于快速谱峭度的信号 - 图像转换方法进行处理,

并对快速谱峭度图像进行处理, 去除图中文字只保留图片。此时每一套数据集均生成 200 张快速谱峭度图, 最终生成的数据集包含 600 张快速谱峭度图。实验数据集的轴承“三态”故障快速谱峭度图像如上图 8 所示。

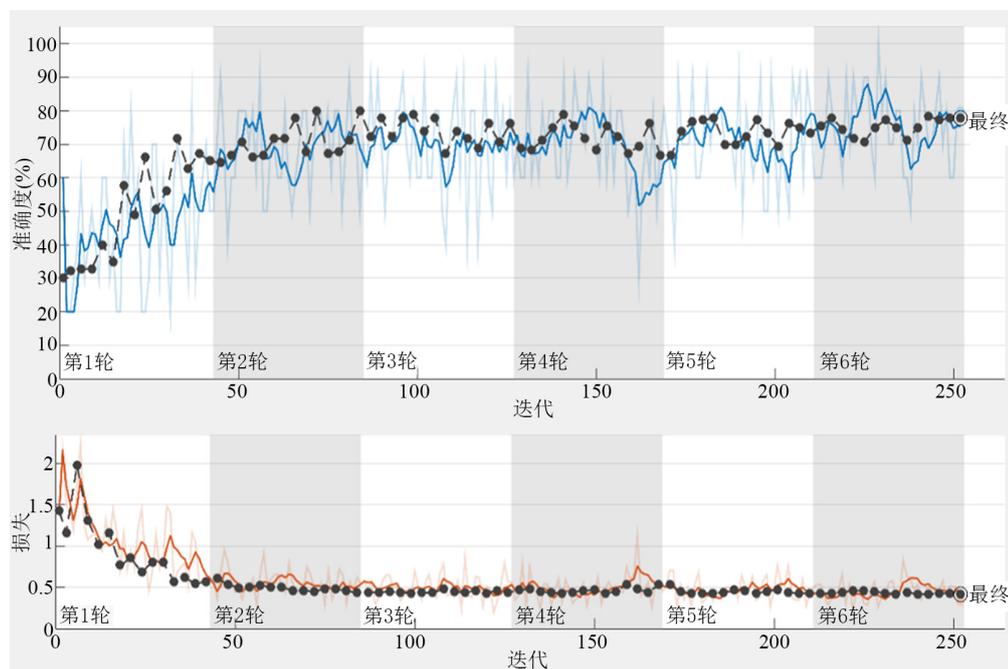


Figure 9. Training loss and accuracy curves for the Cincinnati IMS bearing dataset

图 9. 辛辛那提 IMS 数据集训练损失和准确度曲线

对 600 张快速谱峭度图进行 GoogLeNet 网络训练, 训练次数为 6 轮, 然后随机显示若干个验证图像与预测的标签, 计算针对验证集图像的分类准确度。对比数据模拟生成损失和准确度曲线, 结果显示该训练方法以该数据集为数据来源的轴承故障诊断分类准确度达到了 77.78%, 对比曲线如上图 9 所示。

江南大学轴承数据采样频率为 50 kHz, 利用上述同样的数据处理流程, 每种故障类型生成 500 张快速谱峭度图, 共分为内圈故障、滚动体故障和外圈故障三类状态, 最终生成的数据集包含 1500 张快速谱峭度图, 轴承故障类型对应数据快速谱峭度图谱如图 10 所示, 对数据进行 GoogLeNet 网络训练, 训练次数为 6 轮, 对比数据模拟生成损失和准确度曲线, 结果显示该训练方法以该数据集为数据来源的轴承故障诊断分类准确度达到了 77.78%, 对比曲线如图 11 所示。

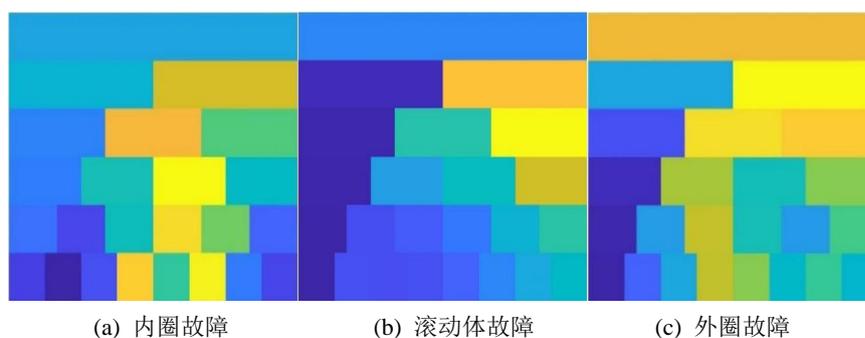


Figure 10. Fast spectral kurtosis images of the Jiangnan University bearing dataset

图 10. 江南大学数据集快速谱峭度图像

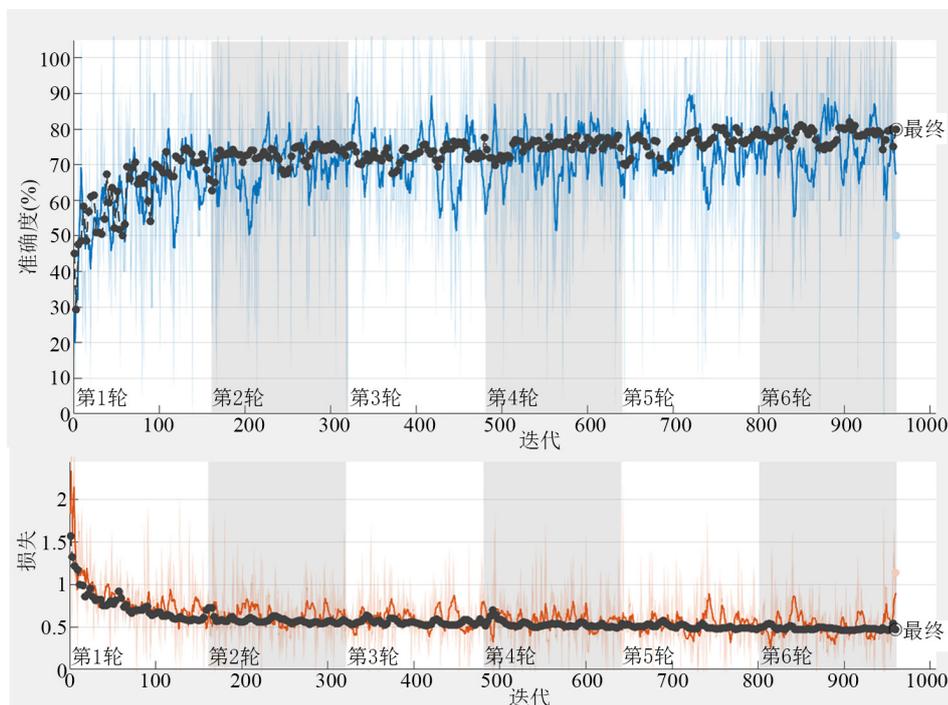


Figure 11. Training loss and accuracy curves for the Jiangnan University bearing dataset
图 11. 江南大学数据集训练损失和准确度曲线

为使研究具有普适性, 将实验中的三个轴承数据集快速谱峭度图像文件保存在同一个路径文件夹下, 载入到 GoogLeNet 网络进行训练(其中 80% 的图像用作训练集, 20% 的图像用作验证机)训练次数为 6 轮, 然后随机显示若干个验证图像与预测的标签, 计算针对验证集图像的分类准确度, 绘制损失和准确度拟合曲线, 结果显示混合数据集状态下, 轴承故障诊断分类准确度达到 77.68%。结果如图 12 所示。

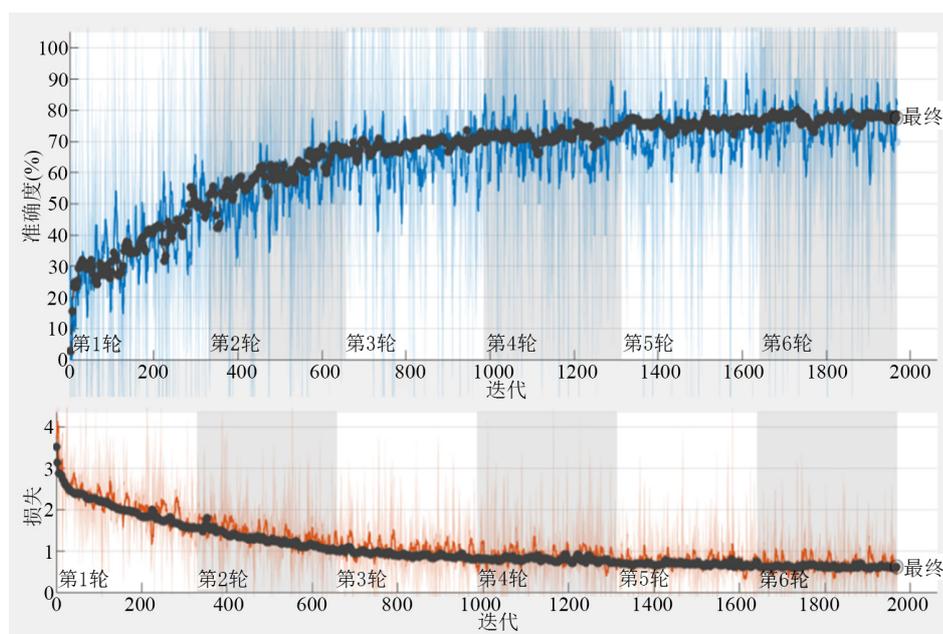


Figure 12. Training loss and accuracy curves for the mixed dataset
图 12. 混合数据集训练损失和准确度曲线

5. 结论

本文以滚动轴承为研究对象, 对比传统信号和数据驱动两种模式下的故障诊断方式, 以深度学习为基础, 使用快速谱峭度算法处理轴承振动信号数据, 引入 GoogLeNet 网络进行多状态轴承故障诊断, 提出一种基于快速谱峭度的信号 - 图像转换方法进行多状态滚动轴承数据处理, 并进行可行性研究, 得到以下结论:

(1) GoogLeNet 模型对比以前的卷积神经网络结构, 不仅延伸了网络深度, 还扩展了网络的宽度, 整个网络模型由许多块状子网络的堆叠构成, 该模块具有降低维度和修正线性激活的作用, 在计算设备运算能力有限的前提下展现出更优越的计算性能;

(2) 分别采用凯斯西储大学、辛辛那提 IMS、江南大学的滚动轴承数据进行基于快速谱峭度的信号 - 图像转换, 然后将快速谱峭度图像加载到 GoogLeNet 网络中训练并对验证图像进行分类, 最终分类准确度达到分别达到 90%、77.78% 和 80%;

(3) 将三个数据集进行混合, 利用同样的计算方法进行计算, 得到损失和准确度拟合曲线, 结果显示准确度高达 77.68%, 这说明该类滚动轴承故障诊断准确度较高, 具有可行性, 但准确度还需进一步提升, 为滚动轴承多状态故障诊断提供了一种新思路。

参考文献

- [1] Yang, B., Lei, Y., Jia, F. and Xing, S. (2019) An Intelligent Fault Diagnosis Approach Based on Transfer Learning from Laboratory Bearings to Locomotive Bearings. *Mechanical Systems and Signal Processing*, **122**, 692-706. <https://doi.org/10.1016/j.ymssp.2018.12.051>
- [2] 郭秀才, 吴妮, 曹鑫. 基于特性融合与 DBN 的矿用通风机滚动轴承故障诊断[J]. 工矿自动化, 2021, 47(10): 14-56.
- [3] 赵冬梅, 王闯, 马泰屹. 基于改进堆栈自编码器的变压器故障诊断模型[J]. 华北电力大学学报(自然科学版), 2020, 47(6): 61-67.
- [4] 王应晨, 段修生. 深度学习融合模型在机械故障诊断中的应用[J]. 振动.测试与诊断, 2019, 39(6): 1271-1276, 1363, 1364.
- [5] Wen, L., Li, X.Y. and Gao, L. (2019) A Transfer Convolutional Neural Network for Fault Diagnosis Based on ResNet-50. *Neural Computing and Applications*, **32**, 6111-6124.
- [6] Janssens, O., Slavkovicj, V., Vervisch, B., Stockman, K., Loccupier, M., Verstockt, S., *et al.* (2016) Convolutional Neural Network Based Fault Detection for Rotating Machinery. *Journal of Sound and Vibration*, **377**, 331-345. <https://doi.org/10.1016/j.jsv.2016.05.027>
- [7] Yang, R., Huang, M., Lu, Q. and Zhong, M. (2018) Rotating Machinery Fault Diagnosis Using Long-Short-Term Memory Recurrent Neural Network. *IFAC-PapersOnLine*, **51**, 228-232. <https://doi.org/10.1016/j.ifacol.2018.09.582>
- [8] 李凤林. 基于改进快速峭度图的高速列车滚动轴承复合故障诊断[D]: [硕士学位论文]. 成都: 西南交通大学, 2019.