

[自控·检测]

DOI:10.3969/j.issn.1005-2895.2023.01.009

基于改进 DenseNet 和迁移学习的 变负载滚动轴承故障诊断

吕欢¹, 许涛^{1,2}, 麻爱松¹, 李建平¹, 陈玉立¹

(1. 西安工程大学机电工程学院, 陕西 西安 710600;
2. 西安市现代智能纺织装备重点实验室, 陕西 西安 710049)

摘要: 由于在实际工作环境下滚动轴承故障样本不足, 而且受到环境噪声以及负载变化的影响, 故障样本分布存在差异性导致诊断泛化性差, 对此课题组提出一种基于改进 DenseNet 与迁移学习结合的滚动轴承故障诊断方法。对原 DenseNet 中的 ReLU 激活函数, 使用 LeakyReLU 函数替代, 并在全连接层后添加 Softmax 层进行分类, 使提取故障特征更为丰富; 为了使轴承信号接近工厂采集的数据, 对凯斯西储大学轴承数据集中添加了信噪比为 -2 dB 的高斯白噪声并进行模拟, 经 Z-Score 归一化处理后转化为二维灰度图作为样本数据。实验结果表明该方法在小样本变负载下的跨域诊断准确率都达到了 90% 以上, 与其他模型对比具有更好的泛化性。

关键词: 滚动轴承; 故障诊断; DenseNet; 迁移学习; LeakyReLU 函数

中图分类号: TP181; TH133.33 文献标志码: A 文章编号: 1005-2895(2023)01-0053-06

Rolling Bearing Fault Diagnosis Method Based on Improved DenseNet and Transfer Learning under Load Changes

LÜ Huan¹, XU Tao^{1,2}, MA Aisong¹, LI Jianping¹, CHEN Yuli¹

(1. School of Mechanical and Electrical Engineering, Xi'an Polytechnic University, Xi'an 710600, China;
2. Xi'an Key Laboratory of Modern Intelligent Textile Equipment, Xi'an 710049, China)

Abstract: Due to the insufficient fault samples of rolling bearings in the actual working environment, and the influence of environmental noise and load changes, the difference in fault sample distribution leads to poor generalization of diagnosis. A rolling bearing fault diagnosis based on improved DenseNet and transfer learning method was proposed. The ReLU activation function in the original DenseNet was replaced by LeakyReLU, and a Softmax layer was added after the fully connected layer for classification to enrich the fault features extraction. In order to make the bearing signal close to the data collected by the actual factory, a Gaussian white noise with a signal-to-noise ratio of -2 dB was added to the Case Western Reserve University data set for simulation. After Z-Score normalization, it was transformed into a two-dimensional grayscale map as the sample data. The experimental results show that the cross-domain diagnostic accuracy of the proposed method has reached more than 90% under small samples and load changes, and has better generalization compared with other models.

Keywords: rolling bearing; fault diagnosis; DenseNet; transfer learning; LeakyReLU

收稿日期: 2022-07-01; 修回日期: 2022-11-15

基金项目: 陕西省自然科学基金资助项目(2019JM-310); 广东省精密齿轮柔性制造装备技术企业重点实验室开放基金(中山迈雷特数控技术有限公司 & 华南理工大学)(2021B1212050012-05); 西安市现代智能纺织装备重点实验室资助项目(2019220614SYS021CG043)。

第一作者简介: 吕欢(1997), 男, 安徽桐城人, 硕士研究生, 主要研究方向为深度学习与故障诊断。E-mail: lvhuan@stu.xpu.edu.cn

滚动轴承作为旋转机械的重要组成部分之一,对其进行故障诊断是众多学者研究的重点^[1]。由于传统故障诊断技术需要大量的人力和物力,而且诊断精度不高,深度学习技术的出现改变了现状,其中算法包括卷积神经网络、自编码器、深度置信网络和长短期记忆网络^[2]。吴晨芳等^[3]提出了一种基于改进的 LeNet-5 模型的卷积神经网络故障诊断方法,该方法有较好的鲁棒性和泛化能力。王太勇等^[4]提出了基于 DenseNet 的卷积核 dropout (KD) 智能故障诊断模型 KD-DenseNet,提高了有效特征的提取效率,解决了传统特征提取方法中无法有效挖掘特征、无法自适应于任务进行调整等问题。Che 等^[5]提出一种门循环单元和混合自编码器的智能故障预测模型,用凯斯西储大学数据集验证了该方法的有效性且具有较高的精度。Gao 等^[6]提出一种新的优化自适应深度置信网络,实验证明该方法在滚动轴承故障诊断上具有较高的诊断精度。曹正志等^[7]提出了一种基于改进的一维卷积神经网络 (1D-CNN) 和长短期记忆网络 (LSTM) 集成的滚动轴承故障诊断方法,此方法在不同工况下有良好的适应性和高效性,其中模型有较强的泛化能力。

但深度学习需要大量的标签样本进行训练,而在实际工况中滚动轴承有标签的故障样本较少,大部分学者都是通过模拟故障实验来获得数据集的。迁移学习解决了故障样本不足的问题,不仅缩短了训练时间,而且提高了训练精度^[8]。院老虎等^[9]提出了一种基于 AlexNet 和迁移学习的滚动轴承故障诊断方法,在标记故障数据稀缺的情况下仍可实现对滚动轴承常见故障类型的诊断,且诊断精度与对比模型相比有所提升。赵宇凯等^[10]提出一种基于 VGG16 卷积神经网络与迁移学习的故障诊断方法,能够取得接近 100% 的轴承故障诊断准确率。Qian 等^[11]提出了基于改进的 DenseNet 和联合分布适应 (FT-IDJ) 的特征迁移学习模型,具有比 DAN 和其他 8 种方法更高的分类精度,证明了此模型具有从辅助数据中有效学习的特征。

但以上方法没有考虑到工厂实际采集的数据中存在的噪声。针对环境噪声以及负载变化的影响,滚动轴承故障样本分布存在差异性以及样本不足和跨域诊断泛化性差的问题,课题组提出一种基于改进 DenseNet 与迁移学习结合的变负载滚动轴承故障诊断

方法。在原 DenseNet 中,使用 LeakyReLU 替代 ReLU 激活函数,并在全连接层后添加 Softmax 层使提取故障特征更为丰富。

1 理论基础

1.1 DenseNet 原理

DenseNet 如图 1 所示,主要是由稠密连接块和过渡层组成的^[12]。其中稠密连接块使用了密集连接的思想,即将每一层的特征输出通过叠加后作为下一层的输入,其公式如下:

$$t_i = H_i[t_0, t_1, \dots, t_{i-1}]。 \quad (1)$$

式中: i 表示此网络的第 i 层; $H_i(\cdot)$ 表示每一层的非线性变化处理,包括归一化、非线性变化、卷积和池化操作; t_i 表示第 i 层的输出特征。




图 1 DenseNet 结构图

Figure 1 DenseNet structure diagram

而过渡层中包括归一化操作、非线性变化以及卷积池化层,可以压缩模型,起到降维的作用。

1.2 LeakyReLU 激活函数

不同于 ReLU 函数将所有负值都设为 0, LeakyReLU^[13] 激活函数是在负值部分的斜率赋予了一个非零的斜率,公式为:

$$f(x) = \begin{cases} ax, & x \geq 0; \\ x, & x < 0. \end{cases} \quad (2)$$

式中: x 为输入, a 取默认值 0.01。

课题组采用 LeakyReLU 替代 ReLU 函数,加强非线性变化能力。

2 故障诊断方法

故障诊断流程如图 2 所示。主要分为 3 个步骤:

- 1) 确定源域和目标域,将 2 域数据转化为灰度图像;
- 2) 对源域数据进行预训练,得到损失最小和准确率最高的预训练模型权重;

3) 将目标域数据按 1:4 划分为训练集和测试集,使用步骤 2) 得到的预训练权重对目标域数据进行再训练得到权重文件,在测试集进行测试输出故障分类。




图 2 迁移学习流程图

Figure 2 Flow chart of transfer learning

课题组提出的故障诊断方法是基于改进 DenseNet 模型进行诊断的,其主要参数如表 1 所示。首先对 64×64 图像样本进行卷积层和池化层处理,再通过 4 个稠密连接块和 3 个过渡层堆叠的结构来防止过拟合,同时提取特征;其中稠密连接块包括不同个数的 1×1 和 3×3 卷积,而过渡层中包含 1×1 卷积和 2×2 的平均池化,然后经过全局平均池化和全连接层拉伸为一维向量,最后使用 Softmax 层进行分类后输出。

3 实验部分

3.1 数据集划分

实验采用凯斯西储大学(CWRU)滚动轴承故障数据集。在 CWRU 滚动轴承实验台采集的振动信号中,有 0.18, 0.36 和 0.54 mm 共 3 种不同尺寸的单点缺陷,分别在滚动轴承的内圈、外圈和滚动体上;这 9 种故障类型由电火花造成的,故障标签序号为 0 ~ 8,无故障轴承标签序号为 9,如表 2 所示。还分别记录了电机负载为 746, 1 492 和 2 238 W 时各种故障类型的时域振动信号。在 12 kHz 采样频率下,由 16 通道采集仪采集到不少于 10 s 的时域振动原始信号。

在工厂实际情况下,传感器采集的振动信号会受到环境噪声的影响,为了模拟这一现状,对 746, 1 492 和 2 238 W 的 3 种不同电机负载下的数据集进行加噪处理,信噪比(R_{SN})定义为信号功率与噪声功率的比值,通常用分贝(dB)为单位,定义如下:

表 1 改进 DenseNet 模型参数

Table 1 Parameters of improved DenseNet model

类型	输出尺寸	参数
卷积层	$32 \times 32 \times 64$	卷积 7×7 , 步长 2
池化层	$16 \times 16 \times 64$	最大池化 3×3 , 步长 2
稠密连接块 1	$16 \times 16 \times 256$	$\left(\begin{matrix} \text{卷积 } 1 \times 1 \\ \text{卷积 } 3 \times 3 \end{matrix} \right) \times 6$
过渡层 1	$16 \times 16 \times 128$ $8 \times 8 \times 128$	卷积 1×1 平均池化 2×2 , 步长 2
稠密连接块 2	$8 \times 8 \times 512$	$\left(\begin{matrix} \text{卷积 } 1 \times 1 \\ \text{卷积 } 3 \times 3 \end{matrix} \right) \times 12$
过渡层 2	$8 \times 8 \times 256$ $4 \times 4 \times 256$	卷积 1×1 平均池化 2×2 , 步长 2
稠密连接块 3	$4 \times 4 \times 1\,024$	$\left(\begin{matrix} \text{卷积 } 1 \times 1 \\ \text{卷积 } 3 \times 3 \end{matrix} \right) \times 24$
过渡层 3	$4 \times 4 \times 512$ $2 \times 2 \times 512$	卷积 1×1 平均池化 2×2 , 步长 2
稠密连接块 4	$2 \times 2 \times 1\,024$	$\left(\begin{matrix} \text{卷积 } 1 \times 1 \\ \text{卷积 } 3 \times 3 \end{matrix} \right) \times 16$
池化层	$1 \times 1 \times 1\,024$	全局平均池化 7×7
全连接层	1×10	—
Softmax	10	—

表 2 故障数据标签

Table 2 Fault data labels

故障	内圈缺陷/mm			外圈缺陷/mm			滚动体缺陷/mm			正常
标签	0.18	0.36	0.54	0.18	0.36	0.54	0.18	0.36	0.54	0.00
序号	0	1	2	3	4	5	6	7	8	9

$$R_{SN} = 10 \lg \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right). \quad (3)$$

式中, P_{signal} 和 P_{noise} 分别表示信号的功率和噪声的功率。

如图 3 所示,分别为原始数据和添加 $R_{SN} = -2$ dB 的高斯白噪声。

假设样本 $x = (x_1, x_2, x_3, \dots, x_m, \dots)$, μ 为原始样本数据的均值, σ 为原始样本数据的标准差,则 Z-Score 归一化公式为:

$$x^* = \frac{(x - \mu)}{\sigma}. \quad (4)$$

将加噪信号经过 Z-Score 归一化处理,将数据量级统一到规定的范围内。在每个负载下,将振动原始信号中每取 4 096 个点分别以重叠间隔 128, 256 和 512 个采样点的方式循环生成 3 600 个 64×64 的灰度图像,实验数据集如表 3 所示。




图3 不同负载下的噪声数据对比

Figure 3 Comparison of noise data under different loads


表3 实验数据集

Table 3 Experimental data set


数据集	R_{SN}/dB	功率/ N	样本数
A	-2	746	3 600
B	-2	1 492	3 600
C	-2	2 238	3 600

3.2 变负载下迁移学习实验

实验在 PyTorch 的框架下开发,使用 Intel(R) Core (TM) i9-10900X CPU (主频 3.70 GHz), NVIDIA RTX2080ti 显卡,主机上安装了 CUDA10.2, Cudnn8.1.1 对显卡运算进行加速。使用交叉熵函数和 Adam 优化器更新参数,学习率初始化为 0.001, batchsize 为 16。如图 4 采用 100% 的源域数据集 A 进行预训练,随机选取 20% 目标域数据集 B 和 C 进行再训练,对剩下的目标域数据进行测试。从图中可以看出,经过预训练权重进行再训练后,模型很快达到了收敛。



(a) 训练曲线



(b) 损失曲线

图4 迁移学习下的诊断曲线

Figure 4 Diagnostic curve under transfer learning

如图 5 所示为数据集 A 在数据集 B 和 C 进行迁移诊断的混淆矩阵。从图 5 中可以看出,对角线的方法

块显示了诊断正确样本数量的准确率,其他方块显示了诊断错误样本数量的准确率。可以看出在数据集 *B* 上,除了标签序号 4,其余标签诊断准确率都达到了

90% 以上;而在数据集 *C* 上,除了标签序号 2 和 3,其余标签诊断准确率都达到了 90% 以上,证明了该方法的有效性。




图5 数据集 *A* 在数据集 *B* 和 *C* 上进行迁移的混淆矩阵

Figure 5 Confusion matrix for migration of dataset *A* on datasets *B* and *C*

为了证明课题组提出方法的泛化性,对任一负载下 100% 的源域数据集进行预训练,随机选取其他负载下的 20% 目标域数据集进行再训练,对剩下的目标域数据集进行测试。通过对比模型 LeNet-5^{[3]56}、模型 ResNet18 以及原 DenseNet 模型来进行迁移学习实验,实验结果为每组实验 5 次的平均值,如图 6 所示。从图中可以看出,课题组提出方法在小样本和变负载下的跨域诊断准确率都达到了 90% 以上,相比其他模型精度都高,证明了课题组提出方法具有更高的泛化性。

4 结论

课题组针对工厂中滚动轴承故障样本不足以及变负载轴承故障分布差异大而导致跨域诊断泛化性差的问题,提出了一种基于改进 DenseNet 和迁移学习的变负载滚动轴承故障诊断方法。课题组对原 DenseNet 模型进行了改进,使用 LeakyReLU 替换了 ReLU 激活函数增强非线性变化,添加了 Softmax 层进行分类。在工厂采集的振动信号往往存在环境干扰的噪声,因此通过在凯斯西储大学轴承数据集中 746,1 492 和 2 238 W 不同负载数据集上添加高斯白噪声来模拟现




图6 变负载下迁移学习的模型准确率

Figure 6 Model accuracy of transfer learning under load changes

实场景采集的信号。通过实验表明:对比 LeNet-5 模型^{[3]57}、ResNet18 模型、原 DenseNet 模型,课题组所提方法在小样本的故障数据训练下,变负载跨域诊断准确率都达到了 90% 以上,证明了改进 DenseNet 模型具有较好的泛化性。该方法可以适用添加较低噪声的故

障数据,考虑到现实场景的环境噪声更为复杂,下一步将针对于该方法的鲁棒性作研究重点。

参考文献:

- [1] LIU Z P,ZHANG L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings[J]. Measurement,2020,149:107002.
- [2] LEI Y G,YANG B,JIANG X W, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap [J]. Mechanical Systems and Signal Processing,2020,138:106587.
- [3] 吴晨芳,杨世锡,黄海舟,等. 一种基于改进的 LeNet-5 模型滚动轴承故障诊断方法研究[J]. 振动与冲击,2021,40(12):55-61.
- [4] 王太勇,官立明,王鹏,等. 基于 KD-DenseNet 的旋转机械故障诊断模型[J]. 振动与冲击,2020,39(16):39-45.
- [5] CHE C C,WANG H W,FU Q, et al. Intelligent fault prediction of rolling bearing based on gate recurrent unit and hybrid autoencoder [J]. Journal of Mechanical Engineering Science,2021,235(6):1106-1114.
- [6] GAO S Z,XU L T,ZHANG Y M, et al. Rolling bearing fault diagnosis based on intelligent optimized self-adaptive deep belief network[J]. Measurement Science and Technology,2020,31(5):055009.
- [7] 曹正志,叶春明. 改进 CNN-LSTM 模型在滚动轴承故障诊断中的

应用[J]. 计算机系统应用,2021,30(3):126-133.

- [8] YANG B, LEI Y G, JIA F, et al. An intelligent fault diagnosis approach based on transfer learning from laboratory bearings to locomotive bearings[J]. Mechanical Systems and Signal Processing, 2019,122:692-706.
- [9] 院老虎,陈源强,杜白雨,等. 基于 AlexNet 和迁移学习的滚动轴承故障诊断研究[J]. 机电工程,2021,38(8):1016-1022.
- [10] 赵宇凯,徐高威,刘敏. 基于 VGG16 迁移学习的轴承故障诊断方法[J]. 航天器环境工程,2020,37(5):446-451.
- [11] QIAN C H, JIANG Q S, SHEN Y H, et al. An intelligent fault diagnosis method for rolling bearings based on feature transfer with improved DenseNet and joint distribution adaptation [J]. Measurement Science and Technology,2021,33(2):025101.
- [12] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu: IEEE, 2017: 4700-4708.
- [13] ZHANG X H, ZOU Y X, SHI W. Dilated convolution neural network with LeakyReLU for environmental sound classification[C]//2017 22nd international conference on digital signal processing (DSP). London: IEEE, 2017:1-5.

(上接第 52 页)

单、稳定性好、加工过程无人化、可以实时监控加工状态与设备运行状态等功能,对其他的线束加工设备设计有一定的借鉴作用。该控制系统尚缺乏实时准确的反馈系统,不具备参数的自我调节能力,这是今后需要继续改进的方面。

参考文献:

- [1] 王姝骐. 低碳环保背景下我国新能源汽车的发展现状及发展前景[J]. 时代汽车,2022(8):110-112.
- [2] 杨桂林,王明娣,杜秋. 并排导线激光自动剥离装置的设计与分析[J]. 机械设计与研究,2016,32(1):126-128.
- [3] 刘建. 基于 PLC 的磨线机和剥线机控制系统的设计与实现[D]. 桂林:广西师范大学,2008:38-39.
- [4] 闻丽燕,周洪昌. 台式剥线机的开发[J]. 制造业自动化,2015,37(22):153-156.
- [5] 马欣,方喜峰,李治多. 基于 PLC 的四刀光阑自动控制系统设计[J]. 制造业自动化,2021,43(9):97-100.

- [6] 李友堂,白锐,李强,等. 基于 PLC 的药芯焊丝成型机自动控制系统的开发和设计[J]. 制造业自动化,2022,44(1):99-103.
- [7] 单根立,董沛森. 基于 PLC 控制的多芯电缆全自动剥线设备设计及研究[J]. 液压与气动,2019(8):116-120.
- [8] 王文立. 基于 PLC 的种子烘干机自动控制系统设计[J]. 农机化研究,2023,45(4):225-228.
- [9] 张哲成. 基于 PLC 的粮食扦样机控制系统的设计与试验[D]. 合肥:安徽农业大学,2021:8-10.
- [10] 张辰贝西,贾爱梅. 基于松下 PLC 的全自动微生物样本处理系统设计与实现[J]. 机械设计与制造工程,2021,50(10):49-53.
- [11] 贺安民,原长锁,卢熠昌,等. 基于 PLC 的全断面矩形快速掘进机电气控制系统的设计[J]. 煤矿机械,2021,42(11):180-183.
- [12] 朱志豪,李阳,陈再良. 机床润滑剂制备工艺 PLC 控制系统的设计[J]. 制造业自动化,2017,39(6):27-30.
- [13] 武永强,于涛. 触摸屏在伺服电机控制系统中的应用[J]. 机械工程与自动化,2021(6):157-159.
- [14] 王光祥. 基于触摸屏和 PLC 的物料智能分拣控制系统设计[J]. 集成电路应用,2021,38(12):26-28.