

基于 Inception v3 的印刷设备轴承故障智能诊断方法研究

胡兵兵^a, 唐嘉辉^b, 武吉梅^a

(西安理工大学 a.印刷包装与数字媒体学院 b.机械与精密仪器工程学院, 西安 710048)

摘要: **目的** 轴承作为印刷设备中的旋转核心元件, 其运行状态对印刷设备的健康监测作用较大。通过融合小波时频处理与 Inception v3 模型的优势, 提出一种用于印刷设备轴承故障智能诊断方法。**方法** 利用 Morlet 小波对采集到的印刷设备轴承原始振动信号进行处理, 得到对应的二维时频图像, 从时域和频域两方面对轴承故障进行表征; 将时频图像作为 Inception v3 模型的输入, 利用其模型的稀疏特性, 快速从时频图像中自动学习故障特征, 并对其模型参数进行调整; 最后, 利用训练好的模型实现印刷设备轴承故障诊断。**结果** 利用印刷设备轴承实验平台对提出方法的有效性进行了验证, 实验结果表明该方法的平均诊断精度可达 92.53%。**结论** 与传统智能诊断方法相比, 所提方法在诊断精度与稳定性方面均具有一定的优势, 可实现高精度印刷设备轴承故障诊断。

关键词: Morlet 小波; Inception v3 模型; 轴承; 故障诊断

中图分类号: TS803⁺.6 **文献标识码:** A **文章编号:** 1001-3563(2022)13-0189-07

DOI: 10.19554/j.cnki.1001-3563.2022.13.024

An Intelligent Fault Diagnosis Method Based on Inception v3 for Printing Press Bearing

HU Bing-bing^a, TANG Jia-hui^b, WU Ji-mei^a

(a. School of Printing, Packaging Engineering and Digital Media Technology b. School of Mechanical and Precision Instrument Engineering, Xi'an University of Technology, Xi'an 710048, China)

ABSTRACT: As a core rotating component in printing press, the operation status of bearing plays a major role in the health monitoring of printing press. The work aims to propose an intelligent diagnosis method of bearing faults in printing press by mixing the advantages of wavelet time-frequency processing with the Inception v3 model. The Morlet wavelet was used to process the raw vibration signals collected from bearing, and the corresponding two-dimensional time-frequency images were obtained to characterize the bearings faults from the time-domain and frequency-domain. The time-frequency images were used as input of the Inception v3 model, and the filter-level sparsity of the Inception v3 model was used to quickly and automatically learn the fault features from the time-frequency images and adjust the model parameters; finally, the trained model was used to implement the fault diagnosis of printing press bearing. The effectiveness of the proposed method was verified with a printing press experimental platform, and the results indicated that the average diagnostic accuracy of the method can reach 92.53%. Compared with traditional intelligent diagnosis methods, the proposed method has higher diagnosis accuracy and stability to achieve the bearings fault diagnosis of high-precision printing press.

KEY WORDS: Morlet wavelets; Inception v3 model; bearing; fault diagnosis

收稿日期: 2021-08-10

基金项目: 国家自然科学基金 (51705420, 52075435); 陕西省自然科学基金基础研究计划 (2020JQ-630, 20JY054); 西安理工大学博士学位论文创新基金 (252072105)

作者简介: 胡兵兵 (1983—), 男, 博士, 西安理工大学讲师, 主要研究方向为机械故障诊断。

随着现代印刷企业的生产效率不断提高,轴承作为印刷设备中重要的旋转核心元件,在长期高速运转情况下容易产生不同程度的损伤^[1-2]。如果不能及时发现轴承故障,轻则造成整个印刷设备无法正常运行以致影响印品质量,重则导致设备损坏,造成经济损失,甚至人身安全事故^[3-4],因此,如何有效实现印刷设备轴承故障诊断是保障印刷设备长期高速可靠运行的关键问题。

在传统的轴承故障诊断研究中,其主要方法是利用信号处理技术对采集到的振动信号进行分析,去除冗余成分并提取出可以反映故障特征的信息,从而实现轴承故障诊断。这类方法在故障诊断研究初期表现出了较好的效果,但是随着人们对生产效率的要求日益提升,印刷设备的规模也随之不断扩大,需要采集设备信号的数据量与采样频率都在不断提高,导致收集到的包含设备运转状态的信号趋于“海量”,使得传统故障诊断方法在面对这种情况时诊断效果不佳^[5]。随着人工智能理论的迅速发展,诸如支持向量机(SVM)、逻辑回归等浅层结构算法在故障诊断领域的应用越来越广泛。由于印刷设备的机械结构复杂度不断提升,多部件耦合振动产生的振动信号中的有用信息常被强噪声背景所淹没,导致上述浅层模型无法准确提取出轴承故障的特征信息^[6-8],因此,亟待研究新的改进方法用来有效检测隐藏在印刷设备大量振动信号中的轴承故障特征。

因其优越的大数据处理及自适应特征提取能力,深度学习算法的出现解决了传统故障诊断方法中手动选择特征的不足,使得其在机械故障诊断领域得到了广泛的应用。邵海东等^[9]在传统故障诊断研究中引入了深度迁移自动编码器,该方法在不同设备之间实现了高精度故障识别。Wen等^[10]提出了一种基于卷积神经网络的故障诊断方法,实验结果表明该方法诊断精度相较于其他故障诊断方法有了较为明显地提升。Jia等^[11]提出了一种基于深度归一化卷积神经网络的故障诊断方法,实验结果表明该方法相较于一般的卷积神经网络取得了更佳的诊断精度。Jia等提出的方法通过直接在深度学习算法中输入采集到的原始振动信号,在一定程度上实现了较为精确的机械故障诊断。在印刷设备实际工作状况中,由于轴承内部的零部件之间存在相互作用,导致传感器采集到的振动信号信噪比较低,降低了深度学习算法提取故障特征的准确性,从而限制了深度学习算法在机械故障诊断领域的应用范围。为了解决此问题,文中通过选用在时频域均具有良好分辨率的 Morlet 小波对采集到的印刷设备轴承振动原始信号进行预处理,将它转换为二维时频图,从而增强了原始信号的特征信息。随后,采用卷积神经网络的典型变体之一 Inception v3 网络对其时频谱中的故障特征进行学习。由于该网络在传统卷积神经网络模型中引入了分解卷积的思想,不仅

具有密集矩阵的高计算性能,又保持了滤波器级别的稀疏特性,可从轴承振动信号时频图中自适应的学习到反映故障特征的有用信息,也能获得故障特征与故障类别之间的非线性映射关系。正是基于小波时频图和 Inception v3 网络的各自优势,文中提出的印刷设备轴承故障智能诊断方法可实现强噪声背景下轴承故障的精确识别,实验结果表明所提方法与其他传统智能故障诊断方法相比具有更好的识别精度和诊断效率。

1 信号预处理

轴承作为印刷设备中连接固定部件与旋转部件的“关节”,在实际运行过程中,会承受来自与之相关的各部件的激励,导致轴承故障信号在这些干扰源的影响下呈现出非平稳、非线性和低信噪比的特点。传统的傅里叶变换无法对轴承故障信号中的任意时刻内的频率成分进行表征,难以满足轴承故障微弱特征提取的需求。小波变换因具有多分辨率的特性,使得信号分解后在低频部分具有较高的频率分辨率和较低的时间分辨率,在高频部分具有较高的时间分辨率和较低的频率分辨率,从本质上解决了传统傅里叶变换无法提供任何局部时间段上频率信息的不足^[12-13]。由于 Morlet 小波的时域波形与轴承故障信号的冲击特征较为相似,能够很好地实现它与故障信号在时间和频率分辨率之间的匹配^[14],因此,文中选择 Morlet 小波对印刷设备轴承振动信号进行预处理。

Morlet 小波可以定义为:

$$\psi_{\sigma}(t) = C_{\sigma} \pi^{-\frac{1}{4}} e^{-\frac{1}{2}t^2} \left(e^{i\sigma t} - \kappa_{\sigma} \right) \quad (1)$$

式中: $\psi_{\sigma}(t)$ 为 Morlet 小波的波形振幅曲线; σ 为无量纲频率; C_{σ} 为归一化因子; κ_{σ} 为小波的容许准则。

Morlet 小波的傅里叶变换表达式可表示为:

$$\hat{\psi}_{\sigma}(\omega) = C_{\sigma} \pi^{-\frac{1}{4}} \left(e^{-\frac{1}{2}(\omega-\sigma)^2} - \kappa_{\sigma} e^{-\frac{1}{2}\omega^2} \right) \quad (2)$$

由于 σ 为无量纲频率,将归一化因子设置为 1,其傅里叶变换表达式可简化为:

$$\hat{\psi}_{\sigma}(\omega) = \pi^{-\frac{1}{4}} e^{-\frac{1}{2}(\omega-\sigma)^2} \quad (3)$$

为了保证 Morlet 小波在不同缩放因子下均具有可比性,对小波函数进行归一化使其具有相同的单位能量。

$$\hat{\psi}(s\omega_k) = \left(\frac{2\pi s}{\delta t} \right)^{-\frac{1}{4}} \hat{\psi}_{\sigma}(s\omega_k) \quad (4)$$

$$\sum_{k=0}^{N-1} |\hat{\psi}(s\omega_k)|^2 = N \quad (5)$$

式中: $\hat{\psi}(s\omega_k)$ 为经过 Morlet 小波变换后的结果; N 为频率索引; ω_k 为频率分量。

2 卷积神经网络与 Inception v3

借助深度学习方法实现轴承故障诊断的研究已屡见不鲜, 当遇到因数据噪声过大引起模型精度下降问题时, 传统基于深度学习的故障诊断方法一般会通过增加模型深度或宽度改善这种情况, 但这种形式易造成模型的参数量激增。此外, 太深层的模型同样会带来严重的过拟合问题, 从而导致模型性能降低。在传统卷积神经网络基础上提出的 Inception v3 模型解决了上述问题, 该模型利用 Inception module、分解卷积等一系列操作增加了模型的深度与宽度, 但参数量仅为同深度 Alexnet 的 $1/12^{[15]}$ 。Inception module 的基本结构见图 1, 该结构存在 4 个主要分支, 每个分支均存在 1×1 的卷积核, 该操作能对输出特征进行降维处理, 增加模型的特征表达能力。同时, 多种尺寸的卷积核从不同尺度方面增加了模型的特征适应能力。




图 1 Inception module 基本结构
Fig.1 Basic structure of Inception module

分解卷积核的主要思想是将单个卷积核分解为 2 个或多个卷积核。该操作在增加网络的宽度与深度的同时, 减少了参数的增长量。传统卷积方法中尺寸较大的卷积核虽然具有较好的感受野, 但在运算的过程中容易丢失部分重要的特征, 并会引入极大的参数量。采用分解卷积将单个卷积核分解为多个小卷积核, 在不改变感受野的情况下降低了参数量, 此外多个卷积核共同作用相当于为模型增加了多个激活函

数, 提升了模型的非线性表征能力。如图 2 和图 3 所示, 引入 Inception module 中的分解卷积主要存在对称分解与非对称分解 2 种形式, 分别在不改变感受野大小的情况下降低了大约 28% 和 33% 的网络模型参数量。文中所采用的网络结构参数见表 1, 其中关于 Inception module 更详细的架构可参考文献[15]。




图 2 对称式分解卷积
Fig.2 Symmetric decomposition convolution

3 基于 inception v3 的印刷设备轴承故障诊断方法

印刷设备作为一种专用功能的旋转设备, 由于其结构构成种类众多和振动传递路径复杂等因素影响, 导致其采集到的振动信号常表现出非平稳、非线性和低信噪比的特性。为了更好地表征振动信号的故障特征, 文中首先采用 Morlet 小波对原始振动信号进行预处理, 从而得到振动信号的二维时频图。然后, 将其作为训练数据, 可有效提高后续智能故障诊断模型精度。此外, 研究过程中引入了 Inception v3 模型对时频图图像特征进行学习, 通过 Inception module、分解卷积带来的高效特征学习与快速训练能力可实现印刷设备轴承高精度故障诊断。结合小波时频处理与 Inception v3 模型的印刷设备轴承故障诊断方法流程见图 4, 其详细步骤如下。




图 3 非对称式分解卷积
Fig.3 Asymmetric decomposition convolution

表 1 文中方法结构参数
Tab.1 Structure parameters of proposed method

结构名称	输出维数
输入层	(200,200,3)
卷积层 1	(99,99,32)
卷积层 2	(97,97,32)
卷积层 3	(97,97,64)
最大池化层 1	(48,48,64)
卷积层 4	(48,48,80)
卷积层 5	(46,46,192)
最大池化层 2	(22,22,192)
Inception module A	(22,22,256)
2*Inception module A	(22,22,288)
Inception module D	(10,10,768)
4*Inception module B	(10,10,768)
Inception module E	(4,4,1 280)
2*Inception module C	(4,4,2 048)
线性激活层	2 048
Dropout 层	1 024
输出层	10




图 4 基于 Inception v3 的印刷设备轴承故障诊断方法流程

Fig.4 Flow chart of fault diagnosis method of printing press bearing based on Inception v3

1) 使用信号采集设备收集印刷设备运行过程中所产生的轴承振动信号。

2) 利用 Morlet 小波对原始振动信号进行预处理, 得到相应的轴承振动信号时频图。

3) 初始化 Inception v3 网络模型参数, 设置其学习率为 0.04, 迭代次数为 20, 学习动量为 0.99。

4) 将获取到的振动信号时频图输入到 Inception v3 网络模型中, 采用随机梯度算法对它进行优化, 从而获得最优模型参数, 输出 Inception v3 模型, 并通过未知类别数据集对其进行测试。

5) 记录测试结果, 更新印刷设备健康状态。

4 实验分析

4.1 实验数据

为了验证所提方法的有效性, 文中搭建了 FR400 凹印机轴承故障诊断实验平台, 见图 5。该实验平台

的测试对象为输纸芯轴一端的滚动轴承, 实验过程中所使用的轴承包含内圈、外圈、保持架等 3 种典型故障类型和正常状态 4 种情况。为了体现文中方法的鲁棒性, 每种故障类型分别具有 0.2、0.4、0.6 mm 等 3 种不同程度的损伤。在测试过程中, 利用压电式加速度传感器对其振动信号进行收集, 采样频率设置为 12 kHz。3 种典型故障类型下收集到的凹印机轴承振动信号时域波形, 以及经过 Morlet 小波处理后的小波时频图见图 6。将已知的原始振动信号小波时频图以 7:3 的比例进行分组, 可获得用于所提方法网络模型训练过程中的训练集与测试集。




图 5 凹印机轴承故障诊断实验平台

Fig.5 Experimental platform of gravure press bearing fault diagnosis

4.2 结果分析

将凹印机轴承振动信号小波时频图输入到 Inception v3 网络模型后获得的一次实验迭代过程中的误差曲线与准确率曲线见图 7。从图 7 中可以看出, 随着迭代次数的升高, 误差呈逐渐下降的趋势, 而诊断精度逐渐上升, 最终稳定在 93% 左右。分析结果表明, 文中提出的基于 Inception v3 模型的印刷设备轴承故障诊断方法可从时频图像中逐步提取出与故障特征相关的有用信息。为了测试提出方法的性能, 将 Alexnet 和支持向量机 (Support Vector Machine, SVM) 与文中方法进行对比。Alexnet 网络模型是与 Inception v3 具有相似结构的算法, 而 SVM 是浅层机器学习的代表算法之一。每组实验重复进行 5 次, 最终得到的详细实验结果见图 8。从图 8 中可以看出, 文中方法具有更高的精度和较好的稳定性。经过 5 次实验后得到的平均诊断结果见表 2。从表 2 中可以看出, 文中方法的平均诊断精度可达 92.53%, 高于 Alexnet (89.65%) 和 SVM (87.19%) 的诊断结果, 并且从均方误差可以看出, 文中方法相较于其他 2 种对比方法更为稳定。




图 6 凹印机轴承振动时域信号及其对应的时频图

Fig.6 Time domain vibration signal and time frequency spectrum of gravure press bearing




图 7 训练结果曲线

Fig.7 Training result curves




图 8 输入为时频图时, 3 种诊断方法分析结果对比
Fig.8 Comparison of analysis results of three diagnosis methods when time-frequency graph is input

表 2 输入为时频图时, 3 种方法的平均诊断结果
Tab.2 Average diagnosis results of three methods when time-frequency graph is input

方法	重复实验次数	测试样本数量	准确率/%	均方误差
Inception v3	5	1 152	92.53	0.37
Alexnet	5	1 152	89.65	0.51
SVM	5	1 152	87.19	0.44

5 结语

针对印刷设备轴承故障诊断问题, 文中提出了一种小波变换与 Inception v3 模型相结合的智能诊断方法。利用凹印机轴承故障诊断实验台对提出方法的有效性进行了验证, 分析结果可得出结论: 利用 Morlet 小波对原始振动信号进行处理后得到的时频图图像作为训练数据, 提高了后续智能故障诊断模型的精度; 具有分解卷积思想的 Inception v3 模型可以高效和准确地自适应学习原始振动信号时频图中包含的特征信息, 从而实现了轴承故障的精准诊断; 通过凹印机轴承诊断实验平台验证了提出方法的有效性, 实验结果表明所提方法能够有效识别出不同类型的轴承故障, 且相较于其他传统故障诊断方法具有更好的诊断精度和稳定性。

参考文献:

- [1] 赵庆海, 赵玮, 石玉霞. 现代故障诊断技术研究现状与趋势[J]. 包装工程, 2018, 39(15): 159-165.
ZHAO Qing-hai, ZHAO Wei, SHI Yu-xia. Present Situation and Trend of Modern Fault Diagnosis Technology[J]. Packaging Engineering, 2018, 39(15): 159-165.
- [2] 王国彪, 何正嘉, 陈雪峰, 等. 机械故障诊断基础研究“何去何从”[J]. 机械工程学报, 2013, 49(1): 63-72.
WANG Guo-biao, HE Zheng-jia, CHEN Xue-feng, et al. Basic Research on Machinery Fault Diagnosis—What is the Prescription[J]. Journal of Mechanical Engineering, 2013, 49(1): 63-72.
- [3] 邓瑞, 徐卓飞, 徐倩倩, 等. 基于声场图像分析的印刷机轴承故障诊断方法[J]. 包装工程, 2018, 39(9): 151-157.
DENG Rui, XU Zhuo-fei, XU Qian-qian, et al. Fault Diagnosis Method of Printing Press Bearings Based on Image Analysis of Sound Field[J]. Packaging Engineering, 2018, 39(9): 151-157.
- [4] JIA Feng, LEI Ya-guo, LIN Jing, et al. Deep Neural Networks: A Promising Tool for Fault Characteristic Mining and Intelligent Diagnosis of Rotating Machinery with Massive Data[J]. Mechanical Systems and Signal Processing, 2016, 72/73: 303-315.
- [5] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
LEI Ya-guo, JIA Feng, ZHOU Xin, et al. A Deep Learning-Based Method for Machinery Health Monitoring with Big Data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [6] CHEN Jing-long, ZI Yan-yang, HE Zheng-jia, et al. Compound Faults Detection of Rotating Machinery Using Improved Adaptive Redundant Lifting Multiwavelet [J]. Mechanical Systems and Signal Processing, 2013, 38(1): 36-54.
- [7] 汤芳, 刘义伦, 龙慧. 稀疏自编码深度神经网络及其在滚动轴承故障诊断中的应用[J]. 机械科学与技术, 2018, 37(3): 352-357.
TANG Fang, LIU Yi-lun, LONG Hui. Application of Deep Neural Network with Sparse Auto-Encoder in Rolling Bearing Fault Diagnosis[J]. Mechanical Science and Technology for Aerospace Engineering, 2018, 37(3): 352-357.
- [8] 李恒, 张氢, 秦仙蓉, 等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J]. 振动与冲击, 2018, 37(19): 124-131.
LI Heng, ZHANG Qing, QIN Xian-rong, et al. Fault Diagnosis Method for Rolling Bearings Based on Short-Time Fourier Transform and Convolution Neural Network[J]. Journal of Vibration and Shock, 2018, 37(19): 124-131.
- [9] 邵海东, 张笑阳, 程军圣, 等. 基于提升深度迁移自动编码器的轴承智能故障诊断[J]. 机械工程学报, 2020, 56(9): 84-90.
SHAO Hai-dong, ZHANG Xiao-yang, CHENG Jun-sheng, et al. Intelligent Fault Diagnosis of Bearing Using Enhanced Deep Transfer Auto-Encoder[J]. Journal of Mechanical Engineering, 2020, 56(9): 84-90.

- [10] WEN Long, LI Xin-yu, GAO Liang, et al. A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [11] JIA Feng, LEI Ya-guo, LU Na, et al. Deep Normalized Convolutional Neural Network for Imbalanced Fault Classification of Machinery and Its Understanding via Visualization[J]. Mechanical Systems and Signal Processing, 2018, 110: 349-367.
- [12] 冯志鹏, 刘立, 张文明, 等. 基于小波时频框架分解方法的滚动轴承故障诊断[J]. 振动与冲击, 2008, 27(2): 110-114.
- FENG Zhi-peng, LIU Li, ZHANG Wen-ming, et al. Fault Diagnosis of Rolling Element Bearings Based on Wavelet time-Frequency Frame Decomposition[J]. Journal of Vibration and Shock, 2008, 27(2): 110-114.
- [13] 高强, 何正嘉. 谐波小波及其时频剖面图在旋转机械诊断中的应用[J]. 西安交通大学学报, 2000, 34(9): 62-66.
- GAO Qiang, HE Zheng-jia. Application of Harmonic Wavelet and Its Time-Frequency Profile Plot to Diagnosis of Rotating Machinery[J]. Journal of Xi'an Jiaotong University, 2000, 34(9): 62-66.
- [14] DAUBECHIES I, HEIL C. Ten Lectures on Wavelets[J]. Computers in Physics, 1992, 6(6): 697.
- [15] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the Inception Architecture for Computer Vision[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016: 2818-2826.

责任编辑: 曾钰婵