



基于FFT和CNN的滚动轴承故障诊断方法

尹文哲, 夏虹, 彭彬森, 朱少民, 王志超

引用本文:

尹文哲, 夏虹, 彭彬森, 等. 基于FFT和CNN的滚动轴承故障诊断方法[J]. 应用科技, 2021, 48(6): 97-101.

YIN Wenzhe, XIA Hong, PENG Binsen, et al. A fault diagnosis method of rolling bearing based on FFT and CNN[J]. *Applied science and technology*, 2021, 48(6): 97-101.

在线阅读 View online: <https://dx.doi.org/10.11991/yykj.202101004>

您可能感兴趣的其他文章

Articles you may be interested in

基于PCA-RF的永磁电机故障诊断

Fault diagnosis of permanent magnet motor based on PCA-RF

应用科技. 2021, 48(6): 90-96 <https://dx.doi.org/10.11991/yykj.202103024>

基于小波神经网络的燃气轮机故障诊断研究

Research on fault diagnosis of gas turbine based on wavelet analysis and BP neural network

应用科技. 2019, 46(4): 11-15 <https://dx.doi.org/10.11991/yykj.201811025>

基于小波包和SOM神经网络的电作动器故障诊断

Fault diagnosis of electromechanical actuator based on wavelet packet and SOM neural network

应用科技. 2018, 45(1): 1-6 <https://dx.doi.org/10.11991/yykj.201706023>

小波预处理的神经网络在轴承故障诊断中的应用

Application of the neural network to the bearing fault diagnosis based on wavelet preprocessing

应用科技. 2016, 43(6): 78-81 <https://dx.doi.org/10.11991/yykj.201603003>

核电站故障诊断与故障程度评估方法

Fault diagnosis and fault degree evaluation in nuclear power plant

应用科技. 2016, 43(4): 1-5 <https://dx.doi.org/10.11991/yykj.201508032>

基于遗传算法优化的相关向量机的燃机涡轮叶片故障诊断

Fault diagnosis s for gas turbine blades based on the relvea nce vector machine optimized by genetic algorithm

应用科技. 2016, 43(2): 70-74 <https://dx.doi.org/10.11991/yykj.201506026>



微信公众平台



期刊网址

DOI: 10.11991/ykj.202101004

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1191.U.20210611.1309.010.html>

基于 FFT 和 CNN 的滚动轴承故障诊断方法

尹文哲^{1,2}, 夏虹^{1,2}, 彭彬森^{1,2}, 朱少民^{1,2}, 王志超^{1,2}

1. 哈尔滨工程大学 核安全与先进核能技术工信部重点实验室, 黑龙江 哈尔滨 150001

2. 哈尔滨工程大学 核安全与仿真技术国防重点学科实验室, 黑龙江 哈尔滨 150001

摘 要: 为提高滚动轴承故障诊断的识别准确率、摆脱信号处理方法对专家经验的过度依赖, 提出一种基于快速傅里叶变换 (FFT) 和卷积神经网络 (CNN) 的滚动轴承故障诊断方法。即对滚动轴承原始振动信号进行快速傅里叶变换, 再将得到的一维数据转变为二维的特征图, 输入到 ResNet-18 网络中进行学习训练, 以实现滚动轴承的故障诊断。通过与其他几种输入方法进行对比分析, 验证了该方法的有效性以及优越性。实验结果表明该方法诊断准确率高、收敛速度快, 并且信号处理过程不需要设定相关预定义参数, 摆脱了对专家经验的过度依赖。

关键词: 滚动轴承; 故障诊断; 深度学习; 卷积神经网络; 残差网络; 振动信号; 快速傅里叶变换; ResNet-18 网络

中图分类号: TL364

文献标志码: A

文章编号: 1009-671X(2021)06-0097-05

A fault diagnosis method of rolling bearing based on FFT and CNN

YIN Wenzhe^{1,2}, XIA Hong^{1,2}, PENG Binsen^{1,2}, ZHU Shaomin^{1,2}, WANG Zhichao^{1,2}

1. Key Laboratory of Nuclear Safety and Advanced Nuclear Energy Technology, Ministry of Industry and Information Technology, Harbin Engineering University, Harbin 150001, China

2. Fundamental Science on Nuclear Safety and Simulation Technology Laboratory, Harbin Engineering University, Harbin 150001, China

Abstract: In order to improve the recognition accuracy of rolling bearing fault diagnosis, and get rid of the excessive dependence of signal processing methods on expert experience, a rolling bearing fault diagnosis method based on fast Fourier transform (FFT) and convolutional neural network (CNN) is proposed in this paper. The fast Fourier transform is performed on the original vibration signal of the rolling bearing, and then the obtained one-dimensional data is transformed into a two-dimensional feature map, which is input into the ResNet-18 network for learning and training, so as to realize the fault diagnosis of rolling bearing. Through comparative analysis with several other input methods, the effectiveness and superiority of this proposed method are verified. This method has high diagnostic accuracy and fast convergence speed, and the signal processing process in this method does not need to set relevant predefined parameters, thus getting rid of the excessive dependence on expert experience.

Keywords: rolling bearing; fault diagnosis; deep learning; convolutional neural network; residual network; vibration signal; FFT; ResNet-18

在核电厂中存在诸多旋转设备, 如电机、泵、风机、汽轮机等, 它们在核动力系统中扮演着重要的角色, 而滚动轴承是旋转设备中最常用的部件之一, 其对旋转设备完成预定功能起着至关重要的作用。但由于设计、制造、安装、工况等多方面因素, 滚动轴承也是最常出现故障的部件之

一。为确保核动力系统安全稳定运行, 对滚动轴承进行有效的故障诊断十分必要。

目前最常用的滚动轴承故障诊断方法是振动分析法, 即利用滚动轴承的振动信号进行故障诊断。针对该方法的研究主要集中在特征提取和模式识别 2 个方面: 首先利用信号处理方法, 如小波变换^[1]、希尔伯特-黄变换^[2]、局部均值分解^[3]、变分模态分解^[4]等, 提取原始振动数据的相关特征, 并构建特征向量; 然后利用机器学习算法, 如贝叶斯分类器^[5]、支持向量机^[6]、神经网络^[7]等, 对特征向量进行模式识别。虽然传统的滚动轴承故障

收稿日期: 2021-01-06. 网络出版日期: 2021-06-15.

基金项目: 国家自然科学基金项目 (51379046); 黑龙江省自然科学基金项目 (E2017023).

作者简介: 尹文哲, 男, 硕士研究生.

夏虹, 女, 教授, 博士生导师.

通信作者: 夏虹, E-mail: xiahong@hrbeu.edu.cn.

诊断方法已取得一定的效果,但其诊断模型表达能力有限,且较依赖于信号处理技术和专家经验。

近年来,深度学习已成为学术研究热点,为了增强故障诊断模型的表达能力,摆脱对专家经验的过度依赖,学者们开始研究将深度学习模型应用到滚动轴承故障诊断中,以追求更加良好的诊断效果。其中,研究最多的深度学习模型是卷积神经网络。卷积神经网络是一种监督学习算法,广泛应用于模式识别领域。目前,一般是将原始振动信号处理变换成时域图像、频域图像或时频图像,然后用卷积神经网络对这些图像进行诊断识别故障类型。HAN等^[8]将滚动轴承振动信号转换成时域图像,对图像进行相关处理后将其作为卷积神经网络的输入,以实现轴承故障类别的判定。李恒等^[9]对原始振动信号进行短时傅里叶变换,构造时频图样本,并将其作为卷积神经网络的输入,完成故障识别。袁建虎等^[10]对轴承振动信号进行连续小波变换,得到相关时频图,作为卷积神经网络的输入。许理等^[11]对采集的轴承信号进行小波包时频分析,得到各类信号的时频图,然后与卷积神经网络相结合进行故障诊断。然而,以时域图像或频域图像作为输入的卷积神经网络诊断效果有限,采用时频图像作为输入,诊断效果虽然得到一定的提升,但一般需要对相关预定义参数,如基函数、窗函数、窗口大小等参数进行合适地选择才能得到较好的效果,对专家经验具有一定的依赖性。

针对上述问题,本文提出一种基于快速傅里叶变换(FFT)和卷积神经网络(CNN)的滚动轴承故障诊断方法。该方法在信号处理过程中不需要设定相关预定义参数,对原始振动信号进行快速傅里叶变换后,将得到一维数据转换为二维的特征图作为 ResNet-18 网络的输入,对不同故障类型和故障程度的滚动轴承进行诊断识别。

1 快速傅里叶变换

快速傅里叶变换是快速计算序列的离散傅里叶变换(discrete Fourier transform, DFT)或其逆变换的方法。傅里叶分析能够将信号从原始域(通常是时间或空间)转换到频域中进行表示,对于序列 $x(n) = \{x_0, x_1, \dots, x_{N-1}\}$, $0 \leq n < N$ 的离散傅里叶变换表达式为

$$\hat{x}(k) = \sum_{n=0}^{N-1} x(n) e^{-i \frac{2\pi}{N} nk}$$

式中: e 为自然对数的底数; i 为虚数单位; $k = 0, 1, \dots, N-1$ 。

FFT 通过将 DFT 矩阵分解为稀疏因子之积来

快速计算此类变换,因此它能够计算 DFT 的复杂度,将用 DFT 定义计算需要的 $O(n^2)$ 降低到 $O(n \log n)$ 。

2 卷积神经网络

卷积神经网络是深度学习的代表算法之一,它是一类包含卷积计算的前馈深度神经网络。CNN 在如文本识别、语音识别、故障诊断等识别领域有着广泛的应用。典型的卷积神经网络主要由输入层、卷积层、池化层、全连接层以及输出层构成。其中,卷积层以及池化层属于滤波级,用于对输入信号进行深度特征提取;全连接层属于分类级,用于对得到的特征向量进行分类判断。

在卷积神经网络中,卷积层可以有效地对图像进行特征提取,它具有权值共享、局部连接的特点,即使用若干个卷积核对原始输入数据按照一定的步长进行局部滑动卷积计算,从而实现对输入数据的特征提取,因而可以利用较低的计算成本得到较好的提取效果。卷积操作过程的数学表示如下:

$$X_j^k = \sum_{i \in M_j} X_i^{k-1} * W_{ij}^k + b_j^k$$

式中: M_j 为输入的特征向量, k 为第 k 层网络, X_j^k 为第 k 层的输出, X_i^{k-1} 为第 k 层的输入, W_{ij}^k 为卷积核的权重矩阵, b_j^k 为偏置项, “*” 为卷积符号。

池化层也称下采样层,主要是通过采样的方法来减小特征的空间尺寸。目前比较常用的 2 种池化方法是平均池化和最大池化,两者分别是用一定宽度的窗口以一定的步长在得到的特征图上滑动,求取该窗口内特征值的均值或最大值。本文选用的池化方法是最大池化法,可降低参数数目,提高特征的鲁棒性。

在经过前面一系列的卷积操作和采样操作后,会连接一个或多个全连接层,用于整合通过卷积层和采样层提取出的局部信息,然后将这些局部信息输入到 Softmax 分类器中进行故障分类。Softmax 分类器实质上是逻辑回归二分类器的演化,它在多分类场景中应用较为广泛,通过将多分类问题映射为概率分布以实现分类决策。

由于卷积层、池化层和全连接层都是线性计算,为弥补线性模型表达能力的不足,通常会引入激活函数进行非线性操作,使得整个网络的非线性表达能力增强,挖掘出信号背后的潜藏特征,提升网络在非线场景下的分类能力。常用的激活函数有 Sigmoid 函数、tanh 函数以及 Relu 函数。本文使用的激活函数是 Relu 函数,它能够避免神经网络出现梯度消失的问题,并且收敛速度快。

3 故障诊断模型

本文的故障诊断流程如图1所示,首先对原始振动信号进行信号处理,再将处理后的信号按一定比例随机分为训练集和测试集;然后采用交叉熵函数作为损失函数,并使用Adam方法对卷积神经网络模型进行训练;最后使用测试集对训练好的模型进行测试,验证模型的泛化性能。

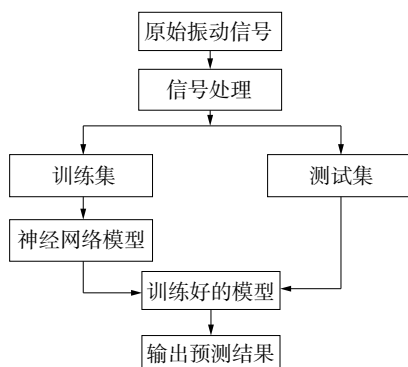


图1 故障诊断流程

3.1 信号处理

在信号处理过程中,首先将原始振动信号等分成若干个数据段,假设每段序列表示为 $y(N) = \{y_1, y_2, \dots, y_k, \dots, y_{m \times n}\}$,其中 m, n 为正整数, $1 \leq N \leq m \times n$;接着,对 $y(N)$ 进行快速傅里叶变换,并求其模值,即可得到变换后的数据序列 $Y(N) = \{Y_1, Y_2, \dots, Y_k, \dots, Y_{m \times n}\}$;最后,将序列 $Y(N)$ 按如图2所示方式转换成 $m \times n$ 的二维矩阵,构成特征图,作为卷积神经网络的输入。

$$Y_1 \quad Y_2 \quad Y_3 \quad \dots \quad Y_k \quad \dots \quad Y_{m \times n}$$

$$\begin{array}{ccccc} Y_1 & Y_2 & Y_3 & \dots & Y_n \\ Y_{n+1} & Y_{n+2} & Y_{n+3} & \dots & Y_{2n} \\ Y_{2n+1} & Y_{2n+2} & Y_{2n+3} & \dots & Y_{3n} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ Y_{(m-1)n+1} & Y_{(m-1)n+2} & Y_{(m-1)n+3} & \dots & Y_{mn} \end{array}$$

图2 转换方式

这种数据预处理方法直接有效,且处理速度快。更重要的是,相比于一些时频分析方法,如小波变换(wavelet transform, WT)需要选择合适的基函数、短时傅里叶变换(short time Fourier transform, STFT)需要选择合适的窗函数以及窗口大小等,该方法不需要设定相关预定义参数,直接进行计算,摆脱了对专家经验的过度依赖。在本文中,分割1 024个数据点作为一个数据段,对每一数据段采用上述信号处理方法,将其构成大小为 32×32 的特征图。

3.2 神经网络模型

本文所采用卷积神经网络是ResNet-18网络,它是经典卷积神经网络之一。ResNet网络的特点是其存在着大量残差模块,这些残差模块包含着恒等映射层,其能使网络随着深度的增加而不会产生权重衰减和梯度衰减或消失等问题。ResNet-18网络结构如图3所示,包含一系列卷积层、恒等映射、Relu激活函数、批量标准化、全局均值池化、全连接层等。

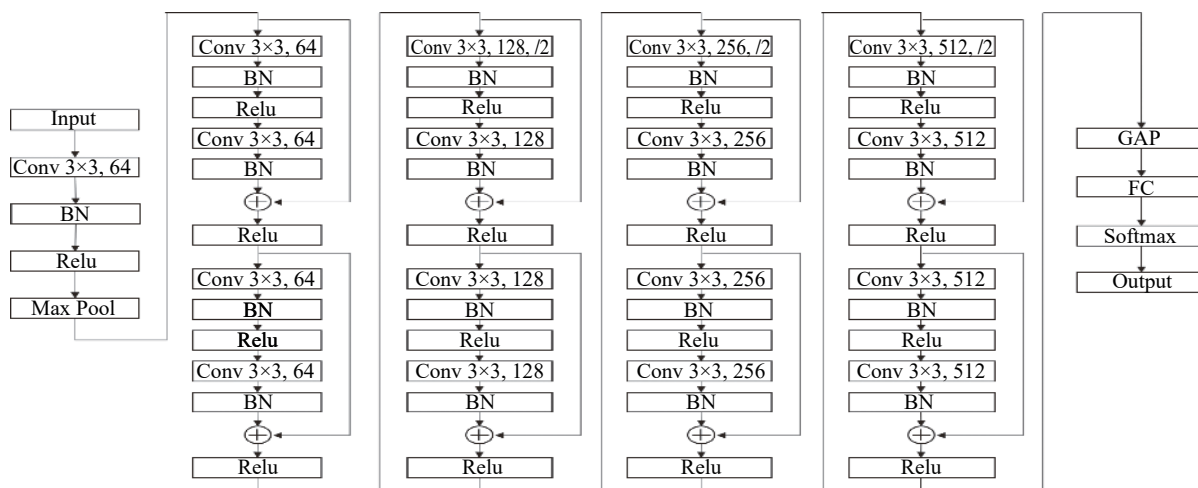


图3 ResNet-18网络结构

图3中“Conv 3×3”指的是长为3、宽为3的卷积核;64、128、256、512表示的是卷积核的个数;“/2”指的是卷积核的步长设置为2,可实现特征图的长宽减半;Relu是激活函数;BN是批量标准化;GAP是全局均值化;Max Pool是最大值池化,

其窗口大小为 2×2 ;FC是全连接层。

4 实验分析

4.1 实验数据

实验所采用的数据来自美国凯斯西储大学的

公开轴承实验数据,其实验台架如图4所示。本文采用的数据包含正常运行状态数据、3种外圈故障数据、3种内圈故障数据以及3种滚动体故障数据,共10种状态运行数据,实验样本信息如表1所示,采样频率为12 kHz。每种数据的样本数目为100,每个样本有1024个数据点,共计1000个样本。将全部样本经过如前所述的处理变换后,从中随机抽取700个样本作为训练集,另外300个样本作为测试集。




图4 轴承实验台架

表1 故障样本信息


故障类型	故障程度	样本长度	样本个数
正常	无	1024	100
	0.007	1024	100
内圈故障	0.014	1024	100
	0.021	1024	100
	0.007	1024	100
外圈故障	0.014	1024	100
	0.021	1024	100
	0.007	1024	100
滚动体故障	0.014	1024	100
	0.021	1024	100

4.2 超参数设置


在本实验中,需要进行设定的卷积神经网络超参数为批量大小 m 、学习速率 α 以及迭代次数 N 。为保证网络具有较好的分类效果,本文通过对 m 、 α 以及 N 进行组合对比试验,以得到良好的超参数组合。选择常用的 m 值以及 α 值作为可选值(m 可选值为32、64、128, α 可选值为0.01、0.001、0.0001),得到9种组合,每种组合迭代次数为10次。用已准备好的训练集对不同超参数设置的神经网络模型分别进行训练,训练完成后,用测试集进行测试。为避免实验的偶然性,对每种组合进行10次训练和测试,将得到的10次测试准确率结果去除最大、最小值后取均值,即为平均测试准确率,实验结果如图5所示。

当学习速率 $\alpha=0.01$ 时,由于学习速率过大,出现了梯度弥散现象;当学习速率 $\alpha=0.001$ 时,平均测试准确率最大值为100%,此时批量大小 $m=32$;当学习速率 $\alpha=0.0001$ 时,平均测试准确率最大值为100%,此时批量大小 $m=32$ 或 $m=64$ 。而在平均测试准确率为100%的3种超参数组合


中, $\alpha=0.0001$ 、 $m=32$ 组合收敛速度最快。综上,本文采用学习速率 α 为0.0001、批量大小 m 为32、迭代次数 N 为10的超参数组合进行正式的训练和测试。



(a) 学习速率 $\alpha=0.01$



(b) 学习速率 $\alpha=0.001$



(c) 学习速率 $\alpha=0.0001$

图5 超参数设置结果

4.3 结果与分析

用已准备好的训练集数据对 ResNet-18 模型进行训练,训练完成后用测试集数据对模型进行测试。在迭代过程中的平均测试准确率结果如图6所示。




图6 本文方法结果

可以看出,本文所提出的故障诊断方法对于多种滚动轴承故障具有极好的分类效果,平均测试准确率可达100%,诊断效果优良,证明了本文所

提出的滚动轴承故障诊断方法的可行性与有效性。

为凸显本文诊断方法的优越性,将原始振动信号分别处理成时域图像、频域图像、经过STFT变换的时频图像以及经过WT变换的时频图像,且图像均先经过灰度化处理,再对每个像素点值进行归一化,然后作为ResNet-18网络的输入,进行对比分析,其结果如图7和表2所示。




图7 不同方法平均测试准确率变化趋势

表2 平均测试准确率结果

输入形式	平均测试准确率/%
时域图像	63.78
频域图像	96.86
STFT时频图像	99.34
WT时频图像	97.34
本文方法	100

通过对比实验可知:输入形式为本文特征图的卷积神经网络分类效果最佳,其平均测试准确率达到100%;其次是2种时频图像以及频域图像,平均测试准确率分别为99.34%、97.34%、96.86%;最差的是时域图像,平均测试准确率为63.78%。相对于其他几种输入形式,本文的特征图能够更好地表现出信号的特征,当其作为卷积神经网络的输入时,更有利于卷积神经网络进行识别分类。此外,相对于2种时频图像,本文方法不仅测试准确率更高、收敛速度更快,而且不需要设定相关预定义参数,如基函数、窗函数、窗口大小等,摆脱了对专家经验的过度依赖。

5 结论

本文提出了一种基于快速傅里叶变换和卷积神经网络的滚动轴承故障诊断方法。对原始振动信号进行相关处理得到特征图,将其作为CNN的输入进行学习训练,并通过超参数寻优使得模型

具有较好的诊断效果。实验结果表明,提出的诊断方法对于多类滚动轴承故障的识别准确率高,诊断效果良好;通过与不同的输入形式进行对比分析,本文方法的诊断准确率更高,收敛速度更快,并且在本文方法的信号处理过程中不需要设定相关预定义参数,可直接进行计算。

参考文献:

- [1] SUN Wei, YANG Guoan, CHEN Qiong, et al. Fault diagnosis of rolling bearing based on wavelet transform and envelope spectrum correlation[J]. *Journal of vibration and control*, 2013, 19(6): 924-941.
- [2] 郑近德, 程军圣. 改进的希尔伯特-黄变换及其在滚动轴承故障诊断中的应用[J]. *机械工程学报*, 2015, 51(1): 138-145.
- [3] 张亢, 程军圣, 杨宇. 基于局部均值分解与形态学分形维数的滚动轴承故障诊断方法[J]. *振动与冲击*, 2013, 32(9): 90-94.
- [4] ZHANG Xueying, LUAN Zhongquan, LIU Xiuli. Fault diagnosis of rolling bearing based on kurtosis criterion VMD and modulo square threshold[J]. *The journal of engineering*, 2019, 2019(23): 8685-8690.
- [5] 路敦利, 宁芊, 杨晓敏. KNN-朴素贝叶斯算法的滚动轴承故障诊断[J]. *计算机测量与控制*, 2018, 26(6): 21-23, 27.
- [6] SHAO Yang, YUAN Xianfeng, ZHANG Chengjin, et al. Rolling bearing fault diagnosis based on wavelet package transform and IPSO optimized SVM[C]//*Proceedings of 2020 Chinese Control and Decision Conference*. Hefei, China, 2020: 2758-2763.
- [7] 冯玉芳, 卢厚清, 殷宏, 等. 基于BP神经网络的故障诊断模型研究[J]. *计算机工程与应用*, 2019, 55(6): 24-30.
- [8] HAN Tian, TIAN Zhixin, YIN Zhongjun, et al. Bearing fault identification based on convolutional neural network by different input modes[J]. *Journal of the Brazilian society of mechanical sciences and engineering*, 2020, 42(9): 474.
- [9] 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.
- [10] 袁建虎, 韩涛, 唐建, 等. 基于小波时频图和CNN的滚动轴承智能故障诊断方法[J]. *机械设计与研究*, 2017, 33(2): 93-97.
- [11] 许理, 李戈, 余亮, 等. 基于小波包与CNN的滚动轴承故障诊断[J]. *四川理工学院学报(自然科学版)*, 2018, 31(3): 54-59.

本文引用格式:

尹文哲, 夏虹, 彭彬森, 等. 基于FFT和CNN的滚动轴承故障诊断方法[J]. *应用科技*, 2021, 48(6): 97-101.

YIN Wenzhe, XIA Hong, PENG Binsan, et al. A fault diagnosis method of rolling bearing based on FFT and CNN[J]. *Applied science and technology*, 2021, 48(6): 97-101.