

[自控·检测]

DOI:10.3969/j.issn.1005-2895.2019.02.012

基于 Dropout-CNN 的滚动轴承故障诊断研究

张文凤, 周俊

(上海工程技术大学 机械与汽车工程学院, 上海 201620)

摘 要:针对滚动轴承故障特征很难提取及传统故障诊断方法准确率偏低的问题,提出一种基于 Dropout 的改进卷积神经网络(Dropout-CNN)结构,可以无需预先提取滚动轴承振动信号的故障特征,直接端到端的实现滚动轴承故障诊断。该方法以振动信号为监测信号,使用傅里叶变换生成振动信号频谱图,以此作为整个系统的输入,利用卷积神经网络强大的特征提取能力可以自动完成故障特征提取以及故障识别。试验结果表明该方法平均诊断准确率高达 99.5%。该方法实现了大量样本下滚动轴承不同故障类型的故障特征自适应提取与故障状态的准确识别。

关 键 词:滚动轴承;故障诊断;Dropout;卷积神经网络;深度学习;振动信号;特征提取

中图分类号:TP277

文献标志码:A

文章编号:1005-2895(2019)02-0062-06

Fault Diagnosis Method of Rolling Bearing Based on Dropout-CNN

ZHANG Wenfeng, ZHOU Jun

(School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

Abstract: Aiming at the difficulty of the rolling bearing fault feature extraction and the low accuracy of the traditional fault diagnosis method, an improved convolution neural network (Dropout-CNN) structure based on Dropout was proposed to realize the fault diagnosis of rolling bearing directly from end to end without extracting the fault features of rolling bearing vibration signals in advance. The vibration signal was used as the monitoring signal and the frequency spectrum of the vibration signal was generated by Fourier transform. The fault feature and fault identification can be automatically completed by using the powerful feature extraction capability of the convolutional neural network. The experimental results show that the average diagnostic accuracy of this method is as high as 99.5%. It realizes adaptive fault feature extraction and fault state identification of different fault types of rolling bearings under a great quantity of samples.

Keywords: rolling bearing; fault diagnosis; Dropout; convolutional neural network; deep learning; vibration signal; feature extraction

机械设备正朝着大型化、精密化和自动化的方向发展,建立稳定可靠的实时故障诊断系统是保证这些设备安全运行的必要手段^[1]。由于现代化机械设备数量规模大、采样点多以及采样频率高,故障诊断系统将获得海量的数据,因此机械设备故障诊断领域进入“大数据”时代^[2]。

滚动轴承作为机械设备的易损部件,其健康状态对整个机械设备的性能、稳定性及使用寿命有着巨大的影响。基于“信号处理的特征提取+机器学习”分

类的传统诊断方法,需要大量信号处理技术和诊断经验,传统诊断方法已经不能满足滚动轴承的智能诊断要求^[3]。

2006年,HINTON等^[4]在《Science》上发表文章,首次探讨了一种处理大数据的工具,即深度学习理论。深度学习是指建立深层神经网络,利用大量的训练数据来挖掘数据中的隐藏特征,从而提高分类或者预测的准确度。如今,深度学习已在图像识别、语音识别和自然语言处理等领域取得了巨大的突破^[5]。

收稿日期:2018-10-22;修回日期:2019-01-15

第一作者简介:张文凤(1993),男,安徽六安人,硕士,主要研究方向为深度学习在故障诊断方面的应用。E-mail:1951764822@qq.com

卷积神经网络^[6]作为深度学习模型的重要组成部分,其在图像识别等多个领域取得了巨大的进展。而在滚动轴承故障诊断领域,卷积神经网络的研究与应用未得到重视,处于起步发展阶段。因此,课题组提出了一种基于 Dropout-CNN 的故障诊断方法。该方法相比传统的“基于信号处理的特征提取+机器学习模型”故障诊断方法^[7-9],其优势在于:①该方法具有强大的特征提取能力,能从大量数据中自动提取故障特征,摆脱了对故障诊断经验和大量信号处理技术的依赖;②建立深层模型,能够很好地表征信号与滚动轴承状态之间复杂的映射关系,适合处理复杂环境下滚动轴承的状态判断,并具有一定的实用性和通用性^[10]。

1 卷积神经网络

1.1 卷积神经网络的结构

卷积神经网络(CNN)是一种多层深度神经网络,处理图像相关的问题有很大优势。一个典型的卷积神经网络由卷积层、池化层、全连接层组成,其中卷积层和池化层配合,组成多个卷积组,逐层提取特征,最终连接若干个全连接层完成分类。图1为卷积神经网络典型结构。




图1 卷积神经网络典型结构

Figure 1 Typical structure of convolutional neural network

1.1.1 卷积层

将图像表示为 $P = f(x, y)$, $f(x, y)$ 是图像 P 上位于第 x 行 y 列点的灰度值,图像 P 的像素大小为 $M \times N$ 。卷积核表示为 $k(x, y)$,大小 $a \times b$, $C(s, t)$ 表示图像 P 与卷积核 k 经过卷积运算后得到的矩阵,运算表达式^[11]为

$$C(s, t) = \sum_{x=1}^a \sum_{y=1}^b k(x, y) f(s+x-1, t+y-1). \quad (1)$$

式中: s 与 t 的取值范围是 $1 \leq s \leq M-a+1, 1 \leq t \leq N-b+1$ 。

输入图像和卷积核的对应位置元素相乘再求和,即得到输入数据的特征图。在卷积层,前一层的矩阵作为输入,与卷积核进行卷积运算,之后经过非线性变换得到这一层的特征图。在传统的卷积神经网络中,

一般采用 ReLu 函数来完成非线性变换,该函数也称为激活函数。其函数表达式如下:

$$\text{ReLu} = \begin{cases} x, & x > 0; \\ 0, & x \leq 0. \end{cases} \quad (2)$$

1.1.2 池化层

池化层在卷积层之后,通过池化来降低卷积层输出的特征向量。池化为对卷积层的输出特征图进行矩形分割,并对每一块矩形做相应计算。主要分为最大池化和均值池化,分别取最大值和平均值。

$$d = \begin{bmatrix} 1 & 0 & 2 & 4 \\ 3 & 4 & 3 & 7 \\ 1 & 1 & 2 & 0 \\ 3 & 1 & 9 & 1 \end{bmatrix}; d_1 = \begin{bmatrix} 4 & 7 \\ 3 & 9 \end{bmatrix}; d_2 = \begin{bmatrix} 2.0 & 4 \\ 1.5 & 3 \end{bmatrix}. \quad (3)$$

式中: d 表示池化前的特征向量, d_1 表最大池化后的结果, d_2 表示均值池化后的结果。池化大小为 2×2 。

1.1.3 全连接层和输出层

将整个网络的最后一层卷积层或池化层得到的特征图的向量按行或按列排成一维特征向量作为全连接层。若整个网络用来做分类时,输出层为一个分类器,输出节点数与类别数一致,且每个节点的输出值代表输入样本属于对应类别的概率。文中所选用的是 softmax 分类器,是一种多分类的分类器。

1.2 卷积神经网络的训练过程

卷积神经网络的训练过程由前向传播和反向传播组成。前向传播是指将样本数据输入到卷积神经网络中,得到网络输出;反向传播是指由损失函数计算出网络输出值与真实值之间的误差值,误差值反向传播^[12]。目前卷积神经网络使用最广泛的损失函数是交叉熵损失函数,公式为

$$L(W, e) = - \sum_{i=1}^K \sum_{j=1}^c 1\{y_i = j\} \ln p_i^j. \quad (4)$$

式中: $1\{y_i = j\}$ 为示性函数,表示括号内的值为真时值为1,为假时值为0; K 为样本的总数, C 为样本的类别数, y_i 是第 i 个样本的真实值, p_i^j 是第 i 个样本为第 j 个类别的预测概率。

整个卷积神经网络的训练目的是使用梯度下降法来最小化损失函数 $L(W, e)$,训练过程中,前向传播计算误差值,误差值反向传播,更新每一层的参数 W 和 e 。参数的更新公式为:

$$W_i = W_i - \eta \frac{\partial L(W, e)}{\partial W_i}; \quad (5)$$

$$e_i = e_i - \eta \frac{\partial L(W, e)}{\partial e_i}. \quad (6)$$

式中 η 为卷积神经网络的学习率。

1.3 Dropout 层

由于 CNN 模型很复杂,实验数据相对过少,因此可能会造成过拟合现象,即在训练集上表现得很好,准确率高,但在测试集上表现较差,准确率较低。为了减少过拟合现象,在每个全连接层引入了 Dropout 层,其作用为设定参数使得全连接层的神经元以一定概率失活。通过 Dropout 方法可以减少过拟合现象,使得 CNN 在测试集上表现得很好。

2 基于 Dropout-CNN 的滚动轴承故障诊断方法

因为 CNN 的输入为图像,滚动轴承的振动数据不能直接作为输入,为了有效地实现故障诊断方法,将傅里叶变换和 Dropout-CNN 结合在一起,对测得的振动信号进行傅里叶变换,生成信号频谱图,以此作为 Dropout-CNN 的输入。实验使用的 Dropout-CNN 具体如图 2 所示,其中, C1, C3, C5 为卷积层; S2, S4, S6 为池化层; FC1 和 FC2 为全连接层,其 Dropout 的参数设为 0.5,即每个神经元的激活概率为 0.5; Softmax 为分类层。具体的网络参数如表 1 所示。




图 2 Dropout-CNN 模型

Figure 2 Model of Dropout-CNN

表 1 卷积神经网络的具体结构与参数

Table 1 Specific structure and parameters of convolutional neural network

网络层类型	具体参数	输出特征
输入层	输入 RGB 图像	150 * 150 * 3
C1	32 个 3 * 3 卷积核, 步长为 1	148 * 148 * 32
S2	最大池化 2 * 2 的核, 步长为 2	74 * 74 * 32
C3	32 个 3 * 3 的卷积核, 步长为 1	72 * 72 * 32
S4	最大池化 2 * 2 的核, 步长为 2	36 * 36 * 32
C5	64 个 3 * 3 卷积核, 步长为 1	34 * 34 * 64
S6	最大池化 2 * 2 的核, 步长为 2	17 * 17 * 64
FC1	18 496 个节点	1 * 18 496
FC2	64 个节点	1 * 64
softmax	10 分类	1 * 10

滚动轴承的故障诊断分为以下几个步骤:

1) 获取滚动轴承振动信号;

2) 将振动信号通过傅里叶变换生成频谱图,并将其分成训练集和测试集;

3) 建立卷积神经网络并初始化参数,根据实验要求,构建合适的网络模型,确定网络参数(如学习率、迭代次数等);

4) 将训练样本输入到网络中,通过前向传播求得输出值和期望值的误差;

5) 判断网络是否收敛,若网络收敛,则执行步骤 7),否则执行步骤 6);

6) 反向传播和权值修改,利用随机梯度下降算法,将步骤 4)求得的误差反向逐层传播,更新权值,重复执行步骤 4)到步骤 6),直至网络收敛;

7) 根据测试样本的准确度判断网络是否满足要求,如满足执行步骤 8),否则跳转到步骤 3),修改网络参数;

8) 输出训练好的 Dropout-CNN 用于滚动轴承故障诊断。

3 实验验证

3.1 实验数据

此次试验数据来自美国凯斯西储大学(CWRU)的滚动轴承数据中心。CWRU 轴承中心数据采集系统如图 3 所示。



图 3 CWRU 滚动轴承数据采集系统

Figure 3 CWRU rolling bearing data acquisition system

此次试验对象为图中的驱动端轴承,有故障的轴承是由电火花加工制作而成,整个系统的采样频率为 12 kHz,负载为 735 W。被诊断的轴承一共有 3 种缺陷位置,分别是内圈损伤、外圈损伤和滚动体损伤,损伤直径分别为 0.18, 0.36 和 0.54 mm,共计 9 种故障状态,加上正常状态,总共 10 种状态^[13]。将振动信号进行分割,每个实验样本包含 2 048 个采样点。对每个样本的 2 048 个采样点进行傅里叶变换产生样本的频谱图,以此作为卷积神经网络的输入。表 2 为本次

实验准备的数据,每种状态有 1 500 个训练样本和 500 个测试样本,所以训练样本总数为 15 000,测试样本总数为 5 000。

表 2 实验数据

Table 2 Experimental data

故障类别	训练样本	测试样本	标签
正常	1 500	500	0
滚动体损伤	损伤直径 0.18 mm	500	I
	损伤直径 0.36 mm	500	II
	损伤直径 0.54 mm	500	III
内圈损伤	损伤直径 0.18 mm	500	IV
	损伤直径 0.36 mm	500	V
	损伤直径 0.54 mm	500	VI
外圈损伤	损伤直径 0.18 mm	500	VII
	损伤直径 0.36 mm	500	VIII
	损伤直径 0.54 mm	500	IX

图 4 为滚动轴承不同状态下的振动信号的频谱图。由于篇幅有限,只取了 4 种不同状态的信号频谱图,分别为轴承正常状态、内圈损伤直径 0.18 mm、外圈损伤直径 0.18 mm 和滚动体损伤直径 0.18 mm 的振动信号频谱图。从图中可以看到,不同状态的频谱图波形存在一定的区别,这说明使用 Dropout-CNN 的方法来区分这些状态是理论可行的。

3.2 实验结果分析

为了说明 Dropout-CNN 方法的优越性,作为对比,同一个故障数据集使用了另外 3 种传统故障诊断方法:①含有单隐藏层的 BP 神经网络(BPNN),直接使用时域信号作为输入,用 BPNN 表示;②同样是含有单隐藏层的 BP 神经网络(BPNN),提取故障信号的 10 个常用特征作为输入,这 10 个特征分别为能量比、峭度、能量算子、波峰因子、峰值、方均根植、变量方均根植、Sideband index、FM0 和 FM4,这 10 个特征定义及物理意义在文献[14]中有详细说明,该方法用常用特征+BPNN 表示;③以故障信号 10 个特征值作为输入,使用 SVM 作为分类器,用常用特征+SVM 表示。

Dropout-CNN 和传统 3 种故障诊断方法实验结果如图 5 所示。从图中可以看到 Dropout-CNN 方法的 20 次实验结果的准确率均在 99.2% 以上,充分说明了 Dropout-CNN 方法可以排除工况干扰,准确识别大量样本下轴承在不同故障位置、不同故障模式下的 10 种故障状态。BPNN 方法的 20 次实验诊断结果准确率在 46.34% ~ 56.47% 之间,准确率整体偏低。常用特征+BPNN 方法的 20 次诊断结果的准确率在 42.47% ~ 96.94% 之间,变化幅度很大,诊断精度不稳定。常用特




图 4 4 种不同状态下的振动信号频谱图

Figure 4 Spectrum of vibration signals in 4 different states

征+SVM 方法的 20 次诊断结果准确率在 92.86% ~ 95.64% 范围内,诊断准确率较高,诊断精度较稳定。为了定量对比 4 种方法的诊断精度,计算 20 次实验的平均诊断精度及其标准差,其结果如表 3 所示。从表

中可以看出,在诊断准确度方面,Dropout-CNN方法最高,平均诊断准确率为99.5%;而BPNN方法的诊断准确率最低,平均仅为50.63%。在诊断稳定性方面,Dropout-CNN方法的稳定性最高,其诊断标准差为0.11,常用特征+BPNN方法最不稳定,其诊断精度标准差高达14.28。以上结果表明,Dropout-CNN方法相较于其他3种方法不管在诊断精度和诊断稳定度方面均具有一定优势,特别是相对于BPNN方法和常用特征+BPNN方法具有明显的优势。




图5 20次实验结果诊断准确率

Figure 5 Diagnostic accuracy in 20 experimental results

表3 20次实验的诊断结果

Table 3 Results of 20 experiments

方法	平均诊断准确率/%	诊断率的标准差
Dropout-CNN	99.50	0.11
BPNN	50.63	3.26
常用特征+BPNN	81.68	14.28
常用特征+SVM	94.86	1.01

通过对图5的观察可以看出,常用特征+BPNN方法在第6次和第12次分别只获得了42.27%和46.75%的诊断准确率,而第17次获得了96.94%的准确率,因此以第6次和第17次实验为代表做具体分析。图6为第6次实验4种方法的训练误差曲线,可以看到BPNN方法和常用特征+BPNN方法的训练误差很早便陷入了局部最优,其训练误差分别为0.54和0.51。图7为第17次实验4种方法的训练误差曲线。BPNN方法的训练误差为0.55左右,依然较大,而常用特征+BPNN方法的训练误差波动较大,但最终收敛到0.03左右,达到了96.94%的准确率。在这两次实验中,Dropout-CNN方法训练误差均很快收敛到0.01以下,并达到99.2%以上的诊断准确率。以上结

果表明:Dropout-CNN方法使用了深度学习的方法对卷积神经网络进行训练,误差收敛速度快,使其具有很好的检测故障能力。




图6 第6次实验的训练误差

Figure 6 Training error of 6th experiment




图7 第17次实验的训练误差

Figure 7 Training error of 17th experiment

BPNN方法诊断准确率很低的原因是输入的信号噪音干扰太大,故障种类太多,因此BP神经网络不能很好地将这些故障种类区分开来。对于常用特征+BPNN方法,其诊断准确率较高,是因为人工提取的故障信号特征能较好地表达故障信息;但因为BP神经网络由于初始化参数选择的不好而陷入局部最优状态使其诊断精度不稳定。对于常用特征+SVM方法,诊断平均准确率94.86%,标准差为1.01,可以看出其诊断准确率和诊断精度稳定性都保持在一个较高的水平,说明基于常用特征+SVM的方法能较稳定和较准确地诊断滚动轴承在不同故障位置 and 不同故障模式下的故障状态。但与Dropout-CNN方法相比,不管在诊断准确度和稳定性方面均具有一定差异,更重要的是Dropout-CNN方法不需要人工提取故障特征。

Dropout-CNN 方法取得很高诊断精度和稳定性的根本原因在于:卷积神经网络可以从故障诊断信号的频谱图中自适应地提取故障特征。由于卷积神经网络的卷积层的输出以人类的视角很难理解,为了验证卷积神经网络强大的特征提取能力,选取全连接层 FC1 的输出作为特征输出,运用主成分分析法提取前两个主成分,并进行可视化,主成分分析法(PCA)是一种降低数据集维数的方法,它是一个线性变换,这个变换把数据变换到一个新的坐标系统中,使得数据投影的第一大方差在第一个坐标(称为第一主成分)上,第二大方差在第二个坐标(第二主成分)上,依次类推。主成分分析法经常用来减少数据集的维数,同时保持数据集对方差贡献最大的特征。如图 8 所示,轴承的同一故障状态很好地聚集在一起,而不同故障状态都有效地分离开来,因而取得了平均 99.5% 的诊断准确率。




图 8 全连接层 FC1 提取特征散点图

Figure 8 Extraction feature scatter plot of full-connection layer FC1

4 结语

1) Dropout-CNN 方法可以自适应从滚动轴承故障信号的频谱图中提取故障信息,减少了普通 CNN 的过拟合现象,摆脱了对大量信号处理技术和诊断经验的依赖,并取得了很高的诊断精度和稳定性,使得滚动轴承故障诊断更加智能化与高效化。

2) 课题组研究的实验数据是在特定的实验环境

下采集的,与正常的工业生产环境存在一定差距,实际生产条件下的样本采集及 Dropout-CNN 的构建仍需进一步研究。

参考文献:

- [1] 雷亚国,何正嘉. 混合智能故障诊断与预示技术的应用进展[J]. 振动与冲击,2011,30(9):129-135.
- [2] 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检测方法[J]. 机械工程学报,2015,51(21):49-56.
- [3] 李国杰,程学旗. 大数据研究:未来科技及经济社会发展的重大战略领域——大数据的研究现状与科学思考[J]. 中国科学院院刊,2012,27(6):647-657.
- [4] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786):504-507.
- [5] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553):436-444.
- [6] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]// International Conference on Neural Information Processing Systems. Lake Tahoe, Nevada, United States; Curran Associates Inc, 2012, 1: 1097-1105.
- [7] DU Wenliao, TAO Jianfeng, LI Yanming, et al. Wavelet leaders multifractal features based fault diagnosis of rotating mechanism[J]. Mechanical Systems & Signal Processing, 2014, 43(1/2):57-75.
- [8] LI Weihua, ZHANG Shaohui, HE Guolin. Semisupervised distance-preserving self-organizing map for machine-defect detection and classification[J]. IEEE Transactions on Instrumentation & Measurement, 2013, 62(5):869-879.
- [9] VAN M, KANG H J. Bearing defect classification based on individual wavelet local fisher discriminant analysis with particle swarm optimization[J]. IEEE Transactions on Industrial Informatics, 2017, 12(1):124-135.
- [10] WORDEN K, STASZEWSKI W J, HENSMAN J J. Natural computing for mechanical systems research: a tutorial overview[J]. Mechanical Systems & Signal Processing, 2011, 25(1):4-111.
- [11] 曾雪琼. 基于卷积神经网络的变速器故障分类识别研究[D]. 广州:华南理工大学, 2016:9-14.
- [12] 李亚飞,董红斌. 基于卷积神经网络的遥感图像分类研究[J]. 智能系统学报, 2018, 13(4):550-556.
- [13] 张伟. 基于卷积神经网络的轴承故障诊断算法研究[D]. 哈尔滨:哈尔滨工业大学, 2017:26-29.
- [14] LEI Y G, ZUO M J. Gear crack level identification based on weighted K nearest neighbor classification algorithm[J]. Mechanical Systems and Signal Processing, 2009, 23(5):1535-1547.