

文章编号:1006-1355(2021)02-0130-06+178

# 深度学习在机械设备诊断中的应用

贾彦杰, 温 皓, 王 靖, 张 彬, 周代军, 王 磊

( 中国石油西南管道公司, 成都 610036 )

**摘 要:**传统的机械设备状态监测是根据经验通过提取现场采集的振动信号特征值构建特征空间,采用多种方法对特征值进行聚类、分类,从而实现对设备状态的分类。但这种方法严重依赖于专家经验,并且效果受到信号噪声等众多因素的影响。分别在经典一维和二维卷积神经网络的基础上,提出两种机械设备智能故障诊断方法,并通过凯斯西储大学轴承数据中心发布的数据集比较两种模型的性能,实验结果表明,基于一维卷积神经网络的智能诊断方法更适用于一维振动信号。将基于一维卷积神经网络的智能诊断方法应用于石化厂的机泵设备,证明其能实现特征自适应提取,可取得较好诊断效果。

**关键词:**故障诊断;智能诊断;深度学习;状态监测

中图分类号:TH165+.3;U226.8+1

文献标志码:A

DOI编码:10.3969/j.issn.1006-1355.2021.02.021

## Application of Deep Learning in Mechanical Equipment Diagnosis

JIA Yanjie, WEN Hao, WANG Jing, ZHANG Bin, ZHOU Daijun, WANG Lei

( Petro China Southwest Pipeline Company, Chengdu 610036, China )

**Abstract :** The traditional mechanical equipment condition monitoring extracts the feature values from the vibration signals collected in the field according to engineer's experience to construct the feature space by using the feature values, and performs clustering and classification in the feature space to realize the classification of the equipment state. However, this method seriously relies on expert's experience, and the effect is limited by several factors such as signal acquisition noise etc. Therefore, based on the classical one-dimensional and two-dimensional convolutional neural networks, two intelligent fault diagnosis methods for mechanical equipment are proposed. The performances of the two models are compared mutually according to the dataset published by the bearing data center of Case Western Reserve University. It is concluded that the intelligent diagnosis method based on one-dimensional convolutional neural network is more suitable for one-dimensional vibration signals. This method is applied to the pump equipment of the petrochemical plant. It is proved that this method can realize the feature adaptive extraction and has a better fault diagnosis effect.

**Key words :** fault diagnosis; intelligent diagnosis; deep learning; condition monitoring

振动传感器所采集的机械设备运行过程中加速度信号可以在某种程度上反映设备运行状态信息。传统的做法是从振动信号中提取有效值、峰值和峰峰值等特征值,然后以这些特征值构建高维的特征空间,在特征空间中训练SVM、BP网络等分类器,将不同状态的特征空间分到不同的子空间中,以此实现故障诊断。但是在实际工作中采集的机泵振动信号会受到噪声的影响,从带噪信号中提取的特征值就不能准确反映设备的运行状态,可能会导致漏报、误报的情况。因此对于机泵振动信号,时频分

析如小波变换<sup>[1]</sup>、维格纳分布<sup>[2]</sup>及自适应分解EEMD<sup>[3]</sup>等方法被用来提取特征,神经网络<sup>[4]</sup>、支持向量机<sup>[5]</sup>、决策树<sup>[6]</sup>、模糊逻辑<sup>[7,8]</sup>等方法被用于对机泵的运行状态进行分类,但由于特征值是根据专家经验进行提取的,对于不同的设备需要不同的专家经验,这在一定程度上也制约了专家经验的泛化能力。

深度学习已经在计算机视觉和自然语言处理等方面大放异彩,深度学习最主要的特点在于其可以自适应提取蕴含于数据中的模式。近年来,常见较为被认可的深度学习模型框架包括:卷积神经网络(CNN)、递归神经网络(RNN)、深度置信网络(DBN)、堆叠自动编码器(SAE)<sup>[7-8]</sup>。其中CNN更适于对图像进行数据处理,应用CNN可自适应提取特征并进行分类识别<sup>[7-8]</sup>、处理并学习海量数据。应用CNN算

收稿日期:2020-07-01

作者简介:贾彦杰(1983-),男,石家庄市人,博士,主要研究方向为工艺设备。

E-mail: jiajj007@petrochina.com.cn

法,进行故障诊断的文献主要可分为两类:一是将CNN作为分类器<sup>[9-10]</sup>;二是采用CNN进行特征提取并识别<sup>[11-12]</sup>。本文结合CNN的算法特点,基于应用于设备故障诊断的数据进行特征提取和故障分类,在经典一维和二维卷积神经网络的基础上,提出两种机械设备智能故障诊断方法,并通过凯斯西储大学轴承数据中心发布的数据集比较两种模型的性能。因此可运用深度学习智能故障诊断方法实现设备的状态监测,实现智能特征提取与故障分析诊断。该方法可提高分类效率,具有较好的抗干扰能力。

## 1 深度学习

深度学习是机器学习的一个分支,其各层级嵌套的结构可以灵活表达我们的世界,深度学习中的概念是由简单的概念互相串联而成的,这样可以从不抽象的概念中提取出更加抽象的概念。神经网络是用于实现这类问题较常见的结构,它是一种高度非线性映射,可以将输入网络的数据映射到决策空间中。神经网络最早受到了生物大脑结构的启发,人们认为模拟大脑的活动机制可以让机器具有和人类类似的智能,但是历史上早期的神经网络实际上是一种简单的线性组合,可以实现的能力极其有限。而后,更多的研究者提出了效率更高的神经网络模型,时至今日,深度学习是实现人工智能的重要工具。

卷积神经网络(Convolutional neural network, CNN)最早是由Le Cun应用于手写数字识别中<sup>[13]</sup>,但是早期由于受到计算机算力的限制和数据量的限制,CNN架构并没有引起过多的关注。Hinton等于2006年正式提出了Deep Learning的概念<sup>[14]</sup>,但是由于缺乏明确的理论基础,深度学习也没有获得过多的关注。直到2012年,Hinton的学生Alex Krizhevsky等提出的Alex Net<sup>[15]</sup>以巨大的优势取得了ILSVRC 2012比赛冠军,深度学习才引起了广泛关注,并且从2012年之后出现了众多深度学习模型<sup>[16-17]</sup>,在图像处理和自然语言处理方面都取得了显著的成果。

传统的卷积神经网络结构由以下5部分构成,分别是读入数据的输入层、进行特征提取的卷积层、池化层和全连接层以及输出最后结果的输出层。

### 1.1 输入层

卷积神经网络的输入层可以处理不同维度的数据。常见地,一维CNN的输入层接收一维或二维数组,其中一维数组通常为振动信号时域图或频谱图,二维数组包含多个通道的时间或频谱采样;二维CNN的输入层接收二维或三维数组;三维CNN的输

入层接收四维数组<sup>[18]</sup>。

与其他神经网络算法类似,由于使用梯度下降算法进行学习,卷积神经网络的输入特征需要进行标准化处理。具体地,学习数据需要在通道或时间/频率维进行归一化后,才能将其输入卷积神经网络,若输入数据为像素,也可将原始像素值二值化。输入特征的标准化可以提升其收敛速度和学习效果。

### 1.2 卷积层

卷积层的功能是对输入数据进行特征提取。卷积层中的每个神经元都连接到前一层中相邻区域中的多个神经元。该区域的大小取决于卷积核的大小,被称为“感受野”,类似于视觉皮层的感受野<sup>[19]</sup>。工作时,卷积核会依次扫过输入特征,在感受野内对输入特征做矩阵点乘并叠加偏差量。每个卷积的输入(除第一层外)和输出也被称为特征图。

以二维为例,卷积过程数学表达式为

$$X_j^n = f \left( \sum_{i \in M_j} X_i^{n-1} \cdot \omega_{ij}^n + b_j^n \right)$$

式中: $X_j^n$ 为第 $n$ 层第 $j$ 个元素; $M_j$ 为 $n-1$ 层特征图的第 $j$ 个卷积区域; $X_i^{n-1}$ 为其中的元素; $\omega_{ij}^n$ 为对应卷积核的权重矩阵; $b_j^n$ 为偏置项。 $f(\cdot)$ 为激活函数,通常使用ReLU函数。

### 1.3 池化层(下采样层)

由输入层接收的数据经过卷积层提取特征后,将由特征矩阵进行进一步降维处理,实现特征筛选和信息过滤,这通过池化层实现,如最大池化、平均池化等。它的主要功能就是将特征向量中的点进行替换填充。

池化层的主要作用有两个:一是减少特征维数,防止“特征灾难”,较为简便描述高维特征;二是控制过拟合,保证测试集准确度不过分偏离训练集准确度。

### 1.4 全连接层

全连接层一般位于卷积层和输出层之间,将由卷积层提取到的特征转换为一维向量,通过与其相邻的全连接层之间的每一个节点相连反映学习样本特征到目标之间的映射关系<sup>[19]</sup>。

卷积神经网络中通常在全连接层之间加入线性整流函数(Rectified linear unit, ReLU)等<sup>[20]</sup>非线性元素增加其处理非线性问题的能力。

综上所述,全连接层主要作用是将由卷积层和池化层提取的特征进行非线性组合,以完成特征到标记样本空间的映射,即全连接层本身不被期望具有特征提取能力,而是试图利用卷积层提取出的高阶特征实现学习目标。

1.5 输出层

卷积神经网络的结构和工作原理与传统前馈神经网络中的输出层相同。对于分类问题,输出层将全连接层的输出转化为分类标签。

2 基于深度学习的机械故障诊断

2.1 传统机械故障诊断方法

传统的机械故障诊断方法可以分为4个层级,如图1所示。

第1层次是原始加速度信号的采集,第2层次是进行原始信号去噪,并通过积分得到速度信号和位移信号,同时对加速度进行解调得到包络信号,第3层次是从加速度、速度、位移以及包络中提取特征,第4层次是将提取的特征作为输入,使用分类、聚类 and 回归等手段分析设备是否存在故障。

其中特征提取至关重要,常见的特征提取包括时域特征提取和频域特征提取,时域特征包括方差、



图 1 传统机械故障诊断4个层次

峰值、偏度和峭度等,频域特征包括频带能量、频域相位、时频图等,具体说明如表1所示。

这些特征是在长期的研究实践中根据专家经验总结出来的,建立两种基于深度神经网络模型,分别使用一维和二维数据,实现自动特征提取,并成功应用于机械故障诊断。

2.2 基于一维卷积神经网络的智能诊断模型

基于一维卷积神经网络的智能诊断模型如图2所示,具体网络参数如表2所示。

表 1 常见时域特征和频域特征

时域特征	方差	信号幅值离散程度的度量。
	峰值	信号中的最大幅值,信号极值状态的度量。
	偏度	信号的3阶标准矩,信号概率密度函数偏斜方向和程度的度量。
	峭度	信号的4阶标准矩,信号概率密度函数陡峭程度的度量。
频域特征	频带能量	信号能量在不同频带的分布情况。
	频域相位	不同频率成分的相位差。
	时频图	对于非平稳信号(主要指变转速的设备振动信号),传统频谱分析会出现频率混叠现象。 时频分析是时间和频率的联合函数,是能量密度在时间和频率上的度量。




图 2 特征自动提取和智能诊断模型

表 2 一维卷积神经网络参数

网络层类型	具体参数
输入层	加速度信号 2 048×1
卷积层 1	16 个 64×1 卷积核, 步长 16
池化层 1	Max Pooling1D 2×1, 步长 2
卷积层 2~5	64 个 3×1 卷积核, 步长 1
池化层 2~5	Max Pooling1D 2×1, 步长 2
全连接层	100 个节点
输出层(Softmax)	10 个节点

如图2所示,前5个卷积层的作用是从加速度信号中提取特征,用加速度信号作为输入数据是因为速度、位移以及包络可以通过对加速度信号做某种

变换得到,因此只要网络的拟合能力足够强大,就可以从加速度信号中提取出足够用于故障诊断的特征。时域上的卷积在频域上对应着相乘,因此通过卷积层的操作,实际上可以得到短时的频域特征。

智能诊断部分由全连接层、BN层和 Softmax 层组成,BN层可以防止网络在训练数据上过拟合,提高网络的泛化性能。

在一个批次里有  $m$  个样本,记为  $x_1, x_2, \dots, x_m$ ,那么对于每一个样本学习两个参数  $\gamma$  和  $\beta$ ,具体计算方法如下所示:

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \tag{1}$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \tag{2}$$

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \tag{3}$$

$$\gamma_i = \gamma \hat{x}_i + \beta \equiv BN_{\gamma, \beta}(x_i) \tag{4}$$

式中:  $\mu_B$  为数据均值;  $\sigma_B^2$  为数据方差; 式(3)是对数据进行标准化; 式(4)包含两个过程,分别是:训练参



数 $\gamma$ 、 $\beta$ 和输出 $y$ 通过 $\gamma$ 与 $\beta$ 的线性变换得到新的值。最后的Softmax层可以实现多种故障类别的区分。

### 2.3 基于二维卷积神经网络的智能诊断模型

二维卷积神经网络参数如表3所示,结构如图3所示。

由二维卷积神经网络处理的数据往往是二维乃至三维的数据,因此振动传感器采集的一维时域振动信号需要先通过时频方法转换为二维的时频图,之后才能送入模型进行训练。

表3 二维卷积神经网络参数

网络层类型	具体参数
输入层	时频灰度图28×28
卷积层1	32个5×5卷积核,步长1×1
池化层1	Max Pooling2D 2×2
卷积层2	64个5×5卷积核,步长1×1
池化层2	Max Pooling2D 2×2,步长2
全连接层	100个节点
输出层(Softmax)	10个节点




图3 二维卷积神经网络

常见的时频方法有4种,分别为:STFT、小波变换、WVD和Hilbert-Huang变换,文中所用时频方法为小波变换。基于二维CNN的智能诊断模型如图4所示。




图4 基于二维卷积神经网络的智能诊断模型

### 2.4 模型对比

上述两种模型原理相同,输入数据包含的信息相同,但在输入数据类型以及网络参数方面略有不同,因此,比较后选择最优的模型作为所用智能诊断模型。

#### 2.4.1 数据集

选取凯斯西储大学轴承数据中心的滚动轴承测试数据作为数据集。使用2马力电动机进行实验,并且在靠近和远离电动机轴承的位置处测量加速度数据。试验中通过电火花加工(EDM)为电机轴承提供故障。在内滚道、滚动体(即滚珠)和外滚道上分别引入直径为0.007英寸至0.040英寸的故障。

#### 2.4.2 模型比较

两种CNN智能故障诊断模型的诊断结果如表4

所示。

表4 两种诊断模型的诊断结果

诊断模型	诊断精度
基于1 DCNN的智能诊断模型	0.986 7
基于2 DCNN的智能诊断模型	0.983 3

比较而言,基于2DCNN的智能诊断模型的诊断正确率稍低,但两者诊断精度都高达98%,且正确率相差不到0.5%,两种模型正确率差别不大。

然而,基于2DCNN的智能诊断模型需要将时域振动信号转换为时频图,需要花费额外的时间成本和计算成本,而且由于测不准原理,在旋转设备转速变化较大时,不能够同时获得较高的频率分辨率和时间分辨率,因此在时频变换的过程中容易丢失部分信息,导致诊断结果出现偏差。

因此,选择基于1DCNN的智能诊断模型作为最终使用的智能诊断模型。

## 3 智能诊断现场应用

将智能诊断系统应用于某石化厂的机泵设备,设备结构如图5所示。这些设备用于输送高危介质,一旦出现故障,轻则导致生产停止,重则发生火灾、爆炸等灾难性事件。该设备常见故障包括轴承松动、轴承损伤、润滑不良、叶片故障等。



图5 某石化企业机泵设备

在机泵上安装加速度传感器,采集机泵的加速度振动信号,收集历史数据,并将历史数据打上故障标签。将这些数据作为模型的输入,训练智能诊断模型,模型超参数如表5所示。Loss曲线如图6所示。

表5 模型超参数

优化算法	Adam
损失函数	交叉熵
学习率	0.001
Batch size	50
Epoch	50

从图6中可以看到,模型的Loss收敛到了较小的值。

为了研究模型的特征提取效果,将权值参数可视化,如图7、图8所示。从图中卷积核的频域曲线可以看出,卷积层实际上就是一种特定频响的滤波




图6 模型训练Loss曲线

器,将多个卷积层叠加在一起就可以将信号中对于决策重要的频带提取出来。

将训练好的模型部署在云平台上,将该设备实时上传的振动数据作为输入,由诊断结果得到混淆矩阵如表6所示。根据混淆矩阵计算得出Macro\_F1值为91.61%,Micro\_F1值为91.64%,总准确率为91.64%,由此可见所建立的特征自动提取和智能诊断模型具有较好的应用效果。

表6 诊断结论混淆矩阵

		预测故障标签		
		正常	轴承损伤	轴承松动
真实故障标签	正常	111	5	10
	轴承损伤	7	97	2
	轴承松动	2	4	121







图7 卷积核权值示意图(一)

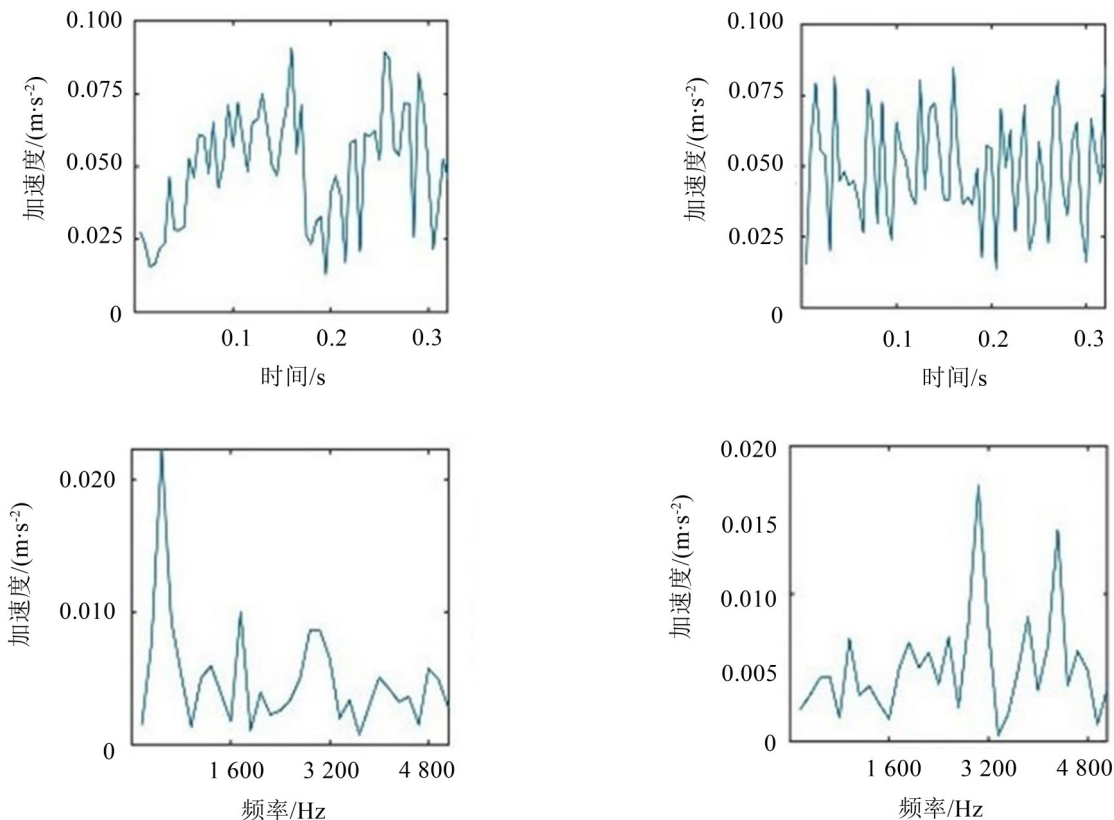


图8 卷积核权值示意图(二)

## 4 结 语

本文提出了两种基于卷积神经网络的智能诊断模型,即基于1DCNN的智能诊断模型和基于2DCNN与小波变换的智能诊断模型。通过两种模型的比较可知,由于振动信号的一维性,基于1DCNN的故障诊断模型相较于二维卷积神经网络,具有准确率高、时间成本低、不受测不准原理限制等优点,并且该模型将特征提取和智能诊断两个阶段合并到一个模型中,实现“端到端”的故障诊断,提高了设备监测的效率。

### 参考文献:

- [1] KONG F, CHEN R. A combined method for triplex pump fault diagnosis based on wavelet transform, fuzzy logic and neuro-networks[J]. Mechanical Systems and Signal Processing, 2004, 18(1): 161-168.
- [2] KOO I S, KIM W W. The development of reactor coolant pump vibration monitoring and a diagnostic system in the nuclear power plant[J]. ISA Transactions, 2000, 39(3): 309-316.
- [3] 贾建明,李得保. 基于EEMD自适应选取IMF的机泵滚动轴承故障诊断[J]. 净水技术, 2018, 37(S1): 164-167+174.
- [4] SAKTHIVEL N R, SUGUMARAN V, BABUDEVASE-
- NAPATI S. Vibration based fault diagnosis of monoblock centrifugal pump using decision tree[J]. Expert Systems with Applications, 2010, 37(6): 4040-4049.
- [5] YUAN S F, CHU F L. Support vector machines-based fault diagnosis for turbo-pump rotor[J]. Mechanical Systems and Signal Processing, 2006, 20(4): 939-952.
- [6] WANG J, HU H. Vibration-based fault diagnosis of pump using fuzzy technique[J]. Measurement, 2006, 39(2): 176-185.
- [7] 任浩,屈剑锋,柴毅,等. 深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策, 2017, 32(8): 1345-1358.
- [8] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- [9] CHEN ZHI QIANG, LI CHUAN, SANCHEZ RENE-VINICIO. Gearbox fault identification and classification with convolutional neural networks[J]. Shock and Vibration, 2015, 390134.
- [10] JEONG HAEDONG, PARK SEUNGTAEE, WOO SUN-HEE, et al. Rotating machinery diagnostics using deep learning on orbit plot images[J]. Procedia Manufacturing, 2016, 5: 1107-1118.
- [11] GUO XIAO JIE, CHEN LIANG, SHEN CHANG QING. Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis[J]. Measurement, 2016, 93: 490-502.

(下转第178页)