

# 基于卷积神经网络的层级化智能故障诊断算法

曲建岭<sup>1</sup>, 余路<sup>1,2†</sup>, 袁涛<sup>1</sup>, 田沿平<sup>1</sup>, 高峰<sup>1</sup>

(1. 海军航空大学青岛校区 航空机电控制工程与指挥系, 山东 青岛 266041;

2. 海军潜艇学院 航海观通系, 山东 青岛 266199)

**摘要:** 传统智能故障诊断算法需要依赖人工特征提取和专家知识, 而旋转机械设备复杂的工作环境和工况使得传统算法在实际应用中缺乏良好的自适应性和泛化性. 针对以上问题, 提出基于卷积神经网络 (Convolutional neural network, CNN) 的层级化故障诊断算法 (CNN based hierarchical fault diagnosis, CNN-HFD). 首先, 将原始振动信号进行分段预处理, 以实现数据扩容; 然后, 分别根据故障类型和故障程度设计多个卷积神经网络, 并将原始振动数据以某一时间步进行分割, 作为卷积神经网络的输入进行训练; 最后, 将待识别信号送入 CNN-HFD 模型, 经过分层故障诊断, 在末端卷积神经网络输出相应故障类别和程度. 通过滚动轴承振动数据库的实验表明, 所提出的算法不仅具有高达 99.5% 以上的故障识别率, 而且在负载发生变化时依然可以保持高达 97% 以上的故障识别率, 具有较好的鲁棒性和泛化性能.

**关键词:** 卷积神经网络; 深度学习; 层级化故障诊断; 滚动轴承; 振动信号

中图分类号: TP206

文献标志码: A

## A hierarchical intelligent fault diagnosis algorithm based on convolutional neural network

QU Jian-ling<sup>1</sup>, YU Lu<sup>1,2†</sup>, YUAN Tao<sup>1</sup>, TIAN Yan-ping<sup>1</sup>, GAO Feng<sup>1</sup>

(1. Department of Electrical Control and Command of Aviation Instrument, Qingdao Branch of Naval Aviation University, Qingdao 266041, China; 2. Department of Navigation and Communication, Naval Submarine Academy, Qingdao 266199, China)

**Abstract:** Traditional intelligent fault diagnosis methods largely depend on manual feature extraction and expert knowledge. However, complex working conditions of rotatory machinery make traditional fault diagnosis lack adaptivity and generalization. Aiming to solve the problems mentioned above, a novel CNN-based hierarchical fault diagnosis algorithm called CNN-HFD is proposed. Firstly, raw temporal vibration signals are segmented to enlarge samples. Then, several simple CNN networks are constructed according to fault categories and severities. Training samples divided by a certain time-step are sent to the CNN. Finally, signals to be identified are utilized as the input of the CNN-HFD. After hierarchical analysis, the fault category and fault severity are output at the end of the model. Experiments on rolling bearing datasets demonstrate that the proposed method can not only achieve 99.5% fault recognition, but also keep a 97% accuracy under variable loads, which verifies its good robustness and generalization.

**Keywords:** convolutional neural network; deep learning; hierarchical fault diagnosis; rolling bearing; vibration signal

## 0 引言

滚动轴承等旋转机械是大型工业生产设备的的重要组成部分, 恶劣的工作环境和复杂的工况使其成为最易于受到损坏的元件之一<sup>[1]</sup>. 一旦发生故障, 将可能给工业生产和操作者的安全带来威胁. 因此, 对旋转机械设备的状态监控和故障诊断一直以来是故障诊断领域研究的热点问题<sup>[2-3]</sup>. 近年来, 机器学

习领域研究的蓬勃发展使得智能故障诊断算法逐渐取代了传统故障诊断算法, 成为目前业界的主流方法. 智能故障诊断算法由特征提取、特征选择和故障分类 3 部分组成<sup>[4]</sup>. 机械设备的故障诊断方法通常由振动数据的采集、分析振动数据并提取故障特征、构建故障分类器等步骤组成<sup>[5]</sup>. 原始振动信号中除了含有与故障相关的信息外, 还含有大量的无

收稿日期: 2018-03-05; 修回日期: 2018-10-16.

基金项目: 国家自然科学基金项目 (51505491); 航空科学基金项目 (20165853040).

责任编辑: 董久祥.

†通讯作者. E-mail: yulu\_china@163.com.

用噪声,若不将噪声有效去除,则会对后续的分析处理造成干扰.因此,特征提取,即从原始信号中提取与设备故障特性相关的信息,常用的方法包括时频分析<sup>[6]</sup>、快速傅立叶变换<sup>[7]</sup>、小波变换<sup>[8]</sup>和时频图分析<sup>[9]</sup>等.对提取后的特征需要进行特征选择,用于舍弃不敏感或无用的特征,对特征实现遴选,达到去伪存真的目的.流形学习<sup>[10]</sup>和主成分分析法<sup>[11]</sup>是目前特征选择的主流算法.将经过筛选后的特征送入故障分类器中,构建和训练合适的分类器用于故障类型的识别.在故障分类器的选择上,反向传播神经网络(Back propagation neural network, BP-NN)<sup>[12]</sup>和支持向量机(Support vector machine, SVM)<sup>[13]</sup>是常用的方法.上述是传统智能故障诊断算法的大致流程,具有以下优点:1)应用范围广泛;2)用于特征提取的算法比较成熟,提取的特征具有明确的物理意义;3)通过合理设置分类器的各项参数指标,部分场景下可以满足对识别率的要求.但是,不可否认,传统智能故障诊断算法也存在一些不可忽视的弊端:1)在特征提取环节,所提取的特征依赖于人工经验和领域内的专家知识,给实际操作者带来使用难度和学习成本.同时,考虑到一种机械设备适用的特征可能在另一种设备中并不能达到良好的效果,需要重新提取、选择合适的特征用于对当前特定设备的故障诊断任务,缺乏灵活性.2)在实际机械设备的运转中,负载不断变化,导致在当前负载下提取的特征在另一种负载下会出现偏差,使得故障诊断模型的识别率在不同负载下差别较大,限制了传统故障诊断模型的泛化能力.

近年来,深度学习理论逐渐成为机器学习领域中炙手可热的学习算法,尤其是在图像处理领域得到了广泛应用.吕恩辉等<sup>[14]</sup>提出了基于反卷积的特征提取算法,克服了梯度下降算法带来的梯度弥散问题,并成功应用于手写体和CIFAR数据集.潘广源等<sup>[15]</sup>针对深度置信网络的最佳隐层数目问题展开研究,提出了基于重构误差的网络深度判别方法,并在手写体数据集中得到验证.

深度学习理论在故障诊断领域的应用也在蓬勃发展. Jia等<sup>[16]</sup>提出了基于自动编码器的滚动轴承故障诊断算法; Lu等<sup>[17]</sup>引入去噪自动编码器对输入信号进行有缺失提取,增加了隐层提取特征的鲁棒性,进一步提高了故障识别率; Gan等<sup>[18]</sup>利用小波包进行特征提取,构建了基于深度信念网的故障诊断算法.基于卷积神经网络的故障诊断研究目前尚处于探索阶段<sup>[19]</sup>,部分学者对此进行了尝试. Chen等<sup>[20]</sup>

提出了基于CNN的齿轮箱故障诊断算法,以时频域特征作为CNN的输入实现故障识别; Zhang等<sup>[21]</sup>建立了自适应CNN故障诊断模型,以原始数据作为输入,免去了对人工特征提取的依赖,并成功应用于电气机车滚动轴承故障诊断.

上述算法虽然已在机械设备故障诊断中得到应用,但是故障识别率仍然有很大的提升空间.机械设备的故障诊断包括故障类型和故障程度识别两部分,识别故障类型可以给相应部件的维修和替换提供指导,因此是对故障诊断最基本的要求.识别故障程度可以为设备的剩余使用寿命提供依据,帮助操作者决定是否需要立即维修.因此,对于一个成熟的故障诊断系统,故障类型和故障程度的识别均必不可少.但是,现有的故障诊断算法在模型建立时,大多没有考虑二者之间的关系,普遍将所有类型样本作为训练模型的训练样本实现故障诊断<sup>[18-21]</sup>.一方面,不同故障类别的同一故障程度的信号之间可能存在高度相关性,会对多类识别造成干扰;另一方面,为了实现较高的故障识别率,部分深度学习算法需要建立更深层次的特征学习模型才能实现,模型需训练的参数通常在 $10^6$ 数量级,增加了训练成本.

基于以上分析,本文提出基于卷积神经网络的层级化故障诊断算法模型CNN-HFD,并建立两级卷积神经网络模型.第1级卷积神经网络只用于识别故障类型,不区分故障程度;第2级卷积神经网络接收第1级的识别结果,并在此基础上进一步识别故障程度.通过层级式故障诊断结构,综合卷积神经网络强大的特征自学习能力,实现以原始振动数据为输入,以故障诊断结果为输出的端到端故障诊断模型.

## 1 一维CNN特征提取算法

CNN属于典型的前馈神经网络,通过在网络中设置多个滤波器,以卷积和池化算子的运算方式实现对蕴含于输入数据中的拓扑结构特征的逐层提取.随着网络层数的递增,网络所提取的特征也不断抽象,最终实现从原始输入数据中提取具有旋转平移不变性的鲁棒特征.

一个典型的CNN包括样本预处理、特征提取和样本分类3部分:样本预处理用于对输入样本进行调整,使其适用于CNN的输入;特征提取由多个滤波级组成,每个滤波级由一个卷积层和一个池化层组成;样本分类是多层感知器结构,由一个或多个全连接层组成,其中最后一个全连接层用作分类.典型的一维CNN如图1所示.




图1 一维CNN模型

1.1 样本预处理

对振动数据而言,在某一采样频率下能覆盖机械设备一个完整冲击的周期需要几十个数据点甚至几百个数据点,因此输入数据通常在  $10^2$  数量级.若卷积核尺寸太小,则覆盖完整输入需要的卷积操作会显著增加,相应地,算法的运算时间也会显著增加;若卷积核尺寸太大,则无法精确获取输入数据中的特征,提取的特征可能会不明显,且包含较多的冗余信息.为了保证卷积核能够充分地提取输入信号的特征,在本文所采用的CNN中引入“时间步”的概念,即将一个完整的输入样本以某一尺度的时间步进行分割,分割成数据点较少的输入数据作为CNN网络的输入,保证了运算速度的同时又将较小的卷积核用于对输入特征的有效提取.

1.2 特征提取

通过交替多个卷积层和池化层实现对输入样本的特征提取.其中,卷积层的作用是将输入信号的局部区域与卷积核进行卷积,在激活函数的作用下产生非线性映射.

卷积层由多个特征面 (Feature map) 组成,每个特征面包含多个神经元,每个神经元与上一层特征面的局部区域通过卷积核连接.在一维CNN中,卷积核通过卷积运算实现对输入信号不同特征的提取.权值向量将当前卷积层的神经元连接到上一层特征面的局部区域,即卷积层中的神经元与其输入层中的特征面进行局部连接,在同一个输入特征面和同一个输出特征面中,CNN的权值共享<sup>[22]</sup>.CNN中每个输出特征面大小  $S_{oFM}$  满足下式:

$$S_{oFM} = \frac{S_{iFM} - w_{Kernel}}{stride} + 1. \quad (1)$$

其中:  $S_{iFM}$  为输出特征面的尺寸,  $w_{Kernel}$  为卷积核大小,  $stride$  为卷积核在上一层的滑动步长.因此,每个卷积层需要训练的参数  $N_{param}$  满足下式:

$$N_{param} = (N_{iFM} \times w_{Kernel} + 1) \times N_{oFM}. \quad (2)$$

其中:  $N_{oFM}$  和  $N_{iFM}$  分别为输出和输入特征面的个数; 1 为偏置,同一输出特征面中偏置共享.

每个卷积核与当前输入的卷积操作的结果输出作为下一层神经网络的输入.设  $K_i^l$  和  $b_i^l$  分别为第  $l$  层第  $i$  个滤波器的权重向量和偏置,  $x_j^l$  为第  $l$  层第  $j$  个局部感受域,则卷积过程表示为

$$y_i^l(j) = f(K_i^l * x^l(j) + b_i^l). \quad (3)$$

其中: “\*” 表示卷积算子;  $y_i^{l+1}(j)$  是该层第  $i$  个特征面中第  $j$  个神经元的输出;  $f(\cdot)$  是激活函数.在CNN中通常选择修正线性单元 (Rectified linear unit, ReLU), ReLU 的优势在于使一部分神经元的输出为 0, 提高了网络的稀疏性,并且减少了参数的相互依存关系,缓解了过拟合问题的发生. ReLU 可由下式表述:

$$f(x) = \max\{0, x\}. \quad (4)$$

池化层是对上一个卷积层输出的缩放映射,执行下采样操作,主要用于减少网络的参数.常采用的池化算子有最大池化 (Max pooling) 和均值池化 (Average pooling).其中,最大池化是将每个特征面感知域的最大值作为最终输出,均值池化则输出感知域内元素的平均值,两者的公式化表述分别为

$$p_{l+1}^i(j) = \frac{1}{w} \sum_{i=(j-1)w+1}^{jw} a_i^l(t), \quad (5)$$

$$p_{l+1}^i(j) = \max_{(j-1)w+1 \leq t \leq jw} \{a_i^l(t)\}. \quad (6)$$

其中:  $a_i^l(t)$  为第  $l$  层中第  $i$  个特征面内第  $t$  个神经元的激活值,  $w$  为池化区域宽度,  $p_{l+1}^i(j)$  为第  $l+1$  层神经元对应的值.交替的卷积和池化过程使模型从原始数据中提取的特征具有区分性和鲁棒性.

1.3 样本分类

样本分类部分由两个全连接层组成,第 1 个全连接层实现“展平”操作,即将所有特征矢量首尾连接

组成一维向量;第2个全连接层的神经元个数与故障类别数目保持一致,利用Softmax回归分类器实现目标输出类别. Softmax回归模型是逻辑回归模型在多元分类问题的推广,类标签 $y$ 具有向量形式,表明当前样本的类别在所有可能类别中的分布概率. Softmax回归模型的损失代价函数可以表示为

$$J(\theta) = -\frac{1}{M} \left[ \sum_{i=1}^m \sum_{j=1}^k 1\{y_i = j\} \lg \frac{e^{\theta_j^T x_i}}{\sum_{l=1}^k e^{\theta_l^T x_i}} \right]. \quad (7)$$

其中: $x_i$ 和 $y_i$ 分别为训练样本的原始数据和所属类别; $m$ 为样本个数, $\theta$ 为训练模型参数集,用于最小化当前代价函数.

## 2 CNN-HFD智能故障诊断算法

### 2.1 CNN-HFD概述

CNN-HFD将故障诊断划分为故障类别识别和故障程度识别两部分,目的是降低不同故障类型、不同故障程度之间的相关性.从直观上来说,这种策略可以简化多分类问题任务.例如,一个机械设备含有 $N$ 个故障类别,每个类别含有 $M$ 种故障程度,若将其均作为故障诊断模型的输入,则总共需要对 $M \times N$ 个类别进行分类.虽然深度学习理论上可以通过增加隐层个数实现更多类别的分类,但会增加模型训练的难度和训练时间.而划分故障类别和故障程度的层级式故障诊断策略则会在提高故障识别率的同时,降低模型训练的难度.虽然基于CNN-HFD需要对多个CNN进行学习,但每个CNN所要完成的分类任务难度降低,通过较少的样本就可以实现对模型的训练,因此CNN-HFD是一种自适应层级式故障诊断策略.

### 2.2 CNN-HFD的训练

在CNN-HFD的训练阶段,采用RMSProp优化算法训练模型<sup>[23]</sup>.RMSProp优化器利用指数衰减平均的方法对遥远过去历史信息的摒弃,使其能够在凸结构后迅速收敛,适用于处理非平稳数据类型,是深度学习广泛使用的优化器.损失函数 $L(\cdot)$ 采用最小均方误差(Mean square error, MSE),表示为

$$\text{mse} = \frac{\sum_{i=1}^N (x_{\text{pred}}^i - x_{\text{true}}^i)^2}{N}. \quad (8)$$

其中: $x_{\text{pred}}^i$ 表示第 $i$ 个样本的预测类别, $x_{\text{true}}^i$ 表示第 $i$ 个样本的真实类别.

为了防止深度学习中的过拟合现象,引入Dropout策略<sup>[24]</sup>,即在训练过程中的每一次迭代中,随机选择一定比例的神经元处于闭合状态,不接收模型参数的调整.在模型测试中保持所有神经元打开,

全部用于对测试样本的验证. Dropout自提出以来,就被广泛应用于深度学习模型训练过程.训练模型的基本实现步骤如下.

输入:全局学习速率 $\varepsilon$ ,初始化参数 $\theta$ ,数值稳定量 $\delta = 10^{-6}$ ,衰减速率 $\rho$ ;

中间变量:梯度累积量 $r$ .

while 没有达到停止准则 do

从训练集中无放回地随机抽取小批量 $m$ 个样本 $\{x_1, x_2, \dots, x_m\}$ ,及其对应输出类别 $\{y_1, y_2, \dots, y_m\}$ .

计算梯度

$$\hat{g} \leftarrow +\frac{1}{m} \nabla_{\theta} \sum_i L(f(x_i; \theta), y_i)$$

累积平方梯度

$$r \leftarrow \rho r + (1 - \rho) \hat{g} e \hat{g}$$

计算参数更新

$$\Delta \theta = -\frac{\varepsilon}{\delta + \sqrt{R}} e \hat{g}$$

应用更新

$$\theta \leftarrow \theta + \Delta \theta$$

end while

### 2.3 CNN-HFD实现方式

本文建立的CNN-HFD故障诊断算法流程如图2所示.其中: $FT_i (i = 1, 2, \dots, N)$ 表示第 $i$ 个故障类型, $FS_i^j$ 表示第 $i$ 类故障下的 $j$ 种故障程度.

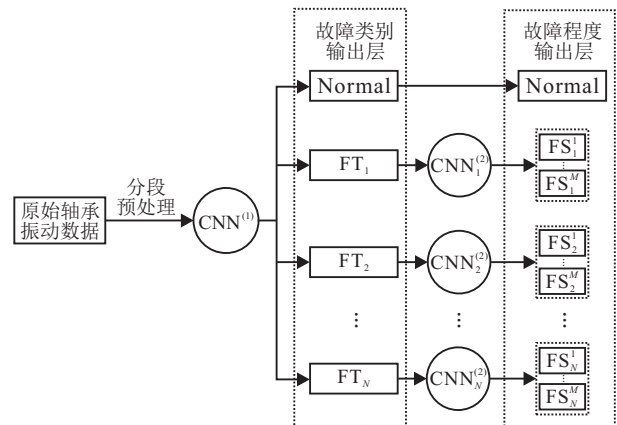


图2 基于CNN-HFD的故障诊断流程

算法包括训练和测试两个部分,具体实现步骤如下.

模型训练阶段:

Step 1: 将不同故障状态、不同故障程度的所有振动数据分为训练集和测试集.

Step 2: 取训练集中数据进行有重叠分段预处理,组成训练样本,并对其进行类别标记.

Step 3: 选择不同故障类型下不区分故障程度的训练样本作为 $\text{CNN}^{(1)} (i = 1, 2, \dots, N)$ 的输入进行

模型训练;选择同一故障类型下不同故障程度的训练样本作为  $CNN_i^{(2)} (i = 1, 2, \dots, N)$  的输入进行模型训练.

模型测试阶段:

Step 4: 将测试集数据进行分段预处理后组成测试样本,作为训练好的  $CNN^{(1)}$  的输入,  $CNN^{(1)}$  输出对故障类型的识别结果.

Step 5: 根据 Step 4 的识别结果将测试样本输入相应的  $CNN_i^{(2)} (i = 1, 2, \dots, N)$  中,模型输出对当前测试样本故障程度的识别结果.

### 3 实验

#### 3.1 实验数据集介绍

为了验证本文所提出的 CNN-HFD 算法对实际机械设备故障诊断的有效性,将凯斯西储大学 (Case Western Reserve University, CWRU) 轴承振动数据库作为实验数据集<sup>[25]</sup>. CWRU 数据集是用于测试振动信号故障诊断算法的开放数据集,被学术界广泛作为故障诊断模型的验证数据.

用于产生轴承故障的实验台如图 3 所示,实验台由 1 491.4 W 三相感应电机 (左侧) 和测力计 (右侧) 组成. 其中,前者用于产生驱动力,后者用于产生额定负载. 在电机的驱动端和风扇端分别安装有加速度传感器用于采集故障轴承的振动信号,采样频率为 12 kHz. 利用电火花加工技术分别在轴承的内圈、外圈和滚动体上引入单点缺陷,设置故障尺寸为 7 inch、14 inch 和 21 inch. 采集不同负载下的振动数据用于实验分析.




图 3 CWRU 实验台

#### 3.2 实验准备

实验选取 1 hp 负载下 10 种滚动轴承状态数据作为实验样本,将所有振动信号数据进行有重叠分割 (本次实验重叠率选择为 80%,可根据样本需要扩大或降低重叠率),组成训练集和测试集,每种状态随机选择 50% 的样本作为训练集,其余作为测试集. 详细的实验样本信息及其对应的类别标记如表 1 所示.

根据选取的实验样本,构建用于本次实验的 CNN-HFD 模型,应包含 4 个 CNN. 其中  $CNN^{(1)}$  模型用于识别故障类别,  $CNN_1^{(2)} \sim CNN_3^{(2)}$  模型用于识别

表 1 实验样本组成

故障信息		样本信息		类别信息	
故障类型	故障程度	样本长度	样本数目	类别标记	程度标记
正常	无	1 024	500	0	无
内圈故障	7 inch	1 024	500	1	0
	14 inch	1 024	500	1	1
	21 inch	1 024	500	1	2
外圈故障	7 inch	1 024	500	2	0
	14 inch	1 024	500	2	1
	21 inch	1 024	500	2	2
滚动体故障	7 inch	1 024	500	3	0
	14 inch	1 024	500	3	1
	21 inch	1 024	500	3	2

故障程度,每个 CNN 模型的参数选择通过网格搜索法确定,最佳参数设置如表 2 所示. 值得指出的是,虽然设定了模型训练的最大迭代次数为 50,但本文引入了 Earlystopping 机制,通过监视训练过程中训练集损失函数在相邻次迭代间的变化值,Earlystopping 可以适时终止模型训练,防止模型过拟合. 若在一定迭代次数内不产生明显变化,则模型训练终止,与 Dropout 的联合操作可以有效防止训练深度学习模型中常见的过拟合现象,有效提高模型的泛化能力.

表 2 CNN-HFD 各参数设置

参数	$CNN^{(1)}$	$CNN_1^{(2)}$	$CNN_2^{(2)}$	$CNN_3^{(2)}$
卷积池化层	2	2	2	3
隐层神经元数目	128, 64	128, 64	128, 64	128, 64, 32
Dropout 比率 / %	25	25	25	25
学习率	0.015	0.015	0.015	0.018
时间步长	32	32	32	32
最大迭代次数	50	50	50	50
卷积核大小	3×1	3×1	3×1	3×1
池化尺寸	2	2	2	2

#### 3.3 实验结果

本文模型建立在基于 python 的 Keras 深度学习库中<sup>[26]</sup>,电脑硬件配置信息为 i5-6 300 HQ 处理器,8 GB 内存, Linux 系统. 每批次迭代平均耗时约 0.375 s,每个模型平均在 16 次迭代后达到终止条件结束训练. 采用 1 hp 下的测试集对每个 CNN 模型的有效性进行验证,实验结果如图 4 和图 5 所示.




图 4 故障类别识别结果

表3 泛化性能实验结果

故障尺寸	正常	内圈故障			外圈故障			滚动体故障			平均识别率
		7 inch	14 inch	21 inch	7 inch	14 inch	21 inch	7 inch	14 inch	21 inch	
2 hp	1	0.990 7	0.986 7	0.990 7	1	1	1	0.984 0	1	0.908 0	0.986 0
3 hp	1	0.941 3	0.937 5	0.941 3	1	0.992 0	1	0.993 3	0.993 3	0.950 9	0.975 0




图5 故障程度识别结果

由图4可见, CNN<sup>(1)</sup>在4类故障类型识别中均达到了100%的识别率;图5的故障程度识别结果表明, CNN<sub>1</sub><sup>(2)</sup> ~ CNN<sub>3</sub><sup>(2)</sup>在内圈故障、外圈故障和滚动体故障程度的识别率分别为100%、100%和98.8% (741/750)的识别率.

3.4 泛化性能实验

机械设备的负载往往是不断变化的,因此将上一节训练的CNN-HFD模型分别选择2hp和3hp负载下的样本进行测试,测试集数据参数除负载不同外,其他与表1保持一致.实验结果如表3所示.由表3可见,随着负载的不断增大,CNN-HFD整体故障识别率呈微弱下降趋势,表现在3hp下内圈故障识别率较2hp有所下滑,而滚动体7inch和21inch故障的识别率有所提高,综合识别率仍然可以达到97.5%,表明本文算法可以应对负载发生变化的情况.

3.5 对比实验

为了比较本文算法与目前主流智能故障诊断算法的优劣,选择具有代表性的反向传播神经网络(Back propagation neural network, BPNN)、堆叠去噪自动编码器(Stacked denoised autoencoder, SDA)、文献[20]的方法、标准CNN以及基于循环神经网络的标准RNN和LSTM等算法进行对比实验.各个智能故障诊断算法的参数设置如下: 1)BPNN:以原始数据作为输入,含有3个隐层,每个隐层神经元个数为20. 2)SVM:将原始振动数据进行4层小波包分解后提取能量特征,采用径向基核函数,惩罚因子为50,核函数半径为0.08. 3)SDA:构建5层网络结构为1024-600-200-100-10,采用tanh激活函数,学习率为0.05. 4)文献[20]的方法:提取原始振动数据的时频域特征值作为卷积神经网络的输入,网络结构含有1个卷积层、1个池化层以及2个全连接层. 5)标准CNN:以原始振动数据作为输入,构建网络为1024-c1(128)-s1(2)-c2(64)-s2(2)-32-10,采用ReLU作为激活函数. 6)基于循环神经网络的两种算法:采用相似的五层网络结构1024-128-64-32-10.选择1hp下振动数据作为训练样本,测试样本为负载在1hp、2hp和3hp的数据,为了避免实验结果的偶然性,反复进行实验20次,实验结果如表4所示.

表4 不同算法对比实验结果 %

算法	1 hp	2 hp	3 hp
BPNN	85.5±1.5	75.5±2.2	70.2±3.8
SVM	91.2±2.1	83.0±3.4	80.5±2.5
SDA	97.6±0.3	96.5±0.4	96.0±0.5
文献[20]方法	93.5±1.2	88.3±1.5	90.5±1.5
标准CNN	99.4±0.2	97.9±0.3	95.5±0.5
LSTM	94.2±0.3	91.3±0.3	89.3±0.2
RNN	92.8±0.5	90.4±0.6	87.6±0.5
RNN-HFD	97.2±0.2	94.2±0.3	91.3±0.3
LSTM-HFD	96.6±0.3	93.5±0.3	90.6±0.3
CNN-HFD	99.6±0.2	98.3±0.3	97.2±0.3

由表4可以看出,基于浅层网络结构的BP-NN和SVM在识别率上较采用深度学习结构的其他4种算法有差距,特别是当负载发生变化时,识别率下降程度较大.SDA虽然取得了较高的识别率,但其隐层数目和神经元个数都较多,导致模型需要训练的参数

急剧增多,增加了模型的训练时间. 文献[20]虽然也采用了CNN的网络结构,但其输入的特征仍然依赖于人工提取,因此当负载发生变化时,这些特征并不具有很好的鲁棒性和自适应性. 由于本文采用了层级化故障诊断(Hierarchical fault diagnosis, HFD),简化了CNN模型需要学习的故障信息,识别率高于标准CNN算法. 对比基于LSTM和RNN的故障诊断模型不难看出,基于CNN的模型具有更高的识别率. 另外,相比于标准模型,采用HFD结构的模型具有更高的识别率.

同时,为了比较不同后端分类器的作用效果,将本文模型的故障分类阶段分别采用SVM、BPNN、随机森林(Random forest, RF)和本文所采用的Softmax四种算法作为分类器进行实验,特征提取部分依然与本文CNN结构保持一致. 其中:SVM采用径向基核函数,惩罚因子为30,核函数半径为0.08;随机森林设置最大树深度为2;BPNN拥有3个隐层,每个隐层神经元数目为20. 以1 hp下样本数据作为训练和测试样本,实验结果如表5所示.

表5 不同后端分类器实验结果 %

模型	故障类型	内圈故障	外圈故障	流动体故障
CNN+SVM	96.2	99.7	95.3	96.4
CNN+BPNN	84.3	85.6	82.4	88.3
CNN+RF	99.5	100	99.8	98.2
CNN+Softmax	100	100	100	98.8

由表5可见,在不同后端分类器的实验结果中,采用随机森林和Softmax分类器均可以达到较高的识别率,且Softmax分类器具有最高的识别率.

## 4 结论

本文建立的CNN-HFD是一种基于深度学习的层级化故障诊断模型,具有以下3个优点:1)利用CNN强大的特征提取能力,不依靠人工特征提取和专家知识,直接利用原始振动信号进行故障诊断. 2)将故障诊断模型划分为故障类型和故障程度识别的层级式结构,最大限度地减弱了故障之间的相互干扰. 3)具有较强的泛化能力,即使负载发生变化也依然能够保持较高的故障识别率. 但是,不可否认,CNN-HFD也存在不足之处:CNN模型的最佳参数设置依赖于网格搜索的策略;在模型的训练时间上,CNN-HFD与标准CNN算法总体训练时间接近,并没有显著提高;在模型的可扩展性上,还无法实现对新故障的有效识别,这都将是下一步的重点研究方向.

## 参考文献(References)

- [1] Lei Y, Lin J, He Z, et al. A review on empirical mode decomposition in fault diagnosis of rotating machinery[J]. *Mechanical Systems & Signal Processing*, 2013, 35(1/2): 108-126.
- [2] Shao H, Jiang H, Zhao H, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis[J]. *Mechanical Systems & Signal Processing*, 2017, 95(C): 187-204.
- [3] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. *仪器仪表学报*, 2018, 39(7): 134-143.  
(Qu J L, Yu L, Yuan T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network[J]. *Chinese J of Scientific Instrument*, 2018, 39(7): 134-143.)
- [4] Zhang W, Peng G, Li C, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals[J]. *Sensors*, 2017, 17(2): 425.
- [5] 余路, 曲建岭, 高峰, 等. 基于改进稀疏编码的微弱振动信号特征提取算法[J]. *仪器仪表学报*, 2017, 38(3): 711-717.  
(Yu L, Qu J L, Gao F, et al. Feature extraction of weak vibration signal based on improved sparse coding[J]. *Chinese J of Scientific Instrument*, 2017, 38(3): 711-717.)
- [6] 蔡剑华, 胡惟文, 王先春. 基于高阶统计量的滚动轴承故障诊断方法[J]. *振动、测试与诊断*, 2013, 33(2): 298-301.  
(Cai J H, Hu W W, Wang X C. Rotor fault diagnosis based on Higer-order statistics[J]. *J of Vibration, Measurement & Diagnosis*, 2013, 33(2): 298-301.)
- [7] He Y, Huang J, Zhang B. Approximate entropy as a nonlinear feature parameter for fault diagnosis in rotating machinery[J]. *Measurement Science & Technology*, 2012, 23(4): 45603-45616.
- [8] 龙英, 何怡刚, 张镇, 等. 基于信息熵和Haar小波变换的开关电流电路故障诊断新方法[J]. *仪器仪表学报*, 2015, 36(3): 701-711.  
(Long Y, He Y G, Zhang Z, et al. Switched-current fault diagnosis based on entropy and Haar wavelet transform[J]. *Chinese J of Scientific Instrument*, 2015, 36(3): 701-711.)
- [9] 张云强, 张培林, 吴定海, 等. 基于CSLBP的轴承信号时频特征提取方法[J]. *振动、测试与诊断*, 2016, 36(1): 22-27.  
(Zhang Y Q, Zhang P L, Wu D H, et al. Time-frequency feature extraction method based on cs-lbp for bearing signals[J]. *J of Vibration, Measurement & Diagnosis*,

- 2016, 36(1): 22-27.)
- [10] 苏祖强, 汤宝平, 姚金宝. 基于敏感特征选择与流形学习维数约简的故障诊断[J]. 振动与冲击, 2014, 33(3): 70-75.  
(Su Z Q, Tang B P, Yao J B. Fault diagnosis method based on sensitive feature selection and manifold learning dimension reduction[J]. J of Vibration and Shock, 2014, 33(3): 70-75.)
- [11] Hu B, Li B. A new multiscale noise tuning stochastic resonance for enhanced fault diagnosis in wind turbine drivetrains[J]. Measurement Science & Technology, 2016, 27(2): 1-14.
- [12] Wang H, Chen P. Intelligent diagnosis method for rolling element bearing faults using possibility theory and neural network[J]. Computers & Industrial Engineering, 2011, 60(4): 511-518.
- [13] 焦卫东, 林树森. 整体改进的基于支持向量机的故障诊断方法[J]. 仪器仪表学报, 2015, 36(8): 1861-1870.  
(Jiao W D, Lin S S. Overall-improved fault diagnosis approach based on support vector machine[J]. Chinese J of Scientific Instrument, 2015, 36(8): 1861-1870.)
- [14] 吕恩辉, 王雪松, 程玉虎. 基于反卷积特征提取的深度卷积神经网络学习[J]. 控制与决策, 2018, 33(3): 447-454.  
(Lv E H, Wang X S, Cheng Y H. Deep convolution neural network learning based on deconvolution feature extraction[J]. Control and Decision, 2018, 33(3): 447-454.)
- [15] 潘广源, 柴伟, 乔俊飞. DBN网络的深度确定方法[J]. 控制与决策, 2015, 30(2): 256-260.  
(Pan G Y, Chai W, Qiao J F. Calculation for depth of deep belief network[J]. Control and Decision, 2015, 30(2): 256-260.)
- [16] Jia F, Lei Y, Lin J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical Systems & Signal Processing, 2016, 72/73: 303-315.
- [17] Lu C, Wang Z Y, Qin W L, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. Signal Processing, 2017, 130(C): 377-388.
- [18] Gan M, Wang C, Zhu C. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings[J]. Mechanical Systems & Signal Processing, 2016, 72/73(2): 92-104.
- [19] 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): 345-358.  
(Ren H, Qu J F, Chai Y, et al. Deep learning for fault diagnosis: The state of the art and challenge[J]. Control and Decision, 2017, 32(8): 345-358.)
- [20] Chen Z Q, Li C, Sanchez R V. Gearbox fault identification and classification with convolutional neural networks[J]. Shock and Vibration, 2015(2): 1-10.
- [21] Zhang W, Peng G, Li C. Rolling element bearings fault intelligent diagnosis based on convolutional neural networks using raw sensing signal[C]. Proc of the 12th Int Conf on Intelligent Information Hiding and Multimedia Signal Processing. Taiwan: Springer, 2017: 77-84.
- [22] 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.  
(Zhou F Y, Jin L P, Dong J. Review of convolutional neural network[J]. Chinese J of Computers, 2017, 40(6): 1229-1251.)
- [23] Goodfellow I, Bengio Y, Courville A, et al. Deep learning[M]. Cambridge: MIT Press, 2016: 303-304.
- [24] Srivastava N, Hinton G E, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. J of Machine Learning Research, 2014, 15(1): 1929-1958.
- [25] Loparo K. Case western reserve university bearing data centre website[EB/OL]. (2017-12-10)[2018-01-05]. <http://csegroups.case.edu/bearingdatacenter/pages/download-data-file>.
- [26] Chollet. Keras[EB/OL]. (2017-09-20)[2017-12-31]. <https://github.com/keras-team/keras>.

### 作者简介

曲建岭(1968—), 男, 教授, 博士, 从事飞参信号处理、深度学习等研究, E-mail: qujianling@tom.com;

余路(1989—), 男, 助教, 博士, 从事深度学习、振动信号分析的研究, E-mail: yulu\_china@163.com;

袁涛(1976—), 男, 副教授, 硕士, 从事飞参信号处理的研究, E-mail: yuyulu\_qd@163.com;

田沿平(1989—), 女, 讲师, 硕士, 从事信号处理与故障诊断的研究, E-mail: dhyanping@163.com;

高峰(1967—), 女, 副教授, 硕士, 从事飞参信号处理等研究, E-mail: gaofeng\_qd@tom.com.

(责任编辑: 齐 霖)