

# 基于改进卷积神经网络 CNND 的电主轴 轴承故障诊断方法

石怀涛<sup>1,2</sup>, 乔思康<sup>1</sup>, 丁健华<sup>1</sup>, 王子男<sup>1</sup>, 白晓天<sup>1</sup>

(1. 沈阳建筑大学机械工程学院, 辽宁 沈阳 110168;

2. 沈阳建筑大学高档石材数控加工装备与技术国家地方联合工程实验室, 辽宁 沈阳 110168)

**摘要** 目的 解决深度学习方法在建立电主轴轴承故障诊断模型时出现的过拟合现象,提高电主轴轴承故障诊断准确率. 方法 提出一种基于改进卷积神经网络的诊断方法,该方法在卷积神经网络的训练过程中融入 Dropout 优化方法,使整个故障诊断模型按照一定的比例随机“关闭”隐藏层中的神经元,减少模型在每一次训练过程中所需要调整的参数数量. 结果 将 Dropout 优化方法与卷积神经网络相结合所建立的电主轴轴承故障诊断模型是可行的,其平均诊断准确率能够达到 99.012%,远高于基于 CNN、CNN + L2 和 BPNN 这 3 种神经网络诊断方法的诊断准确率. 卷积神经网络方法相比于传统的“基于信号处理提取到的特征和机器学习模型”方法,更适用于电主轴轴承故障诊断. 结论 提出的 CNND 方法实现了卷积神经网络与 Dropout 优化方法的有机结合,对原始数据进行降维处理使模型学习到的特征更利于电主轴故障的分类,同时根据故障数据的特点确定相关参数的初始值,克服一般深度学习方法在进行电主轴故障诊断时出现的过拟合现象,提高诊断准确率.

**关键词** 故障诊断;电主轴;深度学习;卷积神经网络;Dropout 优化方法

中图分类号 TH502.15 文献标志码 A

## Fault Diagnosis Method of Motorized Spindle Bearing Based on CNND

SHI Huaitao<sup>1,2</sup>, QIAO Sikang<sup>1</sup>, DING Jianhua<sup>1</sup>, WANG Zinan<sup>1</sup>, BAI Xiaotian<sup>1</sup>

(1. School of Mechanical Engineering, Shenyang Jianzhu University, Shenyang, China, 110168; 2. National Engineering Laboratory of High-grade Stone Material Numerical Machining Equipment and Technology, Shenyang Jianzhu University, Shenyang, China, 110168)

**Abstract:** A diagnosis method based on an improved convolutional neural network for fault diagnosis of motorized spindle bearing was proposed to solves over-fitting phenomenon in the deep-learning method occurred when the fault diagnosis model of the motorized spindle bearing is

收稿日期:2018-05-20

基金项目:国家自然科学基金项目(51705341,51905357,51675353);国家重点研发计划项目(2017YFC0703903);辽宁省自然科学基金项目(2016010623);沈阳市科技计划项目(F17-231-1-28,F16-096-1-00)

作者简介:石怀涛(1982—),男,副教授,博士,主要从事电主轴故障诊断方法方面研究.

established which improves its fault diagnosis accuracy. In this method the dropout optimization method was integrated into the convolutional neural network training process to make the entire fault diagnosis model randomly “Turn off” neurons in the hidden layer according to a certain proportion. So the number of parameters adjusted were reduced in the model during each training session. The results show that the fault diagnosis model based on the combination of dropout optimization method and convolutional neural network is feasible. The average diagnostic accuracy can reach 99.012%, which is much higher than other fault diagnosis methods which are CNN, CNN + L2 and BPNN. The convolutional neural network method is more suitable for the fault diagnosis of the motorized spindle bearing than the traditional method whose feature and machine learning model were obtained based on signal processing. The method proposed in this paper is the organic combination of convolutional neural network and Dropout optimization method. The feature of CNND obtained base on the original data processed by dimensionality reduction is more conducive to classify the fault of the motorized spindle bearing. Simultaneously, the initial value of the relevant parameters determined base on the fault data characteristics can improve the diagnostic accuracy by avoiding over-fitting phenomenon which happens in the fault diagnosis of spindle by general deep learning methods.

**Key words:** fault diagnosis; motorized spindle; deep learning; convolutional neural network; dropout optimization method

电主轴作为高档数控机床的核心部件,其运行状态直接影响加工产品的质量与精度<sup>[1-2]</sup>.电主轴通常是在润滑不当、空气潮湿、负载过大等复杂工况下运行,极易受到外界干扰.因此,电主轴经常会发生转子轴承系统不对中、转子轴承系统不平衡、转子轴承系统碰摩、机械松动、转定子碰摩与机械松动耦合、转子裂纹等故障.电主轴一旦发生故障轻则使加工产品精度降低,重则会使整个生产线瘫痪,造成重大经济损失<sup>[3]</sup>.目前,“基于信号处理提取到的特征和机器学习模型”是电主轴发生故障时最常用的故障诊断方法<sup>[4]</sup>.这一类故障诊断方法存在许多不足:第一,基于信号处理提取故障特征的方法,需要技术人员掌握大量的信号处理技术且具有丰富的工程实践经验,且对每个特定的故障诊断任务都要设计特定的故障特征提取器,这一过程需消耗大量的时间且效率较低<sup>[3]</sup>.第二,利用机器学习方法所构建的故障诊断模型认为特征提取与智能诊断是相互独立的两个环节,并没有考虑二者之间的关系,这使得模型在执行智能诊断环节时存在误差,故障诊断准确率不高<sup>[5]</sup>.第三,利用机器学习

方法建立的模型在训练方面,使用的是结构比较简单的浅层模型训练方法,其对结构复杂的函数表达能力明显不足,极易出现局部最优以及泛化能力差等问题.深度学习是机器学习的一种方法,在人工智能领域具有很大发展前景,深度学习方法被广泛应用于机械故障诊断领域<sup>[6]</sup>.深度学习采用无监督学习方式,相较于传统的机器学习方法增加了多级特征提取结构,在不需要人为先验经验的前提下,能够自动地对数据进行学习,提取出更加抽象且更加有效的数据特征,并用于故障分类,实现故障诊断. D. T. Hoang 和 H. J. Kang<sup>[5]</sup>将深度学习中的深度置信网络(DBN)、深度玻尔兹曼机(DBM)和稀疏自编码器(SAE)方法直接对轴承故障原始信号的时域、频域进行最低级故障特征的提取,然后从这些低级故障特征中学习更高级的特征,克服了基于信号处理提取故障特征的不足.提出一种基于卷积神经网络和振动图像的滚动轴承故障诊断方法,即CNN提取振动图像的特征后,对其进行分类并识别出轴承的故障.该方法将特征提取与智能诊断两个环节联系在一起,避免了将两个环节视为

独立过程而引发的诊断误差. 孙文珺等<sup>[6]</sup>提出一种将两个算法相结合的感应电动机故障诊断方法,即稀疏降噪自编码器与深度神经网络相结合,利用稀疏降噪自编码器自动去学习复杂数据的内在特征,并且将提取出的特征用于训练深度神经网络建立的模型,该模型结构复杂,含有多个隐藏层,对复杂的非线性函数的表示能力强<sup>[7]</sup>,且故障诊断的准确率高于浅层模型. 利用深度学习方法所建立的故障诊断模型均具有多个隐藏层,模型的隐藏层越多参数就越多,越容易出现过拟合现象. 笔者提出一种改进卷积神经网络 (Convolutional Neural Network Dropout, CNND) 方法,用于电主轴轴承故障诊断. 该方法实现了卷积神经网络与 Dropout 优化方法的有机结合,对原始数据进行降维处理使模型学习到的特征更利于电主轴故障的分

类,同时根据故障数据的特点确定相关参数的初始值,克服一般深度学习方法在进行电主轴故障诊断时出现的过拟合现象. 笔者针对电主轴轴承故障进行仿真,该模型在避免出现过拟合现象的同时提高了电主轴的故障诊断准确率,实现了对电主轴的故障诊断,为解决电主轴故障诊断技术奠定了理论基础.

1 深度学习基础理论

1.1 CNN 结构原理

CNN 主要是针对图像数据处理问题而提出的,也可以将其理解为多层神经网络模型的变种,其独特的网络结构在处理高维数据时所展现出的能力<sup>[8-9]</sup>. CNN 网络主要结构如图 1 所示<sup>[10]</sup>.




图 1 CNN 结构图

Fig. 1 CNN structure

(1)卷积层. 卷积层中有两个核心结构,一个是稀疏连接,另一个是参数共享. 传统神经网络结构中相邻层的神经元之间为全连接,全连接的神经网络参数过多、运行速度缓慢、需要运行内存空间足够大且容易陷入局部最优. 而卷积层中的稀疏连接是指相邻层之间的神经元是局部连接,且只针对局部区域进行建模并提取局部区域的数据特征,局部连接最大的优点在于可以减少需要优化的参数以及简化计算过程<sup>[11]</sup> (见图 2). 从图 2 中可以看出,对于第  $m$  层上的第一个神经元,只与第  $m-1$  层上临近的 3 个神经元相连,以此类推,实现稀疏连接. 且第  $m$  层的神经元  $y_1$ 、 $y_2$  和  $y_3$ ,它们的参数都为  $w_1$ 、 $w_2$ 、 $w_3$ , 缩减参数数量的同时提高学习速度.




图 2 卷积层中的权值共享结构图

Fig. 2 Weight sharing structure diagram in convolution layer

CNN 网络通过稀疏连接和参数共享两个原理,实现了对输入数据的降维处理,并且能够自动提取原始数据的优秀特征.卷积层中,最重要的操作是卷积操作<sup>[12]</sup>.

$$x_k^l = g \sum_{i \in N_k} x_i^{l-1} \cdot C_{ik}^l + b_k^l. \tag{1}$$

式中: $l$  为模型的层; $C$  为卷积核; $N_k$  为  $l-1$  层的第  $k$  个特征图; $b$  为输出层的偏置; $g$  为激活函数,一般激活函数采用的是 ReLU,取值范围是  $[0, \infty)$ ,可将所有取值映射到所有正数域,同时还能够避免发生梯度消失的问题.

(2) 池化层. 又被称为下采样层,或是 pooling<sup>[13]</sup>,其工作原理为降低输入数据规模的同时,又可以对数据的各个维度进行空间采样;增强网络泛化能力的同时,又具有局部线性转换的不变性<sup>[14]</sup>. Max - pooling 是池化层用来表达局部区域特征最常用的方法,通过提取局部特征最大值来表示区域特征<sup>[15]</sup>. 卷积与池化的完美结合,使得卷积神经网络模型具有更强的学习能力.

$$y = \max(x, axis = 1). \tag{2}$$

式中: $y$  为输出值; $x$  为输入值.

(3) 全连接层. 全连接层的作用是将卷积层和池化层对数据进行处理后得到的高层抽象进行映射,并最终对其进行分类<sup>[16]</sup>.

$$y = f(w \cdot x + b). \tag{3}$$

式中: $w$  为参数; $b$  为偏置项.

1.2 Dropout 优化方法

Dropout 优化方法是用来解决模型出现过拟合现象的方法. Dropout 优化方法的主要思想是在每一次迭代的过程中,按照一定比例随机让一部分隐藏层节点失效,使失效部分的隐藏层节点不参加正向传播的训练过程<sup>[17]</sup>. 在每次训练过程中,都会将失效的隐藏层神经元的权值保留下来,但不会在当前迭代中更新(见图 3),每次迭代训练重复此操作. 并在最终诊断时,要求所有的隐藏层神经元都参与进行计算,好比将多个不同结构

的网络结合在一起<sup>[18]</sup>. 笔者将 Dropout 优化方法与 CNN 网络进行结合,避免出现过拟合现象的同时提高模型的精度.




图 3 Dropout 优化方法训练图

Fig. 3 Training diagram of dropout optimization method

2 改进卷积神经网络的电主轴故障诊断模型

CNN 网络是由多个卷积层、池化层以及非线性激活函数交替组成,卷积层中的输入是由上一层的权重与局部区域共同作用的,且每一层都运用卷积运算并将运算结果非线性化.池化层会对卷积层的输出结果进行筛选,选出最具代表的故障数据特征,这样的网络结构增强了对复杂函数的表达能力.笔者首先利用有监督特征学习的 CNN 网络对原始数据进行特征提取,然后在搭建网络模型、配置参数将 Dropout 优化方法加入到 CNN 网络的训练过程与全连接层中,完成整个网络的训练与微调,称为 CNND. 对于 CNN 网络来说,特征提取主要通过卷积层、激活函数以及池化层共同作用,将提取到的特征通过全连接层的 softmax 分类器进行故障识别,由于全连接层的参数过多,加入 Dropout 优化方法之后可以提高模型的预测能力以及泛化能力;且在训练过程中加入到 Dropout 优化方法可以提高模型的可靠性. 方法流程如图 4 所示.



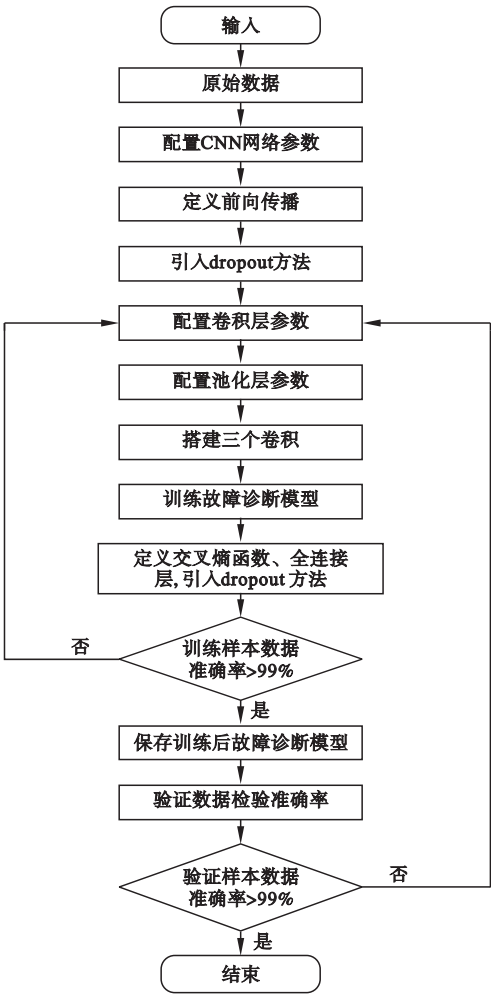


图 4 改进卷积神经网络方法流程图

Fig. 4 The flow chart of improved convolutional neural network method

步骤 1:用有标签的原始故障数据序列  $X = \{x_1, x_2, \cdots, x_N\}$ 、训练 CNN 网络,调整输入数据格式,配置 CNN 网络的参数(见表 1)。

表 1 CNN 网络的结构参数

Table 1 Structural parameters of CNN network				
层类型	卷积核 & Maxpooling	深度	滑动步长	特征数量
卷积层 1	5 × 5	1	5	32
池化层 2	2 × 2	1	2	32
卷积层 3	5 × 5	32	5	64
池化层 4	2 × 2	32	2	64
卷积层 5	5 × 5	64	2	128
池化层 6	2 × 2	64	2	128
第一个全连接层	—	—	—	625

步骤 2:定义故障模型的前向传播过程,添加参数 train 并设置训练过程中适时保存模型,在训练过程中加入 Dropout 优化方法。

步骤 3:定义卷积层的输入,卷积核的尺寸大小、卷积核的数量、移动的步数、深度以及卷积核使用的是全 0 填充,将输入数据与卷积核做的卷积运算输出为

$$O_i = f(w \cdot a_{i,i+h-1} + b).$$

式中: $f$  为激活函数; $h$  为故障数据个数。

ReLU 为非线性化函数:

$$f(x) = \max(0, x).$$

步骤 4:池化层对卷积层的输出进行最大池化操作,选取卷积层中特征值最大的作为池化层的特征值,定义池化层过滤器的尺寸大小,过滤器可以减少整个网络的参数数量,加快运行的速度。

步骤 5:共需要搭建 3 个卷积层,则重复上面的步骤 3 到步骤 4 过程,重新定义各层的卷积核尺寸以及大小、移动的步数、深度以及池化层过滤器的大小、尺寸等参数。

步骤 6:定义两个全连接层和交叉熵函数,并在第一个全连接层中加入 Dropout 优化方法,使模型在测试数据上的效果更好。输出层使用 softmax 函数:

$$h(z_j) = \frac{e^{z_j}}{\sum_k^{10} e^{z_k}}.$$

式中: $z_j$  表示第  $j$  个神经元的值。

令  $p(X)$  表示目标分布,  $q(X)$  表示估计分布,则  $p(X)$  和  $q(X)$  之间的交叉熵函数式为

$$G(p, q) = - \sum_x p(X) \log q(X).$$

式中: $X$  为原始故障数据序列。

步骤 7:若训练样本数据准确率 < 99%, 则执行与之前相同的反向传播算法,迭代更新权值并对整个网络进行微调。

步骤 8:用验证样本数据测试模型的准确率,输出结果,完成诊断任务。

3 电主轴轴承故障仿真与分析

3.1 改进卷积神经网络方法

电主轴通常是在高转速、高功率等复杂的工况中运行,长期在这样的环境中运行会使电主轴的轴承受到安装、冷却以及润滑等因素的影响,并使电主轴系统产生不同类型的故障.电主轴的健康状态直接影响产品的加工精度以及工作效率,因此需要及时对电主轴轴承故障进行诊断,故障形式主要表现为转子轴承系统不平衡、转子轴承系统不对中、滚动轴承故障等<sup>[1-2]</sup>几个方面:

(1)转子轴承系统不平衡.由于转子受材质不均匀、制造误差等初始不平衡的影响,造成转子质量偏心.转子在运行中受到磨损、腐蚀以及疲劳力的作用会使转子轴承系统达到新的不平衡造成零部件局部损坏、脱落、碎块飞出等现象.

(2)转子轴承系统不对中.当电主轴存在安装误差、负载过重产生的变形以及基础沉降不均匀等现象时,会造成电主轴在工作状态时的各转子轴线不平行或不重合,使电主轴发生联轴器偏转、轴承早期损坏、电主轴发生异常振动等现象.

(3)滚动轴承故障.在电主轴故障中,滚动轴承故障是最容易发生的,滚动轴承是由外圈、内圈、滚动体以及保持架组成,且最容易发生故障的位置是球、内圈以及外圈.引发滚动轴承故障的原因很多,如润滑不足使表面产生磨损、设计不符合标准使轴承产生应力集中等.

3.2 仿真结果与分析

为验证基于改进卷积神经网络对电主轴轴承故障诊断的效果,仿真主要针对的电主轴故障为:转子轴承系统不对中、转子轴承系统不平衡以及轴承外圈中度故障. CNND 方法需要大量的实验数据去训练,以此来提高模型的精度.笔者仿真中共获取转子轴承系统不对中、转子轴承系统不平衡、轴承外圈中

度故障以及正常情况下,每种故障状况下的样本各 10 000 组,且每组样本有 1 024 个数据点.对每种故障数据随机选出 50% 用作训练样本,35% 用作测试样本,以及 15% 用作验证样本(见表 2).为排除外界干扰,仿真共重复进行 15 次.

表 2 电主轴故障类型以及仿真样本数

Table 2 Fault types of motorized spindle and the number of simulation samples

故障类型	训练样本/个	测试样本/个	验证样本/个
转子轴承系统不对中	5 000	3 500	1 500
转子轴承系统不平衡	5 000	3 500	1 500
轴承外圈故障	5 000	3 500	1 500
正常	5 000	3 500	1 500

3.2.1 4 种方法仿真准确率对比

由于 Dropout 优化方法和正则化 L2 优化方法对故障诊断模型在防止出现过拟合现象中都有一定的作用,因此笔者还提出了将正则化方法 L2 与 CNN 网络(CNN + L2)进行结合建立故障诊断模型和没有加入任何防止过拟合方法的 CNN 网络建立故障诊断模型两种方法作为比较对象,与 CNND 进行比较得出 3 个方法的最终诊断准确率.理论上,对于隐藏层来说,一般取 0.5 比例的 Dropout 优化方法能够使模型的效果比较好,但是,实践中取 0.3 比例的 Dropout 方法能够使模型接近最优效果,所以仿真中所有的 Dropout 优化方法都取 0.3 比例,并且通过调整整个网络的其他参数,使网络达到最佳效果.后向传播神经网络<sup>[19-22]</sup>(Back Propagation Neural Network, BPNN)作为常用的一种神经网络方法实现了输入输出的非线性映射,使得对参数进行优化以减小误差得到更优结果,但同时也会出现局部最小化的问题. CNND 方法、CNN + L2 方法、CNN 方法以及 BPNN 方法的诊断率都如图 5 所示.每个全连接层的神经元的个数为 1024,且第二层全连接层的输出为 4 种故障类型的准确率.




图5 4种方法的电主轴故障诊断仿真准确率对比

Fig.5 Fault diagnosis accuracy of motorized spindle based on four methods

从图5可以看出,CNND方法15次仿真中的准确率在99.34%~97.26%,误差在0.66%~2.74%,且CNND方法的准确率一直高于其他方法的准确率曲线.CNN+L2方法15次仿真的准确率为97.58%~98.56%.没有加入任何防止出现过拟合现象的CNN方法15次仿真的诊断准确率结果为97.64%~98.42%.这两种方法的准确率变化幅度相对平缓,诊断结果最终也趋于稳定.

从图5中还可以看出,CNN+L2和CNN方法的准确率曲线几乎重合,并且两者准确率范围也基本相同.这是因为CNN网络的卷积层结构中的稀疏连接和池化层中采用的Max-plooping方法,都能够使其本身也具有防止放生过拟合现象的能力,虽然L2优化方法对防止出现过拟合现象有作用,但是这个作用相比于Dropout优化方法效果差很多.用BPNN方法建立故障诊断模型,并对同样的故障数据进行学习,其准确率如图5所示,BPNN方法的15次仿真的诊断准确率结果在61.0692%~70.778%,且准确率曲线一直低于其他方法的准确率曲线,随着仿真的次数增加准确率呈下降的趋势,曲线的波动也较大.表3为4种方法15次仿真的诊断准确率.从表3可以看出,CNND方法的平均诊断准确率最高,15次仿真中,平均诊断准确率在99.012%;而BPNN方法的故障

诊断准确率最低,15次仿真中,平均诊断准确率才为65.08%,且最大准确率与最小准确率之间的差值为9.7088%,BPNN方法准确率差值过大,方法不稳定.这是因为BPNN方法只能处理浅层模型,对于复杂问题的表达能力较弱,容易陷入局部最优,导致梯度消失,使其误差变大,准确率降低.因此,CNN网络是适用于建立电主轴故障诊断模型,且Dropout优化方法可以有效地减少过拟合现象的发生并提高模型的准确率.

表3 4种方法15次仿真的诊断准确率

Table 3 Diagnostic accuracy of 15 simulations based on four methods

方法	平均诊断 准确率/%	最大准确 率/%	最小准确 率/%
CNND	99.012	99.34	97.26
CNN+L2	98.36	98.56	97.58
CNN	98.29	98.42	97.64
BPNN	65.08	70.778	61.069 2

3.2.2 4种方法的故障仿真

为了验证CNND方法的特征提取能力,利用主成分分析方法提取这些特征的前3个主成分,并进行可视化.

图6为CNND方法提取特征的主成分散点.从图6可以看到电主轴同一种故障已经可以很好地聚集在一起,并且已经将不同种故障有效地区分开,只有少量的轴承不对中以及轴承不平衡故障散点聚集在一起,最终获得了99.012%的平均诊断准确率.

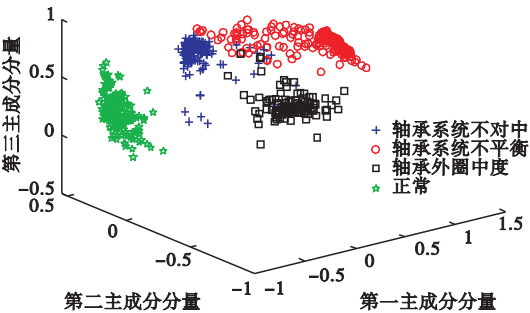


图6 CNND的故障仿真图

Fig.6 Fault simulation diagrams of CNND

图7为CNN+L2方法提取特征的主成分散点.从图7中可以看到,电主轴正常状况下的主成分散点已经很好地聚在一起,只是剩下的轴承系统不对中与轴承系统不平衡以及轴承外圈中度还有极少的一部分散点进行交叉.

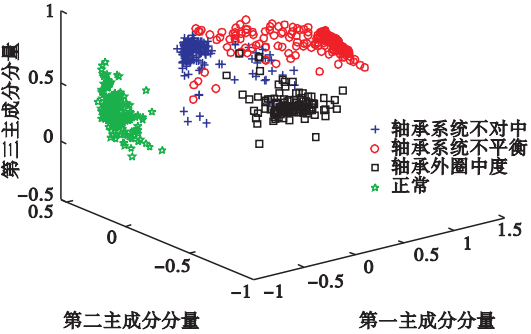


图7 CNN+L2 的故障仿真图

Fig. 7 Fault simulation diagrams of CNN + L2

图8为CNN方法提取特征的主成分散点,其主成分散点图与CNN+L2的主成分散点图相似,差距不大,说明CNN+L2方法中的L2优化方法不能使模型有效地避免出现过拟合现象,但是与CNND主成分散点图相比还是有一些差距.

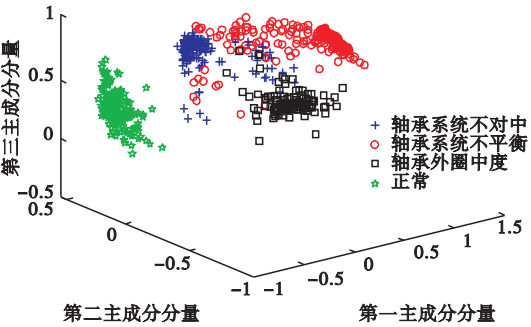


图8 CNN 的故障仿真图

Fig. 8 Fault simulation diagrams of CNN

图9为单隐藏层BPNN方法提取特征的主成分散点图,从图9中可以看到,电主轴的各种故障相互交错,没有呈现出规律的聚集模式,说明单隐藏层BPNN方法的特征提取能力相比于其他3种方法最弱.因此,CNND方法更适合于电主轴故障诊断.




图9 单隐藏层BPNN的故障仿真图

Fig. 9 Fault simulation diagrams of a single hidden layer BPNN

4 结 论

(1)卷积神经网络可以有效提取数据特征,使模型更容易分类,加入Dropout优化方法后,可以使神经元之间的相互作用减弱,提高模型的特征提取能力,让卷积神经网络的学习能力更强,提取到更适合分类的数据特征.

(2)基于改进卷积神经网络电主轴轴承故障诊断方法整体的分类效果要比CNN+L2、CNN以及BPNN方法好,具有更强的优化能力,能够有效地将每一种故障区分开,提高模型的诊断准确率.

(3)将CNND方法应用于电主轴故障诊断中,该方法的平均诊断准确率为99.012%,不仅实现了故障的分类,而且可以有效地避免过拟合现象.

参考文献

[1] 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.  
(REN Hao,QU Jianfeng,CHAI Yi,et al. Deep learning for fault diagnosis: the state of the art and challenge[J]. Control and decision,2017, 32(8):1345-1358.)  
[2] KESHTAN M N, KHAJAVI M. Bearing fault diagnosis using vibrational signal analysis by EMD method[J]. Research in nondestructive evaluation,2016,27(3):155-174.  
[3] 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 Yaguo, 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.)
- [4] SUN Y, WEN G, MALHOTRA B. Cognitive gravitation model-based relative transformation for classification[J]. Soft computing, 2017, 21(18): 5425 – 5441.
- [5] HOANG D T, KANG H J. Rolling element bearing fault diagnosis using convolutional neural network and vibration image[J]. Cognitive systems research, 2018(1): 42 – 50.
- [6] 孙文珺, 邵思羽, 严如强. 基于稀疏自动编码深度神经网络的感应电动机故障诊断[J]. 机械工程学报, 2016, 52(9): 65 – 71.  
(SUN Wenjun, SHAO Siyu, YAN Ruqiang. Induction motor fault diagnosis based on deep neural network of sparse auto-encoder[J]. Journal of mechanical engineering, 2016, 52(9): 65 – 71.)
- [7] LEE G, TAI Y W, KIM J M. Deep saliency with encoded low level distance map and high level features[C]. Las Vegas: Proceedings of the IEEE conference on computer vision and pattern recognition, 2016.
- [8] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Boston: Proceedings of the 2015 IEEE conference on computer vision and pattern recognition, 2015.
- [9] DONG C, CHEN C L, HE K, et al. Image super-resolution using deep convolutional networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2016, 38(2): 295 – 307.
- [10] LI S M, LEI G Q, FAN Ru. Depth maps super-resolution reconstruction based on convolutional neural networks[J]. Acta optica sinica, 2017, 37(12): 1210002.
- [11] ZHENJIANG W, ZHENJIANG W. A diagnosis method of bearing fault signal based on deep convolutional neural network[J]. Boletintecnico/technical bulletin, 2017, 55(4): 177 – 185.
- [12] ALAWAD M, LIN M. Stochastic-based convolutional networks with reconfigurable logic fabric[J]. IEEE transactions on multi-scale computing systems, 2017, 2(4): 242 – 256.
- [13] ZHENG Z, ZHENG L, YANG Y. A discriminatively learned CNN embedding for person re-identification[J]. ACM transactions on multimedia computing, communications, and applications, 2017, 14(1): 13.
- [14] SUN J, XIAO Z, XIE Y. Automatic multi-fault recognition in TFDS based on convolutional neural network[J]. Neuro computing, 2017, 222: 127 – 136.
- [15] 彭开香, 马亮, 张凯. 复杂工业过程质量相关的故障检测与诊断技术综述[J]. 自动化学报, 2017, 43(3): 349 – 365.  
(PENG Kaixiang, MA Liang, ZHANG Kai. Review of quality-related fault detection and diagnosis techniques for complex industrial processes[J]. Acta automatica sinica, 2017, 43(3): 349 – 365.)
- [16] YANG J, YANG M H. Top-down visual saliency via jointCRF and dictionary learning[J]. IEEE transactions on pattern analysis and machine intelligence, 2016, 39(3): 576 – 588.
- [17] 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望[J]. 自动化学报, 2016, 42(5): 643 – 654.  
(DUAN Yanjie, Lü Yisheng, ZHANG Jie, et al. Deep learning for control: the state of the art and prospects[J]. Acta automatica sinica, 2016, 42(5): 643 – 653.)
- [18] ZHANG Q, YANG L T, CHEN Z. Deep computation model for unsupervised feature learning on big data[J]. IEEE transactions on services computing, 2016, 9(1): 161 – 171.
- [19] 陈久宁. 基于变分模型和深度学习的脉冲噪声去除算法研究[D]. 上海: 华东师范大学, 2019.  
(CHEN Jiuning. On impulsive noise removal algorithms based on deep learning and variational model[D]. Shanghai: East China Normal University, 2019.)
- [20] 刘赛, 何军红, 薛文琦, 等. 采用复合特征提取与 LM-BPNN 的故障诊断方法[J]. 机械科学与技术, 2019(1): 1003 – 8728.  
(LIU Sai, HE Junhong, XUE Wenqi. Fault diagnosis method by using composite feature extraction and LM-BPNN[J]. Mechanical science and technology for aerospace engineering, 2019(1): 1003 – 8728.)
- [21] LEI Yaguo, HE Zhengjia, ZI Yingying. EEMD method and WNN for fault diagnosis of locomotive roller bearings[J]. Expert systems with applications, 2011, 38(6): 7334 – 7341.
- [22] JIA F, LEI Y G, 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 and signal processing, 2016, 72: 303 – 315.  
(责任编辑: 徐玉梅 英文审校: 唐玉兰)