

# 基于集合经验模态分解的滚动轴承智能故障诊断方法<sup>①</sup>

陈永毅<sup>②</sup> 张丹<sup>③</sup> 薛焕新

(浙江工业大学信息工程学院 杭州 310023)

(浙江大丰实业股份有限公司 杭州 315400)

**摘要** 针对滚动轴承工作环境中含有强烈的环境噪声,其振动信号具有非平稳、非线性特征以及提取特征困难等问题,本文提出一种基于集合经验模态分解(EEMD)的滚动轴承智能故障诊断方法。首先通过卷积神经网络(CNN)提取振动信号关键特征,并将提取到的特征向量输入到支持向量机(SVM)中进行故障识别与分类。为了提高诊断性能,本文利用集合经验模态分解方法对原始振动信号进行分解,将复杂的振动信号分解为仅包含单一成分的本征模态分量(IMF),然后利用一维卷积神经网络对 IMF 进行特征提取,最后采用 SVM 进行分类。结果表明,所提出的方法相比于现有方法收敛速度更快,诊断正确率可高达 99%,突出了该方法的优越性。

**关键词** 故障诊断;滚动轴承;集合经验模态分解(EEMD);卷积神经网络(CNN);支持向量机(SVM)

## 0 引言

随着科学技术和自动化技术的迅速发展,机械设备在日常生活中的应用越来越广泛,其安全性、精密性成为了大家关注的焦点。滚动轴承作为现代机械设备的关键器件,其工作状态是否正常直接影响到整个机械设备的平稳运行。据相关数据显示,在现代机械中,由于滚动轴承无法正常使用而引起的机械故障约占总体故障的 30%<sup>[1]</sup>。此外,滚动轴承因污垢、锈蚀、润滑油缺少发生的磨损常常导致其极易损坏,如果按照设计寿命定期维修,便会出现两种情况。一是在正常使用期限内发生损坏,从而导致发生严重的意外事故;二是把超过使用期限但仍能正常使用的滚动轴承直接扔掉,造成不必要的浪费<sup>[2]</sup>。传统的滚动轴承检测方法,工作人员需要定期将滚动轴承从设备上拆卸下来进行安全检查,但这种方法既耗费人力和时间,又要支付巨额维护

费用,严重影响生产进程。此外,滚动轴承故障振动信号中含有强烈的环境噪声,具有非平稳、非线性特征以及提取特征困难等问题,如何设计合理的故障检测和诊断方法成为学者研究关注的焦点。

滚动轴承的故障诊断一般分为 3 步:第 1 步需要将采集到的原始信号进行预处理。常见的信号预处理方法有傅里叶变换、小波变换、经验模态分解等。第 2 步是对处理后的信号进行特征提取。传统的特征提取方法,即使用先进的技术完成了一些高性能的工作,但是绝大多数的工作仍然依赖于手工的特征提取和故障分类,人工干预仍然至关重要。随着深度学习技术的不断发展,通过卷积神经网络(convolutional neural network, CNN)<sup>[3,4]</sup>对信号进行自适应的特征提取成为了一种主流,其中一维卷积神经网络对于一维的时域信号有很强表征能力,能够对关键特征进行有效提取。第 3 步是对提取出的特征进行分类,诊断出故障类型。王攀攀等人<sup>[5]</sup>提

① 国家自然科学基金(61873237)和宁波市科技创新 2025 重大专项项目资助。

② 男,1997 年生,硕士生;研究方向:故障诊断;E-mail: woosa1997@foxmail.com

③ 通信作者,E-mail: danzhang@zjut.edu.cn

(收稿日期:2020-03-08)

出了利用骨干微粒群算法和支持向量机(support vector machine, SVM)诊断电机定子故障, 利用最优模型参数和训练集构造 SVM 分类器, 实现感应电机的故障诊断。史丽萍等人<sup>[6]</sup>利用最优小波树和反向传播(back propagation, BP)神经网络相结合的方法对感应电动机定子进行故障诊断。候文擎等人<sup>[7]</sup>提出了基于改进堆叠降噪自编码的滚动轴承故障分类方法, 其基于 PSO-SDAE 网络的诊断方法在泛化性、故障识别率方面均优于深度置信网络(deep belief network, DBN)、BP 以及 SVM。李东东等人<sup>[8]</sup>提出了基于一维卷积神经网络和 Softmax 分类器的风电机组行星齿轮箱故障检测方法, 利用一维卷积神经网络和 Softmax 分类器能够有效地提取出故障特征, 并能达到较高的诊断准确率。胡莺庆等人<sup>[9]</sup>提出了基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法, 利用经验模态分解与卷积神经网络相结合的方法, 能够有效地预处理原始数据, 并将处理后的数据通过卷积神经网络进行特征提取, 最后借助 Softmax 分类器进行分类, 提高了故障诊断准确率。

在众多故障诊断研究工作中, 基于深度学习的故障诊断的精度确实有了很大的提高, 但也存在一些原始信号不能进行有效预处理的问题, 降低了故障诊断的质量。针对经验模态分解方法存在的模态混叠问题, 本文提出了基于集合经验模态分解和卷积神经网络的滚动轴承智能故障诊断方法, 对采集到的原始振动信号进行集合经验模态分解(ensemble empirical mode decomposition, EEMD), 将原始的振动信号分解为  $n$  个本征模态分量(intrinsic mode function, IMF), 并利用一维卷积神经网络对于一维时域信号表征能力强的特点, 对 IMF 分量进行特征提取, 将提取出来的特征作为 SVM 的输入进行分类, 从而达到故障诊断的目的。最后通过美国西储大学轴承数据中心公布的标准数据进行测试, 证明所提出的方法比现有方法性能更好。

## 1 集合经验模态分解方法

### 1.1 经验模态分解

1998 年 Huang 等人<sup>[10]</sup>提出了经验模态分解

(empirical mode decomposition, EMD) 方法, 该方法在处理非线性非平稳信号时相比于其他方法具有明显的优势。EMD 方法基于信号本身的局部特征时间尺度, 可以自适应地将原始信号分解成一组性能较好的本征模态分量。每一阶 IMF 包含了原始信号的不同频率信息, 通过对这些 IMF 进行分析, 便可获得信号的局部信息特征。IMF 必需满足以下两个条件, 即所选数据的极值点数目和过零点数目相等或至多相差一个, 数据的极大值的包络和极小值的包络的平均值为零。

EMD 分解步骤<sup>[11]</sup>如下。

(1) 找出原始信号  $X(t)$  的所有局部极大值点  $X_{\max}$  和局部极小值点  $X_{\min}$ 。

(2) 利用三次插条的方法根据所有局部极大值点  $X_{\max}$  创建上包络线  $X_{\max}(t)$ , 根据所有局部极小值点  $X_{\min}$  创建下包络线  $X_{\min}(t)$ 。

(3) 计算出上包络线和下包络线的均值  $m(t)$ 。

$$m(t) = \frac{X_{\max}(t) + X_{\min}(t)}{2} \quad (1)$$

(4) 计算原始信号与均值的差值  $h(t)$ 。

$$h(t) = X(t) - m(t) \quad (2)$$

(5) 若不满足 IMF 的条件, 把  $h(t)$  作为原始信号, 继续循环以上 4 步, 直到差值满足上面所提到的 IMF 必需满足的两个条件。若满足条件, 得到本征模态分量  $c_i$ , 原始信号减去差值作为新的原始信号。

$$r_i = X(t) - h(t) \quad (3)$$

(6) 判断新的原始信号是否含有至少两个极值点, 如果有, 重复循环以上各步骤, 如果没有, 残差等于原始信号, EMD 分解结束。

$$X(t) = \sum_i^n c_i + r_n \quad (4)$$

其中,  $r_n$  为残余函数。

### 1.2 集合经验模态分解

集合经验模态分解方法是由文献[12]在求解非定常信号时提出的一种自适应信号分解方法。使用 EMD 对信号进行预处理时, 会出现模态函数相互重叠的现象, 会使得到的本征模态分量失去意义。为了抑制模态混叠现象的出现和找到有效的特征向量, 本文采用集合经验模态分解的方法, 通过在对原

始信号进行经验模态分解之前加入高斯白噪声,并对加入了白噪声的原始信号进行多次 EEMD 分解,得到多个本征模态分量。EEMD 分解的流程图如图 1 所示,其算法具体步骤如下。

(1) 向原始信号  $x(t)$  中加入  $M$  次正态分布的白噪声  $b_k(t)$ , ( $k = 1, 2, \dots, M$ ), 即

$$x_k(t) = x(t) + b_k(t) \quad (5)$$

(2) 对加入了白噪声的  $x_k(t)$  进行多次 EEMD 分解, 得到  $n$  个 IMF 分量  $m_{ij}(t)$ , ( $j = 1, 2, \dots, n$ ) 以及残余项  $r(t)$ 。其中  $m_{ij}(t)$  表示第  $i$  次加入白噪声得到的第  $j$  个 IMF 分量。

(3) 将每次得到的 IMF 分量做集成平均运算, 得到原始信号  $x(t)$  经 EEMD 的最终结果为

$$m_j(t) = \frac{1}{M} \sum_{i=1}^M m_{ij}(t) \quad (6)$$

$$x(t) = \sum_i^n m_j(t) + r(t) \quad (7)$$

其中,  $m_j(t)$  为  $M$  个带白噪声信号得到的 IMF 分量总体均值信号。

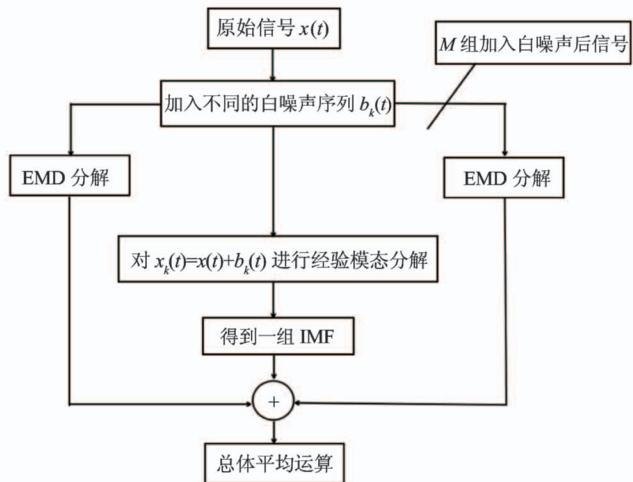


图 1 EEMD 分解的流程图

选取滚动轴承滚动体故障振动信号进行 EEMD 分解, 原始振动信号和分解后各 IMF 分量如图 2 所示。

## 2 卷积神经网络架构与算法原理

深度学习是指通过建立深层神经网络, 利用训练数据集来挖掘同类数据之间的隐藏关系, 同时也

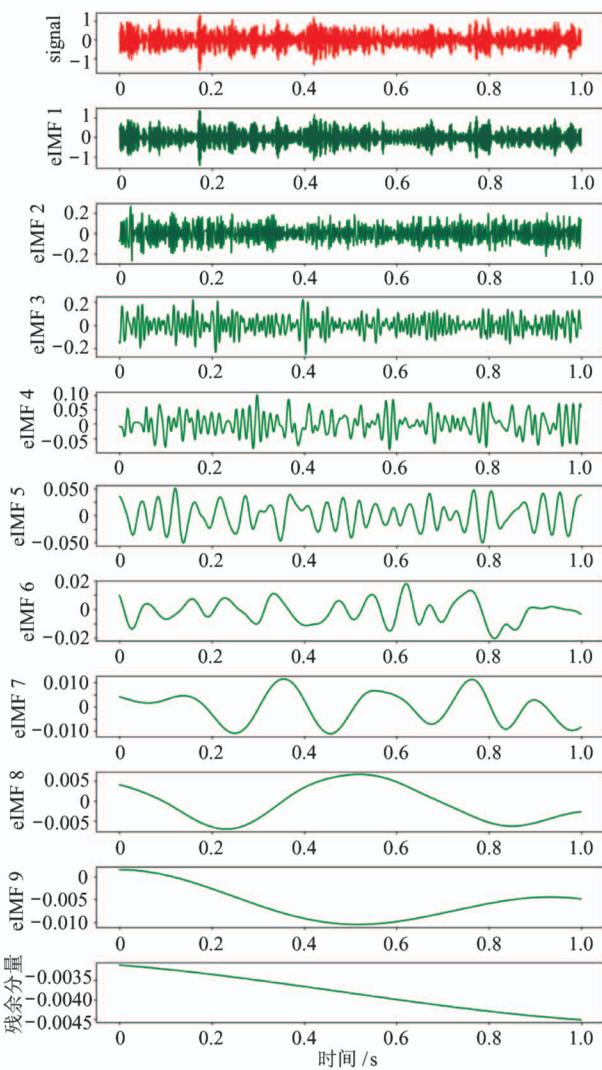


图 2 EEMD 分解结果图

能对不同类别数据之间的特征进行有效提取, 从而提高分类或者预测的准确度, 在大数据处理方面取得了显著的成果<sup>[13]</sup>。近年来, 以 CNN<sup>[14]</sup> 为重要组成部分的深度学习在语音识别、图像识别和数据挖掘等领域都取得了巨大的成就<sup>[15]</sup>。

### 2.1 卷积神经网络的结构

受到人类大脑处理所接收到的外界信息的启发, Cun 等人<sup>[16]</sup>于 1994 年提出了卷积神经网络模型, 并随着深度学习技术不断发展。卷积神经网络模型基本上主要由卷积层、池化层和全连接层组成, 如图 3 所示。自此以后, 通过卷积神经网络对原始数据进行特征提取成为了一种主流, 其中的一维卷积神经网络对于一维的时域信号有很强表征能力, 能够对其关键特征进行有效提取。

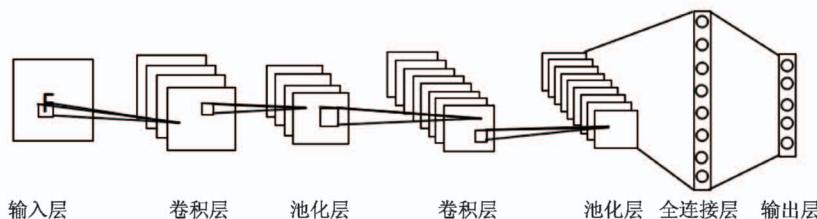


图 3 卷积神经网络结构

## 2.2 卷积层

卷积层通过将上一层的输入图像或特征图与多个卷积核进行卷积操作,以实现特征的提取。卷积层具有局部感知和权值共享的特性,可以极大程度地减少所要训练的网络参数,减少计算量。卷积层的计算如式(8)所示。

$$a_j^l = \sum_{i \in M_j} X_i^{l-1} * \mathbf{K}_{ij}^l + b_j^l, X_j^l = f(a_j^l) \quad (8)$$

其中,  $X_j^l$  是第  $l$  层的第  $j$  个特征映射的激活值;  $M_j$  是该层的特征图谱的数量;  $X_i^{l-1}$  是第  $l$  层的第  $j$  个特征映射;  $\mathbf{K}_{ij}^l$  为权重矩阵;  $b_j^l$  是偏置项; “ $*$ ” 为卷积算子;  $f(\cdot)$  为非线性激活函数, 将非线性引入到多层神经网络中。典型的激活函数有 sigmoid、tanh 和 ReLU, 通常选用 ReLU 激活函数。与传统的、常用的 sigmoid、tanh 等激活函数相比, ReLU 激活函数在特征提取过程中具有非线性特性, 训练效果更好。数学表示式为

$$f(x) = \max\{0, x\} \quad (9)$$

## 2.3 池化层

卷积层之后是池化层, 池化层被用来缩小特征图的尺寸, 通过降低特征图的维数, 来实现降低模型需要训练的参数数量, 避免过拟合现象的发生。池化层通过下采样因子加强提取特征的鲁棒性, 典型的池化操作分为平均池化和最大池化。池化操作通过取某个( $L_x \times L_y$ )区域, 并输出一个值, 该值是该区域的均值或最大值, 使得输出的图像在两个维度上都缩小了  $L$  倍。

将池化函数表示为  $downsample(\cdot)$ , 对于每个  $X_j^l$  有

$$S_j^l = downsample(X_j^l) \quad (10)$$

## 2.4 全连接层和输出层

在大部分情况下, 在卷积层和池化层之后, 会连接几个全连接层, 目的是整合卷积层或者池化层中

能够有效区分不同类别的局部特征信息。实现全连接需要大量的权值参数, 为了提升卷积神经网络的整体性能, 全连接层的激活函数一般采用 ReLU 函数。其前馈过程与标准人工神经网络(artificial neural network, ANN)相同。

$$a_j^l = \sum_{i \in M_j} X_i^{l-1} \mathbf{W}_{ij}^l + b_j^l, X_j^l = f(a_j^l) \quad (11)$$

其中,  $\mathbf{W}_{ij}^l$  和  $b_j^l$  分别为权重矩阵和偏置项。

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, 再将误差值反向传播<sup>[17]</sup>。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

$$E = -\frac{1}{n} \sum_{k=1}^n [y_k \ln t_k + (1 - y_k) \ln (1 - t_k)] \quad (12)$$

其中,  $n$  为该类别的样本数目,  $t_k$  为预测值,  $y_k$  为真实值。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。训练过程中, 前向传播计算误差值, 再通过反向传播, 将输出层的标签预测产生的误差回传到输入层。根据这些误差, 可以逐层更新权重向量和偏置项, 这些参数的更新公式如下。

$$\mathbf{W}_{ij}^l = \mathbf{W}_{ij}^{l-1} + \eta \frac{\partial E}{\partial \mathbf{W}_{ij}^{l-1}} \quad (13)$$

$$b_i^l = b_i^{l-1} + \eta \frac{\partial E}{\partial b_i^{l-1}} \quad (14)$$

式中,  $\eta$  为卷积神经网络的学习率。

神经网络的最后一层通常使用 Softmax 分类器来进行不同类别数据的分类。具有固定维数的特征向量是前一层的输出, 作为输入输入到 Softmax 分类器, Softmax 分类器将最后一层的输出转变为基本概率分布, 来对输入数据的类标签进行预测。

## 2.5 dropout 层

卷积神经网络模型参数数量庞大, 模型复杂, 虽

然展示出了强大的功能,但当实验数据相对过少时,便可能会出现过拟合现象,即模型在训练集上能表现出较高的准确率,但在测试集上却表现较差,这将导致较差的预测性能。为了避免过拟合现象的发生,采用了 dropout 正则化方法,在全连接层后边加入了 dropout 层,如图 4 所示,通过设置参数,全连接层中的神经元将以一定概率失活。实验证明,dropout 是减少深度神经网络过拟合现象的最有效方法,从而使得 CNN 在测试集上表现得很好。

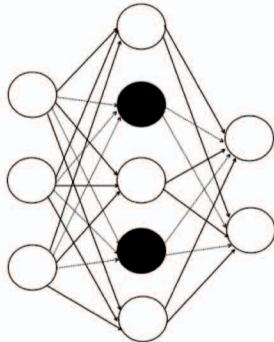


图 4 基于 dropout 的神经网络模型

### 3 支持向量机

自支持向量机(SVM)的方法被提出以后,SVM 就得到了迅速发展,并通过引入核函数来处理各类非线性问题,在训练数据集中表现出良好的泛化能力,实现了较高的准确率。通常使用的核函数主要有 4 种,即线性核函数、多项式核函数、Sigmoid 核函数和径向基核函数。

SVM 通过找到一个超平面,能够将不同类别的样本进行有效划分,使得样本集中的点到这个分类超平面的最小距离最大化,即求解最大分类间隔。最终确定出所有的最大分类间隔对应的超平面,便实现了对样本集的分类,二维空间的 SVM 二分类如图 5 所示。

针对滚动轴承数据集样本数量可能不足的问题,本文引入针对小样本数据分类效果更为稳定的 SVM 分类器。本文采用径向基函数(radial basis function,RBF)做 SVM 的核函数,RBF 表达式为

$$k = \exp(-\gamma \cdot d^2) \quad (15)$$

其中  $d$  表示两点间的距离。

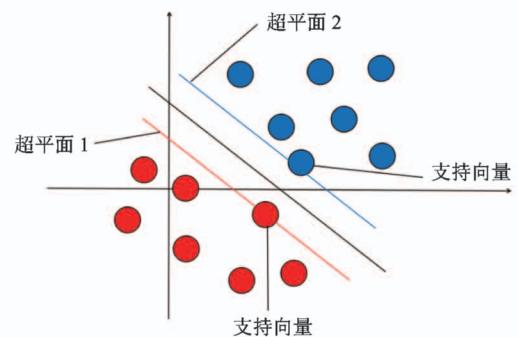


图 5 二维空间 SVM 二分类示意图

由式(15)可知,  $\gamma$  越大支持向量越少,  $\gamma$  值越小支持向量越多。支持向量的个数影响训练与预测的速度。SVM 在参数选择上,选择了  $\gamma = 0.1$  和  $C = 0.8$ 。其中  $C$  是惩罚系数,即对误差的宽容度。 $C$  越高,说明越不能容忍出现误差,容易过拟合。 $C$  越小,容易欠拟合。在处理非线性信号的过程中,SVM 能有效地克服神经网络中存在的收敛速度慢、欠拟合、过拟合等缺点<sup>[18-22]</sup>。基于 SVM 的分类方法采用的是基于结构风险最小化原则,而不是通常在神经网络中实现的最小化经验误差原则。通过选择适当的核函数,将输入空间转换为线性可分离的高维空间,并得到高维空间的最优线性超平面<sup>[23]</sup>。SVM 可以有效避免神经网络中的局部极小化和过拟合问题,从而潜在地实现更高水平的全局性能。

### 4 实验及结果分析

#### 4.1 实验数据集

为了验证本文所提方法的有效性,本文使用美国西储大学轴承数据中心<sup>[24]</sup>的实验数据进行了验证,实验平台如图 6 所示。此次实验对象为图 7 中

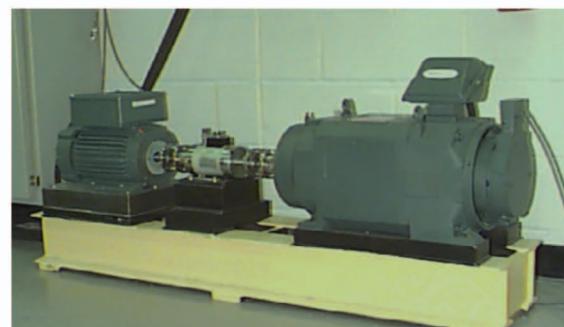


图 6 轴承实验平台



图 7 SKF 型深沟球轴承

的驱动端轴承 SKF 型深沟球轴承, 参数见表 1。

表 1 滚动轴承 SKF 参数

| 滚子直径/mm | 节圆直径/mm | 滚子数 | 接触角/° |
|---------|---------|-----|-------|
| 7.5     | 39      | 9   | 0     |

本实验的采样频率为 12 kHz, 负载为 735 W。选取了正常状态下的数据以及外圈故障、内圈故障、滚动体故障这 3 种损伤, 故障程度分别为 0.007 inch,

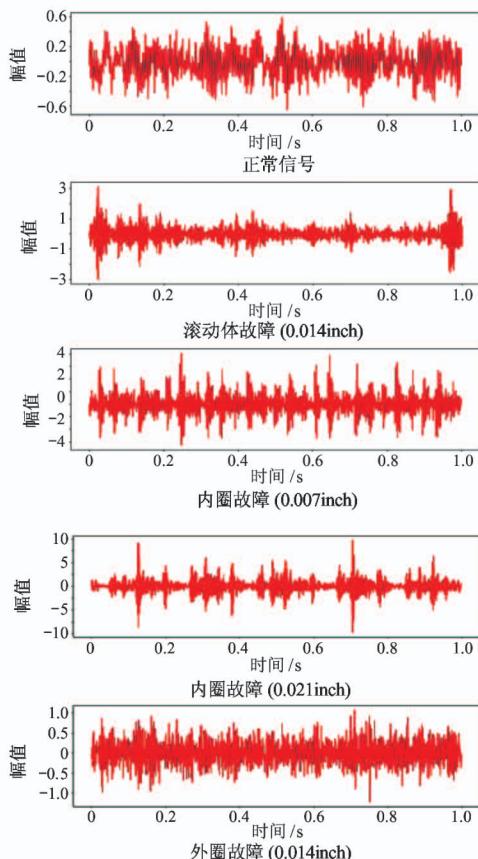


图 8 正常信号与滚动体故障、内圈故障、外圈故障的对比图

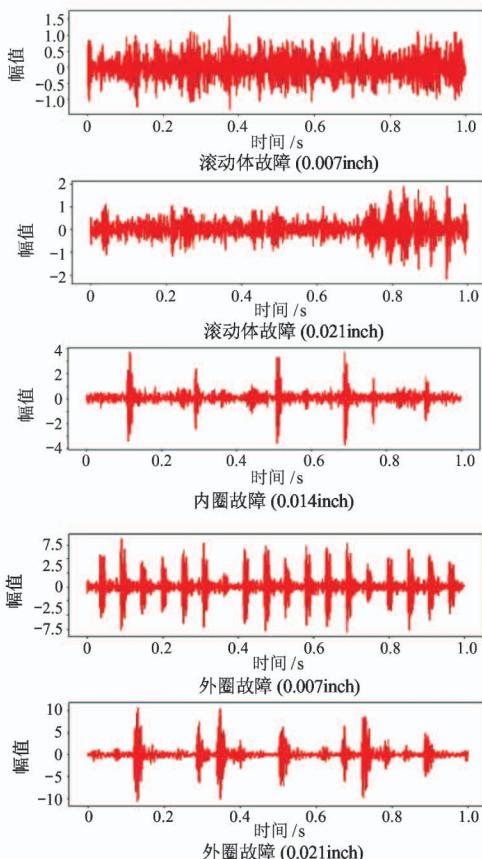
0.014 inch 和 0.021 inch, 共计 9 种不同故障状态的数据来进行实验的验证。实验数据如表 2 所示, 每种状态有 1000 个训练样本和 500 个测试样本, 每个样本含有 2048 个采样点, 共计 1500 个数据。

表 2 实验数据

| 故障类型  | 故障信息      | 样本长度 | 样本数目 | 类别标记 |
|-------|-----------|------|------|------|
| 滚动体故障 | 0.007inch | 2048 | 1500 | 0    |
| 滚动体故障 | 0.014inch | 2048 | 1500 | 1    |
| 滚动体故障 | 0.021inch | 2048 | 1500 | 2    |
| 内圈故障  | 0.007inch | 2048 | 1500 | 3    |
| 内圈故障  | 0.014inch | 2048 | 1500 | 4    |
| 内圈故障  | 0.021inch | 2048 | 1500 | 5    |
| 外圈故障  | 0.007inch | 2048 | 1500 | 6    |
| 外圈故障  | 0.014inch | 2048 | 1500 | 7    |
| 外圈故障  | 0.021inch | 2048 | 1500 | 8    |
| 正常    | 无         | 2048 | 1500 | 9    |

#### 4.2 信号预处理

采集到的原始振动信号具有非平稳、非线性的特点, 图 8 为正常信号与滚动体故障(0.007 inch、



0.014 inch、0.021 inch)、内圈故障(0.007 inch、0.014 inch、0.021 inch)、外圈故障(0.007 inch、0.014 inch、0.021 inch)的对比图。如果直接对原始振动信号进行特征提取,很难提取到最优的特征,对后续的故障诊断过程产生不利的影响。

本文采用集合经验模态分解的方法对采集到的原始振动信号进行预处理,向非平稳的原始信号中加入 $M$ 次正态分布的白噪声,对加入白噪声的原始信号进行多次EEMD分解,得到 $n$ 个IMF分量以及残余项,并将每次得到的IMF分量做集成平均运算,得到原始信号经EEMD分解后的最终结果。

### 4.3 故障特征提取

将滚动轴承数据经过EEMD处理后,针对生成的 $n$ 个IMF分量构建神经网络,神经网络模型的损失函数是基于Softmax的交叉熵损失函数。具体方

法是将每个IMF分量视为一个通道的信号,在前5层构建多通道的一维卷积神经网络,即第1层卷积神经网络的输入通道为 $n$ ,所构建的神经网络结构图如图9所示,一维卷积神经网络中各结构参数如表3所示。利用训练集对CNN进行训练,将提取的 $n$ 个IMF分量输入到所构建的卷积神经网络模型中进行训练,其中训练的具体方法采用的是Adam梯度下降方法,批量大小为128,迭代次数为500,训练完成后,保持CNN模型参数不变。相比于传统的梯度下降方法,Adam方法参数的更新不受梯度的伸缩变换影响,可以自动调整学习率,计算更加高效。通过卷积神经网络对IMF分量进行特征提取,不仅能够对单个IMF分量的特征进行有效提取,也能够对多个IMF分量联合的相关性特征进行提取。

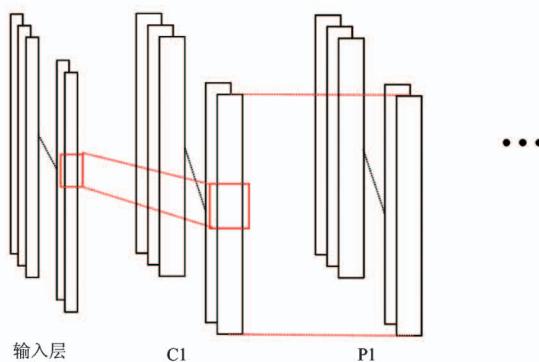


图9 所构建的神经网络结构图

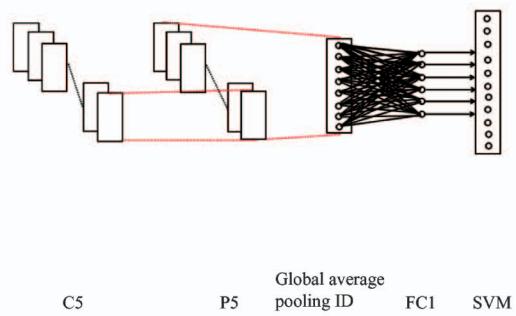


表3 一维卷积神经网络结构参数

| 编号                     | 网络层     | 卷积核大小         | 数目 |
|------------------------|---------|---------------|----|
| C1                     | 卷积层1    | $64 \times 1$ | 16 |
| P1                     | 最大池化层1  | $2 \times 1$  | 16 |
| C2                     | 卷积层2    | $3 \times 1$  | 32 |
| P2                     | 最大池化层2  | $2 \times 1$  | 32 |
| C3                     | 卷积层3    | $3 \times 1$  | 64 |
| P3                     | 最大池化层3  | $2 \times 1$  | 64 |
| C4                     | 卷积层4    | $3 \times 1$  | 64 |
| P4                     | 最大池化层4  | $2 \times 1$  | 64 |
| C5                     | 卷积层5    | $3 \times 1$  | 64 |
| P5                     | 最大池化层5  | $2 \times 1$  | 64 |
| Global average pooling | 全局平均池化层 | -             | -  |
| FC1                    | 输出层     | 100           | 1  |
| FC2                    | Softmax | 10            | 1  |

由于通过卷积神经网络提取出的特征通过肉眼很难分辨,为了验证本文所构建的卷积神经网络具有强大的特征提取能力,利用主成分分析法提取全连接层FC1的输出的前两个主成分,并进行可视化处理。如图10所示,同种状态的轴承数据紧紧地聚集在一起,与其他状态的轴承数据有效地分离,可以证明卷积神经网络能够有效地提取出各种状态的特征。

### 4.4 滚动轴承故障诊断总体流程

本文提出了一种基于集合经验模态分解和卷积神经网络的滚动轴承故障诊断方法,并利用SVM对卷积神经网络提取的特征进行分类。整体流程如下。

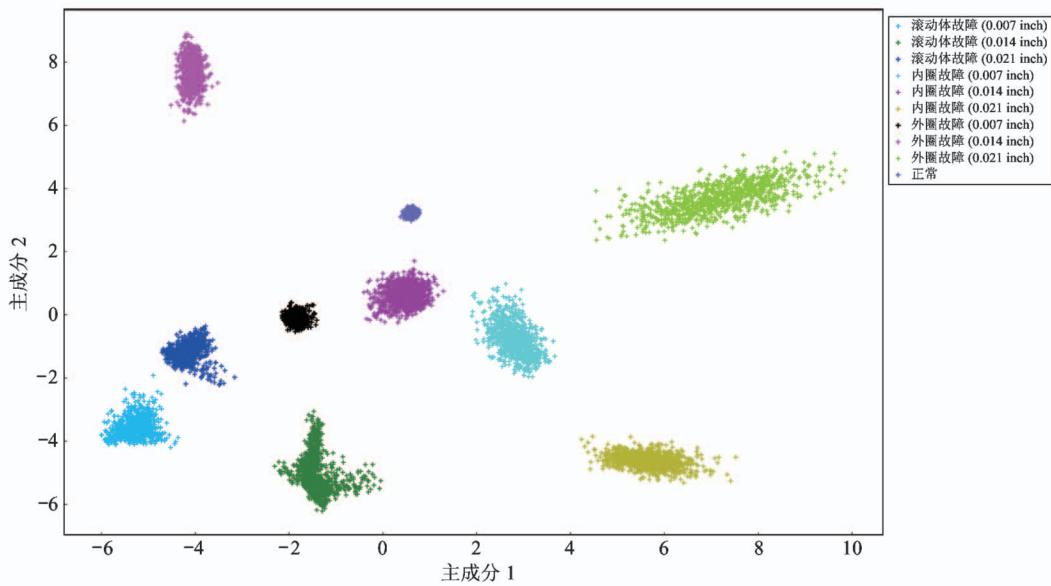


图 10 全连接层 FC1 提取特征散点图

**步骤 1** 采集滚动体故障状态下、内圈故障状态下、外圈故障状态下和正常状态下的滚动轴承振动信号,作为原始振动信号进行模型训练。

**步骤 2** 将原始振动信号构建为训练集和测试集。

**步骤 3** 对采集到的原始振动信号进行集合经验模态分解,将原始的振动信号分解为  $n$  个本征模态分量。

**步骤 4** 针对步骤 3 中的  $n$  个 IMF 分量构建神经网络,神经网络模型的损失函数是基于 Softmax 的交叉熵损失函数。

**步骤 5** 利用训练集对 CNN 进行训练,将步骤 3 中提取的  $n$  个 IMF 分量输入到步骤 4 中构建的神经网络模型中进行训练,其中训练的具体方法采用的是 Adam 梯度下降方法,批量大小为 128,迭代次数为 500,训练完成后,保持 CNN 模型参数不变。

**步骤 6** 利用训练好的模型对 IMF 分量进行特征提取,将通过多层卷积和池化操作提取出来的特征,即选取全连接层 FC1 的输出作为支持向量机的输入进行分类,从而达到故障诊断的目的。流程如图 11 所示。

利用已经训练好的一维卷积神经网络模型,对 10 种不同状态的滚动轴承数据进行故障检测,最后得到了一维卷积神经网络对训练样本检测的准确率

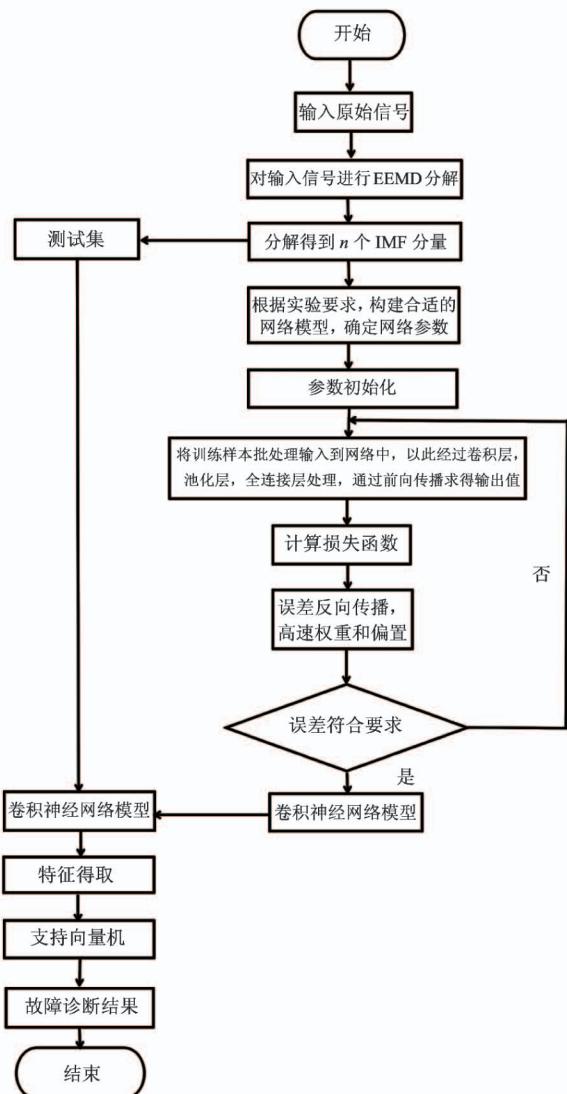


图 11 基于集合经验模态分解和卷积神经网络的滚动轴承故障诊断方法流程图

以及一维卷积神经网络对测试样本检测的准确率的仿真图。图 12 为训练集和测试集的准确率随迭代次数变化的结果图,可以看到当迭代次数为 8 时,准确率趋于最大值,随后趋于稳定。同时以交叉熵损失函数作为 loss,得到训练集和测试集的 loss 的结果图如图 13 所示。

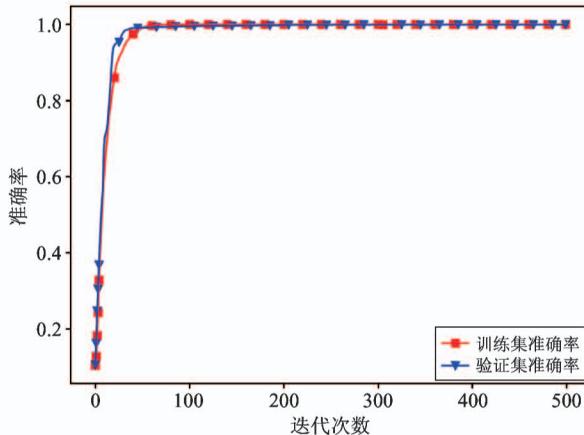


图 12 诊断准确率结果图

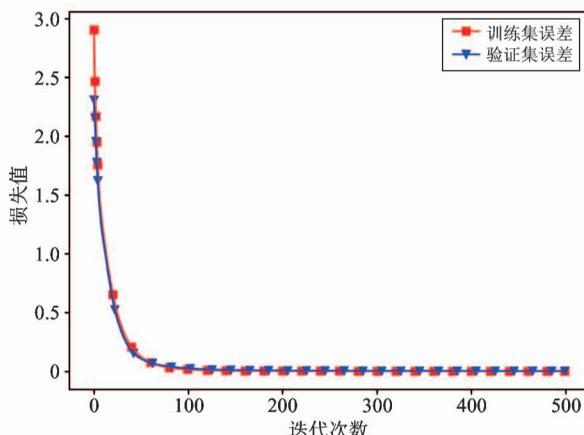


图 13 诊断损失率结果图

将本文提出的基于集合经验模态分解和卷积神经网络的滚动轴承故障诊断方法与现有方法进行比较,通过对故障诊断准确率的对比,由表 4 可以看出本方法相比于现有方法提高了故障识别的准确率和可靠性。对原始信号进行集合经验模态分解的方法可以有效克服经验模态分解存在的模态混叠问题,能够对原始振动信号进行更有效的预处理。同时利用 SVM 对卷积神经网络提取出的特征进行分类,克服了 Softmax 由于样本数量问题出现的过拟合现象,能够有效且准确地诊断出滚动轴承的故障类别。

表 4 本方法与现有算法效果对比

| 模型  | EMD + CNN + Softmax | EEMD + CNN + SVM |
|-----|---------------------|------------------|
| 准确率 | 98.88%              | 99.78%           |

## 5 结 论

在滚动轴承故障诊断过程中,其振动信号特征的提取和优化对整个故障诊断系统的精确度的提高和复杂度的减小具有重要意义。因此本文提出了一种新的滚动轴承故障诊断方法,即基于集合经验模态分解和卷积神经网络的滚动轴承故障诊断方法。该方法通过集合经验模态分解方法对原始信号进行预处理,解决了原始振动信号容易受到环境噪声的影响和传统经验模态分解方法存在的模态混叠问题。进一步利用卷积神经网络提取特征能力强的优点,有效提取数据特征。最后通过 SVM 对提取出的特征进行分类,能够有效且准确地诊断出滚动轴承的故障类别。最后,使用美国西储大学轴承数据中心的实验数据进行了测试,并与现有方法进行对比,证明了本文所提出方法的有效性。今后工作可以对信号预处理方法进行进一步研究,使此神经网络模型能够在复杂多变的环境下表现出良好的性能。

## 参 考 文 献

- [1] 陈进. 机械设备振动监测与故障分析 [M]. 上海: 上海交通大学出版社, 1999: 1-3
- [2] 潘玉娜. 滚动轴承的性能退化特征提取及评估方法研究 [D]. 上海交通大学, 2011
- [3] Ding X X, He Q B. Energy-fluctuated multiscale feature learning with deep convnet for intelligent spindle bearing fault diagnosis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(8): 1926-1935
- [4] 姚明海, 袁惠. 基于优化卷积神经网络的表面缺陷检测 [J]. 高技术通讯, 2019, 29(6): 564-569
- [5] 王攀攀, 史丽萍, 苗长新, 等. 利用骨干微粒群算法和 SVM 诊断电机定子故障 [J]. 电机与控制学报, 2013, 17(2): 48-54
- [6] 史丽萍, 汤家升, 王攀攀, 等. 采用最优小波树和改进 BP 神经网络的感应电动机定子故障诊断 [J]. 电工技术学报, 2015, 30(24): 38-45
- [7] 候文擎, 叶鸣, 李巍华. 基于改进堆叠降噪自编码的滚动轴承故障分类 [J]. 机械工程学报, 2018, 54(7): 87-96
- [8] 李东东, 王浩, 杨帆, 等. 基于一维卷积神经网络和

- Soft-Max 分类器的风电机组行星齿轮箱故障检测 [J]. 电机与控制应用, 2018, 45(6): 80-87
- [9] 胡莺庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法 [J]. 机械工程学报, 2019, 55(7): 9-18
- [10] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for non-linear and non-stationary time series analysis [J]. *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903-995
- [11] 郝欢, 王华力, 魏勤. 经验模态分解理论及其应用 [J]. 高技术通讯, 2016, 26(1): 67-80
- [12] Wu Z, Huang N E. Ensemble empirical mode decomposition: a noise - assisted data analysis method [J]. *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 2009, 1(1): 1-41
- [13] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507
- [14] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C] // International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2012: 1097-1105
- [15] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444
- [16] Cun Y L, Bengio Y. Word-level training of a handwritten word recognizer based on convolutional neural networks [C] // International Conference on Pattern Recognition, Jerusalem, Israel, 1994: 88-92
- [17] 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
- [18] 陈园艺, 孙建平. 基于 EEMD 和 PSO-SVM 的滚动轴承故障诊断 [J]. 电力科学与工程, 2016, 32(10): 47-52
- [19] 李丹峰, 郭雄伟. 基于双谱和 PSO-SVM 的滚动轴承故障诊断 [J]. 贵州大学学报, 2011, 28(4): 85-89
- [20] Chen F F, Tang B P, Song T, et al. Multi-fault diagnosis study on roller bearing based on multi-kernel support vector machine with chaotic particle swarm optimization [J]. *Measurement*, 2014, 47: 576-590
- [21] Sun W J, Shao S Y, Zhao R, et al. A sparse auto-encoderbased deep neural network approach for induction motor faults classification [J]. *Measurement*, 2016, 89: 171-178
- [22] 张小龙, 张氢, 秦仙蓉, 等. 基于 ITD 复杂度和 PSO-SVM 的滚动轴承故障诊断 [J]. 振动与冲击, 2016, 35(24): 102-107
- [23] 杨宇. 基于 EMD 和支持向量机的旋转机械故障诊断方法研究 [D]. 长沙: 湖南大学机械与汽车工程学院, 2005
- [24] Bearing Data Center. Case Western Reserve University, Cleveland, OH [EB/OL]. <http://www.eecs.case.edu/laboratory/bearing/>: EECS, 2018

## Intelligent fault diagnosis method of rolling bearing based on ensemble empirical mode decomposition

Chen Yongyi, Zhang Dan, Xue Huanxin

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023)

(Zhejiang Dafeng Industrial Co. Ltd, Hangzhou 315400)

### Abstract

Aiming at the problems that the rolling bearing's working environment contains strong environmental noise, its vibration signal has non-stationary, non-linear features and difficulty in extracting features, an intelligent fault diagnosis of rolling bearings based on ensemble empirical mode decomposition (EEMD) is proposed. First, the key features of the vibration signal are extracted through a convolutional neural network (CNN), and the extracted feature vectors are input to support vector machine (SVM) for fault identification and classification. In order to improve the diagnostic performance, the set of empirical modal methods are used to decompose the original vibration signal, the complex vibration signal is decomposed into intrinsic mode function (IMF) containing only a single component for feature extraction, and then the one-dimensional convolution neural network is used to perform feature extraction on the IMF, and SVM is finally used for classification. The experiment results show that the proposed method converges faster than the existing methods, and the diagnostic accuracy rate can be as high as 99%, highlighting the superiority of the method.

**Key words:** fault diagnosis, rolling bearing, ensemble empirical mode decomposition (EEMD), convolutional neural network (CNN), support vector machine (SVM)