

# 基于 EMD-SVD 和 CNN 的旋转机械故障诊断\*

张立智, 徐卫晓, 井陆阳, 谭继文

(青岛理工大学机械与汽车工程学院 青岛, 266520)

**摘要** 为解决旋转机械振动信号复杂且难以提取有效故障特征的问题,提出了一种经验模态分解(empirical mode decomposition,简称 EMD)、奇异值分解(singular value decomposition,简称 SVD)和深度卷积网络(Convolutional Neural Network,简称 CNN)相结合的故障诊断方法。首先,通过 EMD 方法将故障信号分解成若干个固有模态分量(intrinsic mode function,简称 IMF),构造时域与频域空间状态矩阵;其次,利用 SVD 方法对空间状态矩阵进行分解得到奇异值数组,构造时域与频域奇异值特征矩阵;最后,将提取的奇异值特征矩阵输入到 CNN 中进行模式识别。将该方法分别应用于滚动轴承与齿轮箱故障诊断中,在西储大学滚动轴承数据集、PHM2009 直齿齿轮箱数据集上均取得了很好效果,正确率优于将原始信号直接输入到 CNN 中等几种对比方法,验证了该方法的优越性。

**关键词** 滚动轴承; 齿轮箱; 故障诊断; 经验模态分解; 奇异值分解; 深度卷积网络

**中图分类号** TH16

## 引言

旋转机械是最常用的机械设备之一,在交通、制造、冶金、化工、能源及航天等多个领域中有广泛应用<sup>[1-2]</sup>。旋转机械运行环境一般比较恶劣,如腐蚀环境、高温环境、大冲击与高负载的工况条件等<sup>[3-4]</sup>,常使得设备出现各种故障,造成安全事故或财产损失。因此,对旋转机械设备进行有效的检测与诊断具有重要意义。

在旋转机械状态监测的大数据时代<sup>[5]</sup>,旋转机械常产生撞击、速度突变、结构变形及摩擦变化等,使得振动信号往往具有非平稳性与非线性,如何提取到有效的故障信息成为当下的研究热点之一。采用传统的线性信号处理方法处理易受负载、摩擦、间隙和刚度等因素的影响<sup>[6]</sup>。小波变换在处理非线性、非平稳信号时具有良好的高低频信号分解能力,但小波基的选取和阈值设置仍然是小波变换的难点问题<sup>[7]</sup>。EMD 在处理非稳定信号时能够突出信号的局部特征,具有良好的时频聚集能力。国内许多学者利用 SVD 对 EMD 分解后得到的 IMF 分量进行特征提取。叶红仙等<sup>[8]</sup>利用 EMD 分解多个传感器信号,对融合后的 IMF 分量进行奇异值分解,并结合贝叶斯信息准则对机械振动源信号数量进行了

估计,解决了卷积混合的机械振动源在观测数小于振动源数情况下的源数估计问题。徐峰等<sup>[9]</sup>利用 EMD 和 SVD 方法对胶合板损伤声发射信号进行数据处理,构造了奇异值特征向量,并建立了 Mahalanobis 距离判别函数对各损伤信号进行识别分类。尚雪义等<sup>[10]</sup>利用 EMD 方法对微震与爆破信号进行分解,利用 SVD 计算主要本征模态分量构成矩阵的奇异值,最后利用支持向量机(support vector machine,简称 SVM)对沙坝矿微震与爆破信号进行分类。上述方法都用到了 IMF 分量的时域波形信息,信息不够全面。

近几年,国内外诸多学者利用 CNN 对旋转机械信号进行模式识别。Janssens 等<sup>[11]</sup>对轴承进行故障监测,先使用快速傅里叶变换(fast Fourier transform,简称 FFT)对信号进行预处理,再使用 CNN 提取振动信号特征并得出诊断结果。Zhang 等<sup>[12]</sup>采用 CNN 对故障轴承进行诊断,直接处理振动信号并结合区域适应性方法,提高模型诊断效果。Chen 等<sup>[13]</sup>将 CNN 应用于齿轮的故障诊断,人工提取了振动信号的统计性特征,对齿轮进行故障识别。Li 等<sup>[14]</sup>将多传感器信号经快速傅里叶变换后的特征均方根图作为 CNN 输入,并结合改进的 D-S 证据理论对滚动轴承进行故障诊断。上述方法大多利用 CNN 对原始信号直接进行自适应特征提取,对

\* 国家自然科学基金资助项目(51475249);山东省重点研发计划资助项目(2018GGX103016);山东省高等学校科技计划资助项目(J15LB10)

收稿日期:2019-01-05;修回日期:2019-03-07

于具有非平稳性和非线性的振动信号处理能力一般,处理时间较长,并且需要对CNN网络结构进行复杂的调参过程。针对上述问题,笔者提出了一种基于EMD,SVD和CNN的旋转机械故障诊断方法,通过EMD与SVD两种方法对非平稳、非线性信号进行预处理与特征提取,利用CNN进行模式识别,并采用两个数据集进行了验证。

## 1 基础理论

### 1.1 EMD原理及空间矩阵构建

EMD方法分解过程是数据筛选的过程,把复杂信号分解为有限个IMF之和,每一个IMF分量代表不同特征尺度的数据系列<sup>[15]</sup>。对于信号,分解后新的信号序列表示为

$$h_1 = x(t) - m_1 \quad (1)$$

其中: $m_1$ 为上下包络平均值; $h_1$ 为分解的第1个信号。

判断 $h_1$ 是否满足IMF的条件,如果满足则记为 $h_1 = c_1$ , $c_1$ 即为原始信号的第1个IMF分量。去掉 $c_1$ 的剩余信号记为 $r_1$ ,将 $r_1$ 作为原始数据,重复以上步骤,得到 $c_1, c_2, \dots, c_k$ 。最终 $x(t)$ 可以由 $n$ 个IMF分量表示

$$x(t) = \sum_{i=1}^n c_i + r_n \quad (2)$$

利用累加百分比超过90%的 $p$ 个IMF分量 $c_i$ 构造时域状态矩阵,其中: $c_i = [c_{i1}, c_{i2}, \dots, c_{ij}, \dots, c_{im}]$ , $j$ 为原始信号的采样点; $c_{ij}$ 为采样点对应的IMF分量离散幅值。时域空间矩阵表示为

$$\mathbf{T} = \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_p \end{bmatrix} = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1n} \\ c_{21} & c_{22} & \cdots & c_{2n} \\ \vdots & \vdots & & \vdots \\ c_{p1} & c_{p2} & \cdots & c_{pn} \end{bmatrix} \quad (3)$$

对于IMF分量频域信息的利用,需要对每个采样区间分别进行FFT变换获取幅值谱。其中: $f_i$ 为与IMF分量 $c_i$ 对应的频域幅值序列; $l$ 为频域幅值序列长度,其矩阵表示为

$$\mathbf{F} = \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_p \end{bmatrix} = \begin{bmatrix} f_{11} & f_{12} & \cdots & f_{1l} \\ f_{21} & f_{22} & \cdots & f_{2l} \\ \vdots & \vdots & & \vdots \\ f_{p1} & f_{p2} & \cdots & f_{pl} \end{bmatrix} \quad (4)$$

### 1.2 SVD原理及特征矩阵构建

SVD是一种有效的代数特征提取方法,是矩阵的固有特性之一,在旋转机械的信号处理与故障诊断等方面得到了广泛应用<sup>[16]</sup>。对于一个行或列线性相关的矩阵,通过对其左右分别相乘一个正交矩

阵进行变换,可将原始矩阵转换为线性独立的矩阵。例如对于矩阵 $\mathbf{B}_{m \times n}$ ,秩为 $r$ ,则存在两个标准正交矩阵 $\mathbf{U}$ 和 $\mathbf{W}$ 及对角矩阵 $\mathbf{D}$ ,满足

$$\mathbf{B} = \mathbf{U}\mathbf{D}\mathbf{W}^T \quad (5)$$

式(5)为分解过程,其中 $\mathbf{U}_{m \times m} = [u_1, u_2, \dots, u_m]$ , $\mathbf{W}_{n \times n} = [\omega_1, \omega_2, \dots, \omega_n]$ ,矩阵 $\mathbf{D}$ 满足

$$\mathbf{D}_{m \times n} = \begin{bmatrix} \mathbf{S}_{r \times r} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \quad (6)$$

其中: $\mathbf{S}_{r \times r} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$ , $r = \min(m, n)$ , $\sigma_i (i=1, 2, \dots, r)$ 为矩阵 $\mathbf{B}$ 的奇异值。

通过上述方法对EMD处理后的空间状态矩阵进行奇异值分解,将分解结果作为最终的特征矩阵,将时域特征矩阵与频域特征矩阵并列到一个矩阵 $\mathbf{Q}$ 中表示为

$$\mathbf{Q} = \begin{bmatrix} \{Q_{T(a)}\} & \{Q_{F(b)}\} \\ \{Q_{T(a)}\} & \{Q_{F(b)}\} \\ \vdots & \vdots \\ \{Q_{T(a)}\} & \{Q_{F(b)}\} \end{bmatrix} \quad (7)$$

其中: $a$ 与 $b$ 分别为筛选得到的时域、频域有效奇异值数组中奇异值的个数; $Q_{T(a)}$ 与 $Q_{F(b)}$ 分别为时域、频域的有效奇异值数组。

### 1.3 深度卷积网络

深度卷积网络主要包含3类结构层,分别是卷积层、池化层及全连接层<sup>[17]</sup>,如图1所示。

卷积层是CNN中最为核心的部分,它通常是由多组二维滤波器组成。假设输入卷积层为 $X$ ,属于 $\mathbf{R}^{A \times B}$ , $A$ 和 $B$ 为输入数据的维度。卷积层的输出可以按式(8)计算

$$C_{cn} = f\left(\sum_{cc=1}^{cc} X_{cc}^{l-1} * W_{cn}^l + B_{cn}^l\right) \quad (8)$$

其中: $C_{cn}$ 为卷积层的第 $cn$ 个输出,输出数为 $CN$ ,即滤波器数; $*$ 为卷积运算符; $X$ 为前1层( $l-1$ )的第 $cc$ 通道的输入数据,通道号为 $CC$ ;  $W_{cn}^l$ 为当前层 $l$ 的第 $cn$ 个滤波器的权重;滤波器的宽度和高度分别

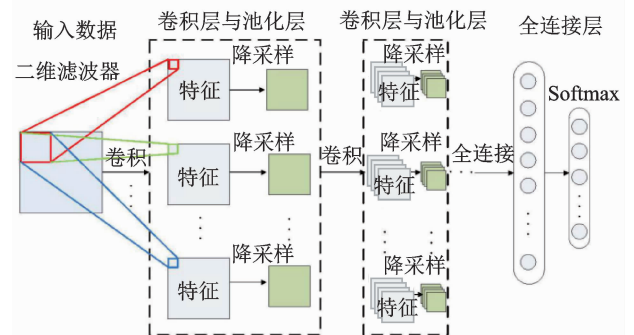


图1 经典深度卷积神经网络结构

Fig. 1 The structure of convolution neural network

为  $C_w$  和  $C_H$ ;  $B_{cn}^l$  为第  $cn$  个偏差;  $f$  为激活函数。

池化层又叫降采样层,一般接在卷积层之后,与卷积层成对出现。输出可以描述如下

$$P_{cn} = \max_{C_{cn} \in S} C_{cn} \quad (9)$$

其中:  $P_{cn}$  为池化层第  $cn$  个输出,输出数为  $CN$ ;  $S$  为池化层尺寸。

全连接层为 CNN 的最后 1 层,由于采用传统网络的“全连接”模式而得名。假设任务是一个 K-label 问题,softmax 回归的输出可以计算如下

$$Q_j = \begin{bmatrix} P(y=1 | x, \theta) \\ P(y=2 | x, \theta) \\ \vdots \\ P(y=k | x, \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k \exp(\theta^{(j)} x)} \begin{bmatrix} \exp(\theta^{(1)} x) \\ \exp(\theta^{(2)} x) \\ \vdots \\ \exp(\theta^{(k)} x) \end{bmatrix} \quad (10)$$

其中:  $\theta^{(1)}, \theta^{(2)} \dots \theta^{(k)}$  为模型的参数;  $Q_j$  为 CNN 的最终结果。

### 1.4 基于 EMD-SVD 和 CNN 的诊断方法

考虑到振动信号的非平稳性与非线性,首先采用 EMD 方法筛选原始数据以突出信号的局部特征,同时利用时域与频域信号能够较大幅度地保持原始信号信息。经过 EMD 后得到的矩阵数据量非常庞大,利用 SVD 方法提炼故障信息特征,完成特征矩阵构建。在大数据的背景下,特征矩阵数量一般较大,卷积神经网络处理大数据的能力突出,故障诊断效果较好,因此构建了本研究方法。基于 EMD, SVD 和 CNN 的旋转机械故障诊断方法流程如图 2 所示,具体流程如下:

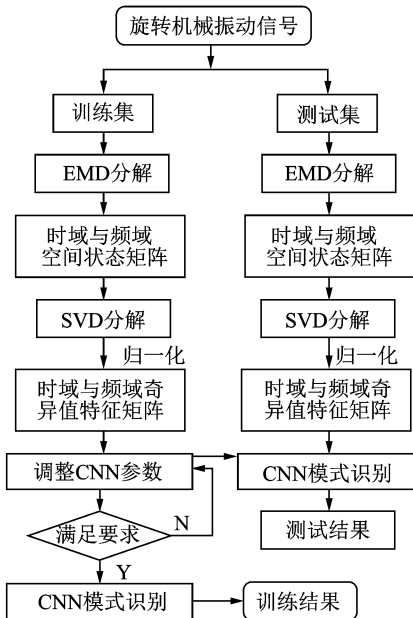


图 2 基于 EMD-SVD 和 CNN 诊断方法流程图

Fig. 2 The model flow based on EMD-SVD and CNN

1) 采集旋转机械振动信号,选取采样点并确定采样区间,对原始时域信号进行 EMD 分解并取前 6 项 IMF 分量;

2) 对每一段采样区间分别进行 FFT,按照上述方法构造时域、频域空间状态矩阵;

3) 对时域与频域空间状态矩阵进行 SVD 分解,得到时域、频域奇异值数组并组成奇异值特征矩阵;

4) 根据特征矩阵维度,初步设定 CNN 模型参数,设置训练集与测试集比例,根据训练结果进行调整,完成最终网络参数选择与测试集测试。

## 2 实验验证

为了验证笔者提出方法的有效性,分别对滚动轴承与齿轮箱进行了故障诊断,采用西储大学滚动轴承公开数据集与 PHM2009 直齿齿轮箱数据集进行实验验证。

### 2.1 滚动轴承故障诊断

选取滚动轴承 7 种状态,轴承参数如表 1 所示。

表 1 轴承参数

Tab. 1 The parameters of bearing

类别	故障类型	尺寸/cm	电机转速/(r · min <sup>-1</sup> )
1	内圈点蚀	0.017 78	1 797, 1 772, 1 750, 1 730
2	滚珠点蚀	0.017 78	1 797, 1 772, 1 750, 1 730
3	外圈点蚀	0.017 78	1 797, 1 772, 1 750, 1 730
4	内圈点蚀	0.035 56	1 797, 1 772, 1 750, 1 730
5	滚珠点蚀	0.035 56	1 797, 1 772, 1 750, 1 730
6	外圈点蚀	0.035 56	1 797, 1 772, 1 750, 1 730
7	正常	正常	1 797, 1 772, 1 750, 1 730

7 种滚动轴承状态按照上述排列顺序的原始信号时域波形如图 3 所示。采样频率为 12 kHz,每种电机转速下采样长度为 5.12 k 个数据点,每种状态得到 45.12 k 个数据点。本实验选取 2 048 个数据点作为 1 组数据样本,每类故障有 100 组数据,共计 700 组数据。选取 90% 为训练样本,为提高结果统计性,每类模型的训练与测试将进行 10 次,10 次测试样本的平均诊断正确率作为最终结果。

#### 2.1.1 特征提取

分别对 7 种滚动轴承原始振动信号进行 EMD 分解,由于西储数据效果一般较好,为了检验本研究方法的正确性,西储数据处理仅利用时域空间状态矩阵进行后续分析。这里仅展示内圈点蚀直径为 0.017 78 cm 的第 1 组数据 IMF 结果,如图 4 所示。

利用所提方法构造时域空间状态矩阵,并对其




图3 7种状态振动信号时域波形

Fig. 3 The time-domain waveforms of seven state vibration signals

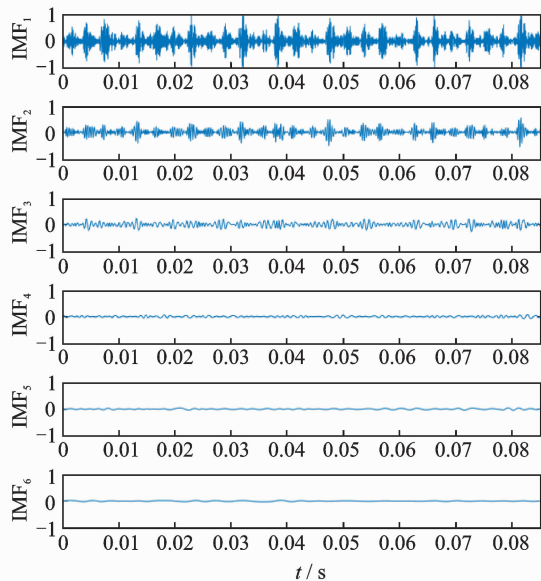


图4 IMF分量时域波形

Fig. 4 The time-domain waveforms of IMF component

进行SVD分解,每一种故障状态得到 $100 \times 6$ 的奇异值数组,组成奇异值特征矩阵。为了清晰地展示各类故障状态的奇异值结果,每一类仅展示前20项奇异值,其结果如图5所示。

### 2.1.2 模式识别

经过EMD和SVD特征提取后得到 $700 \times 6$ 的特征数据。将特征数据输入到CNN中进行模式识别,自适应提取10项特征。使用试错法的参数选择方法并结合深度卷积模型参数选择一般性规律选择CNN模型参数<sup>[18]</sup>,参数选择如表2所示。




图5 时域奇异值数组

Fig. 5 The singular value array of time-domain

表2 CNN模型参数

Tab. 2 The model parameters of CNN

层数	结构类型	参数
1	卷积层	滤波器尺寸为3,个数为10
2	池化层	池化块尺寸为2
3	卷积层	滤波器尺寸为3,个数为15
4	池化层	池化块尺寸为2
5	全连接层	激活函数Relu,节点数为10
6	Softmax	分类数为7

为展示基于EMD-SVD和CNN方法的故障诊断优越性,设置2组对比实验:①将原始轴承时域信号直接输入到经典CNN模型中;②人工提取15项特征输入到经典CNN模型中,人工特征的选择为均值、均方根值、方根幅值、绝对平均值、歪度、峭度、方差、最大值、最小值及峰值这10个有量纲指标,波形指标、峰值指标、脉冲指标、裕度指标及峭度指标这5个无量纲指标,共15个人工特征类型<sup>[19]</sup>,最终3个模型实验诊断结果如表3所示。

同时为展示基于EMD-SVD和CNN方法特征提取效果,分别对原始输入数据、奇异值特征及CNN自适应提取的训练集特征进行了主成分分析<sup>[20]</sup>,其中纵横坐标分别为前2维主分量,如图6所示。

表3 3个模型测试结果

Tab. 3 The test results of three models

模型	正确率/%	运行时间/s
对比实验1	97.01	98
对比实验2	96.99	25
EMD-SVD和CNN方法	100.00	13

由表3可知,笔者所提方法诊断正确率达到最高的100%,高于2种对比方法,且程序运行时间最低。图6从提取特征分类能力的角度证明了EMD-SVD和CNN方法能够有效地提取故障特征并进行模式识别,证明了本研究方法在滚动轴承故障诊断中的有效性与优越性。

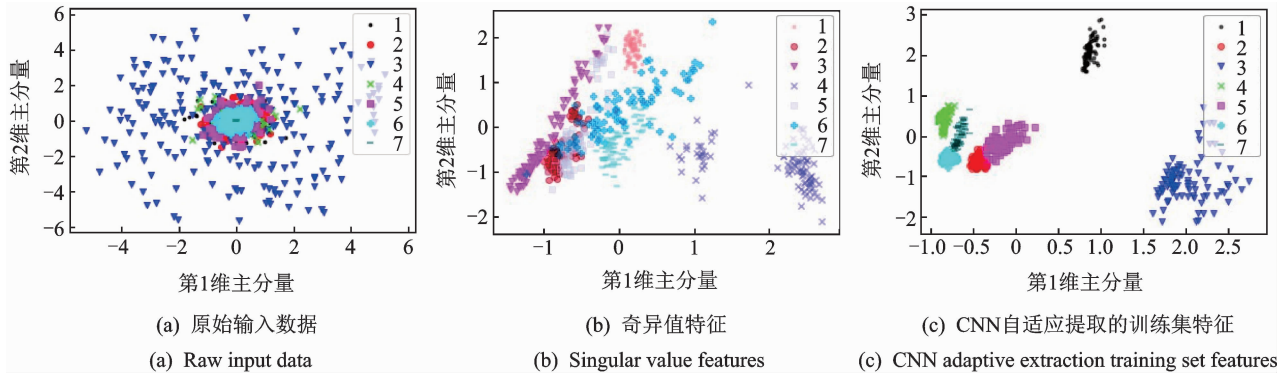


图 6 主成分分析结果

Fig. 6 The results of principal component analysis

### 2.2 齿轮箱复合故障诊断

齿轮箱复合故障诊断利用 PHM2009 数据集进行验证。PHM2009 数据集是由 PHM Society 公布的公开数据集<sup>[21]</sup>,实验台如图 7 所示。




图 7 PHM2009 故障数据集实验台

Fig. 7 PHM2009 fault data set test bench

该实验使用加速度传感器对齿轮、轴承及转轴的故障进行监测。本研究使用数据集中的 2009 年 11 月公布的 PHM2009 附加数据集,该组数据集不仅提供了加速度传感器采集的振动信号,而且给出了每组信号所对应的故障形式,以方便对测试算法的验证。齿轮箱传动示意图如图 8 所示,齿轮箱内部结构如图 9 所示。




图 9 齿轮箱内部结构图

Fig. 9 Gearbox internal structure

其中:齿轮故障有齿面剥落、齿轮断齿及点蚀,故障分别出现在齿轮 1、齿轮 2 与齿轮 4 上;轴承故障有内圈故障、外圈故障及滚动体故障,故障出现在轴承 1、轴承 2 与轴承 3 上;转轴故障有不平衡及键剪断,故障分别出现在输入轴与输出轴上。实验中各类故障类型及其对应的诊断目标标签设置如表 4 所示。

实验中齿轮箱共有 8 类复合故障状态,每类故障状态分别在驱动电机转速为 1.8,2.4 和 3.0 kr/min 且加载载荷为低载荷的工况条件下进行振动信号的采集。选取 2 048 个数据点作为 1 组数据样本,采样频率为 67 kHz,采样时间为 4 s。对每类故障选取其中 100 组数据样本,共有 800 组数据样本。

#### 2.2.1 特征提取

对 8 类直齿齿轮箱数据进行 EMD 分解,构造时域空间状态矩阵,并对得到的每一组数据的前 6 项 IMF 分量分别进行 FFT,得到频域空间状态矩阵。第 1 类故障第 1 组数据 IMF 分量时域波形、频域幅值谱如图 10、图 11 所示。

利用所提方法构造时域与频域空间状态矩阵后,对其进行 SVD 分解,每种故障状态得到 $100 \times 6$ 的奇异值数组,组成奇异值特征矩阵。为了清晰地展示各类故障状态的奇异值结果,每一类仅展示前 20 项奇异值,时域、频域奇异值结果如图 12、图 13 所示。

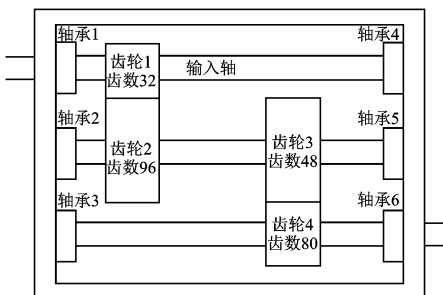


图 8 齿轮箱传动示意图

Fig. 8 Gearbox transmission diagram

表4 复合故障分类及其故障状态信息

Tab. 4 Compound fault classification and fault status information

故障类别	齿轮 1	齿轮 2	齿轮 3	轴承 1	轴承 2	轴承 3	输入轴转轴	输出轴转轴
1	正常	正常	正常	正常	正常	正常	正常	正常
2	纵向剥落	点蚀	正常	正常	正常	正常	正常	正常
3	正常	点蚀	正常	正常	正常	正常	正常	正常
4	正常	点蚀	断齿	滚动体故障	正常	正常	正常	正常
5	纵向剥落	点蚀	断齿	内圈故障	滚动体故障	外圈故障	正常	正常
6	正常	正常	断齿	内圈故障	滚动体故障	外圈故障	不平衡	正常
7	正常	正常	正常	内圈故障	正常	正常	正常	键剪断
8	正常	正常	正常	正常	滚动体故障	外圈故障	不平衡	正常




图10 第1类故障 IMF 分量时域波形

Fig. 10 Time-domain waveforms of IMF components of type 1 faults




图11 第1类故障 IMF 分量频域幅值谱

Fig. 11 IMF component frequency domain amplitude spectrum

2.2.2 模式识别

经过 EMD 和 SVD 特征提取后得到  $800 \times 12$  的特征数据。将特征数据输入到 CNN 中进行模式识别,自适应提取 10 项特征。同样使用试错法的参数选择方法并结合深度卷积模型参数选择一般性规律选取 CNN 模型参数,模型参数选择如表 5 所示。

设置 3 组对比实验:①将时域奇异值特征输入到 CNN 中;②将频域奇异值特征输入到 CNN 中;

表5 实验2的 CNN 模型参数

Tab. 5 CNN model parameters of experiment two

层数	结构类型	参数
1	卷积层	滤波器尺寸为 6,个数为 10
2	池化层	池化块尺寸为 2
3	卷积层	滤波器尺寸为 6,个数为 15
4	池化层	池化块尺寸为 2
5	全连接层	激活函数 Relu,节点数为 10
6	Softmax	分类数为 8




图12 实验2时域奇异值数组

Fig. 12 Time-domain singular value array of experiment two

③将原始直齿齿轮箱时域信号直接输入到经典 CNN 模型中。对齿轮箱实验与 3 项对比实验设置




图 13 实验 2 频域奇异值数组

Fig. 13 The singular value array of frequency domain

不同训练比例进行验证,训练比例分别为 50%,70%和 90%,不同训练比例下 4 个模型最终平均诊断结果如表 6 所示,10 次实验对比结果如图 14 所示。

分析表 6 与图 14,相比对照实验 1、实验 2 与实验 3,笔者提出的 EMD-SVD 和 CNN 相结合方法故障诊断正确率达到最高的 88.06%,并且在不同训

表 6 不同训练比例下 4 个模型测试结果

Tab. 6 The test results of four models under different training proportions

模型	正确率/%			运行时间/s
	50%训练	70%训练	90%训练	
对比 1	71.48	75.62	81.44	60
对比 2	75.22	77.88	79.50	61
对比 3	35.04	49.35	69.85	127
本研究方法	77.53	81.94	88.06	69

练比例下,该方法诊断正确率均最高;从程序运行时间上看,笔者提出的方法为 69s,远快于将原始信号直接输入到 CNN 中。实验结果表明:利用 EMD 对原始信号进行筛选可以起到较好效果,同时利用时域与频域信息可以增加对原始信号信息的保留;SVD 方法可以对故障信息进行较好的特征提取;CNN 方法对大数据处理效果较优越。经过对比实验,验证了 EMD-SVD 方法处理非平稳信号的能力,提取到了有效的故障特征,证明了本研究方法在齿轮箱故障诊断方面的优越性。




图 14 不同训练比例下 4 个模型 10 次实验结果

Fig. 14 Ten experimental results of four models under different training ratios

### 3 结 论

1) 利用振动信号经 EMD 分解后的 IMF 分量分别构造时域与频域空间状态矩阵,在对非稳态、非线性信号处理上具有较好的效果。与现阶段已有的故障特征提取方法相比,获取的故障状态信息更为全面。

2) 利用 SVD 方法对 IMF 分量进行分解,构造时域与频域奇异值特征矩阵。奇异值特征矩阵能很好地反映原始信号故障信息,特征提取效果较好。

3) 利用 EMD-SVD 和 CNN 相结合的故障诊断方法,在大数据处理上具有时间复杂度低、诊断效果佳的优点,为旋转机械故障诊断提供了新思路。

### 参 考 文 献

[1] SHEN C,WANG D,KONG F,et al. Fault diagnosis of

rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier[J]. Measurement, 2013, 46(4): 1551-1564.

[2] WANG W,CHEN J,WU X,et al. The application of some non-linear methods in rotating machinery fault diagnosis[J]. Mechanical Systems and Signal Processing,2001,15(4):697-705.

[3] LEI Y,HE Z,ZI Y. Application of the EEMD method to rotor fault diagnosis of rotating machinery[J]. Mechanical Systems and Signal Processing, 2009, 23(4): 1327-1338.

[4] LEI Y,LIN J,HE Z,et al. A review on empirical mode decomposition in fault diagnosis of rotating machinery [J]. Mechanical Systems and Signal Processing,2013, 35(1):108-126.

[5] 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.
- LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Chinese Journal of Mechanical Engineering, 2015, 51(21):49-56. (in Chinese)
- [6] 俞昆, 谭继文, 李善. 基于多域空间状态矩阵奇异值与局部保持投影的滚动轴承故障特征提取方法[J]. 机床与液压, 2017, 45(9):167-174.
- YU Kun, TAN Jiwen, LI Shan. Fault feature extraction method of rolling element bearing based on singular values of multiple-domain spatial condition matrix and locality preserving projection[J]. Machine Tool & Hydraulic, 2017, 45(9):167-174. (in Chinese)
- [7] 王宏强, 尚春阳, 高瑞鹏, 等. 基于小波系数变换的小波阈值去噪算法改进[J]. 振动与冲击, 2011, 30(10):165-168.
- WANG Hongqiang, SHANG Chunyang, GAO Ruipeng, et al. An improvement of wavelet shrinkage denoising via wavelet coefficient transformation[J]. Journal of Vibration and Shock, 2011, 30(10):165-168. (in Chinese)
- [8] 叶红仙, 杨世锡, 杨将新. 基于 EMD-SVD-BIC 的机械振动源数估计方法[J]. 振动、测试与诊断, 2010, 30(3):330-334.
- YE Hongxian, YANG Shixi, YANG Jiangxin. Mechanical vibration source number estimation based on EMD-SVD-BIC[J]. Journal of Vibration, Measurement & Diagnosis, 2010, 30(3):330-334. (in Chinese)
- [9] 徐锋, 刘云飞. 基于 EMD-SVD 的声发射信号特征提取及分类方法[J]. 应用基础与工程科学学报, 2014, 22(6):1238-1247.
- XU Feng, LIU Yunfei. Feature extraction and classification method of acoustic emission signals generated from plywood damage based on EMD-SVD[J]. Journal of Basic Science and Engineering, 2014, 22(6):1238-1247. (in Chinese)
- [10] 尚雪义, 李夕兵, 彭康, 等. 基于 EMD\_SVD 的矿山微震与爆破信号特征提取及分类方法[J]. 岩土工程学报, 2016, 38(10):1849-1858.
- SHANG Xuanyi, LI Xibing, PENG Kang, et al. Feature extraction and classification of mine microseism and blast based on EMD-SVD [J]. Chinese Journal of Geotechnical Engineering, 2016, 38(10):1849-1858. (in Chinese)
- [11] JANSSENS O, SLAVKOVIKJ V, VERVISCH B, et al. Convolutional neural network based fault detection for rotating machinery[J]. Journal of Sound and Vibration, 2016, 377:331-345.
- [12] 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):425-446.
- [13] CHEN Z Q, LI C, SANCHEZ R V. Gearbox fault identification and classification with convolutional neural networks[J]. Shock and Vibration, 2015, 2015(2):1-10.
- [14] LI S B, LIU G K, TANG X H, et al. An ensemble deep convolutional neural network model with improved D-S evidence fusion for bearing fault diagnosis[J]. Sensors, 2017, 17(8):1-19.
- [15] 徐卫晓, 谭继文, 温国强. 滚动轴承故障信号处理方法与诊断试验研究[J]. 机床与液压, 2014, 42(17):182-186.
- XU Weixiao, TAN Jiwen, WEN Guoqiang. Rolling bearing fault signal processing method and diagnostic tests research [J]. Machine Tool & Hydraulic, 2014, 42(17):182-186. (in Chinese)
- [16] CONG F Y, ZHONG W, TONG S, et al. Research of singular value decomposition based on slip matrix for rolling bearing fault diagnosis[J]. Journal of Sound and Vibration, 2015, 344:447-463.
- [17] JING L Y, ZHAO M, LI P, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox [J]. Measurement, 2017, 111:1-10.
- [18] ZHANG C, LI P, SUN G, et al. Optimizing fpga-based accelerator design for deep convolutional neural networks[C]//Proceedings of the 2015 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays. Monterey, USA; [s. n. ], 2015:161-170.
- [19] 徐卫晓, 谭继文, 文妍. 基于 BP 神经网络和改进 D-S 证据理论的滚动轴承故障诊断方法研究[J]. 机床与液压, 2014, 42(23):188-191.
- XU Weixiao, TAN Jiwen, WEN Yan. Study on fault diagnosis methods of rolling bearing based on BP neural network and D-S evidence theory[J]. Machine Tool & Hydraulic, 2014, 42(23):188-191. (in Chinese)
- [20] JING L Y, WANG T Y, ZHAO M, et al. An adaptive multi-sensor data fusion method based on deep convolutional neural networks for fault diagnosis of planetary gearbox [J]. Sensors, 2017, 17(2):414-429.
- [21] ALATAT H, SIEGEL D, LEE J. A systematic methodology for gearbox health assessment and fault classification[J]. International Journal of Prognostics and Health Management, 2011, 2(1):16-22.



**第一作者简介:**张立智,男,1995年9月生,硕士。主要研究方向为旋转机械故障诊断。曾发表《CNN与D-S证据理论相结合的齿轮箱复合故障诊断研究》(《机械科学与技术》2018年)。  
E-mail:1067110958@qq.com