

# 基于深度融合策略的转子轴心轨迹识别研究\*

郭明军<sup>1,2</sup>, 李伟光<sup>2</sup>, 杨期江<sup>3</sup>, 赵学智<sup>2</sup>

(1. 广西科技大学机械与汽车工程学院 柳州, 545616)

(2. 华南理工大学机械与汽车工程学院 广州, 510640)

(3. 广州航海学院轮机工程学院 广州, 510725)

**摘要** 针对以人工特征为输入的旋转机械故障的传统智能识别方法的精度较低及深度学习对数据量依赖性强的问题, 鉴于 Hu 不变矩具有伸缩、平移及旋转不变性的特点及无监督深度学习模型在小样本数据特征提取方面的优势, 提出了一种融合 Hu 不变矩及深度卷积自动编码特征的故障诊断模型 (deep convolutional auto-encoder fault diagnosis model, 简称 DCAE-FDM)。首先, 采用有效奇异值法对原始振动信号进行提纯, 得到提纯的轴心轨迹集, 并按一定比例划分为训练集和测试集, 分别计算出它们的 Hu 不变矩特征; 其次, 利用所构造的 DCAE-FDM 模型对轴心轨迹进行自适应特征提取, 得到深度自动编码特征; 然后, 将 Hu 不变矩与深度自动编码特征进行融合, 并将训练集的融合特征作为输入对 BP 神经网络进行训练; 最后, 采用测试集的融合特征对训练好的模型进行测试。试验结果表明, 所提方法的识别效果明显优于深度学习方法及传统识别方法, 所提方法的平均准确率达 98.5%, 比次优模型高出约 6 个百分点。

**关键词** 特征提取; 深度学习; 卷积神经网络; 自动编码器; 轴心轨迹

**中图分类号** TH113.2; TN 911.72

## 引言

汽轮机、压缩机、风机及轧机等旋转机械的转子轴心轨迹包含了机械装备运行状态的丰富信息, 其形状与故障类型紧密相关, 如椭圆形、香蕉形、外 8 形、内 8 形及花瓣形等分别与转子的不平衡、弱不对中、强不对中、油膜涡动及碰磨故障相对应<sup>[1]</sup>。因此, 对轴心轨迹进行分析研究, 对旋转机械的状态监测与故障诊断及延长其生命周期具有重要意义。

轴心轨迹的识别是旋转机械智能诊断的重要手段, 其本质是二维图形的模式识别问题, 通常包括特征提取和分类识别两个相对独立的阶段<sup>[2]</sup>。常用的轴心轨迹特征包括描述子、几何参数特征及矩特征等, 将这类可通过理论计算得到且具有明确物理意义的特征统称为人工特征, 对其向量化序列进行学习训练后, 利用人工神经网络<sup>[3]</sup>、D-S 证据理论<sup>[4]</sup>、模糊聚类<sup>[5]</sup>、灰色关联分析<sup>[6]</sup>和支持向量机 (support vector machine, 简称 SVM)<sup>[7]</sup>等模式识别方法完成分类任务。袁喜来等<sup>[3]</sup>以改进不变矩为特征向量作为

概率神经网络的输入进行训练, 成功识别了水电机组不同工况下的轴心轨迹。袁倩等<sup>[4]</sup>以轴心轨迹的不变矩和傅里叶描述子为特征, 提出了一种基于 D-S 证据理论的轴心轨迹自动识别方法, 并成功应用于磁轴承转子的轴心轨迹识别。李辉等<sup>[5]</sup>以多重分形谱特征为输入, 借助模糊 C-均值聚类方法实现轴心轨迹的分类识别。李友平等<sup>[6]</sup>以不变矩作为特征向量, 采用关联度分析方法实现轴心轨迹的自动识别。何刘海等<sup>[7]</sup>以不变矩作为特征向量, 采用 SVM 决策树有效识别了航空发动机转子的轴心轨迹。

上述基于人工特征的传统智能识别方法不仅步骤繁琐, 而且依赖于专家经验且精度也有待提高<sup>[8]</sup>。近年来, 深度学习的兴起, 为解决上述问题提供了新的解决方案。深度学习模型特有的多隐层结构, 使其不仅具有比传统神经网络更强的特征学习能力和非线性映射能力, 而且能够满足机械设备监测数据的自适应特征提取的要求, 减少对专家分析经验的依赖并提高模式识别的精度<sup>[9]</sup>。基于此, 堆栈去噪自编码器 (stack denoising auto-encoder, 简称

\* 国家自然科学基金资助项目 (51875205, 51875216); 广东省自然科学基金资助项目 (2018A030310017, 2019A1515011780); 广东省教育厅资助项目 (2018KQNCX191); 广州市科技计划资助项目 (201904010133); 广东省重大科技专项资助项目 (2019B090918003); 广西科技大学博士基金资助项目 (校科博 21z59)

收稿日期: 2019-12-03; 修回日期: 2020-07-05

SDAE)、深度置信网络(deep belief networks,简称DBN)、卷积神经网络(convolutional neural network,简称CNN)以及卷积自动编码器(convolutional auto-encode,简称CAE)等深度学习模型已成功应用于滚动轴承、齿轮箱等机械故障诊断领域。李松柏等<sup>[8]</sup>提出了一种集成多传感器信息及SDAE的齿轮故障诊断模型,具有比传统故障诊断方法更高的抗噪性及鲁棒性。李巍华等<sup>[10]</sup>利用DBN对轴承的原始振动信号进行自适应特征提取,增强了识别过程的智能性。刘星辰等<sup>[11]</sup>提出一种一维深度卷积神经网络,实现了原始轴承及齿轮箱振动信号的自适应特征学习与故障诊断。李东东等<sup>[12]</sup>利用改进的CAE实现了行星齿轮箱的故障特征提取与检测。上述深度学习模型中,CAE综合了CNN在图像处理方面的优势及自动编码器(auto encoder,简称AE)高效的无监督学习能力,特别适用于本研究的转子轴心轨迹图像的识别。

综上所述,特征提取是轴心轨迹识别的关键,所提取的特征可概括为人工特征(如不变矩、傅里叶描述子等)及深度特征(通过深度学习模型得到的特征)。不管是何种特征,其所包含的信息都是有限的,这在一定程度上限制了故障诊断识别精度的提高。同时,传统的模式识别方法还面临着如何解决小样本、非线性等难题。基于此,笔者将人工特征与深度特征进行融合,提出一种融合Hu不变矩及深度卷积自动编码特征的故障诊断模型(DCAE-FDM)用于轴心轨迹识别,效果明显优于单独采用人工特征或深度特征的方法。

### 1 轴心轨迹获取

轴心轨迹是旋转机械的重要图形特征,包含了丰富的设备运行状态信息,如椭圆形对应不平衡、香蕉形对应弱不对中、外8形对应强不对中及花瓣形对应碰磨故障等<sup>[17]</sup>。本研究的轴心轨迹数据来源于课题组研发的大型滑动轴承试验台,如图1所示,其主要由转子及其两端的滑动轴承、滑动轴承座、液压顶升装置、伺服电机和二级减振平台等部分组成。轴心轨迹可通过转子同一轴截面相互垂直的两个位移传感器 $d_1$ 和 $d_2$ 进行测量,测得的信号分别为 $D_1$ 和 $D_2$ ,如图2所示。其他试验参数如表1所示。

图3(a)为由信号 $D_1$ 和 $D_2$ 直接合成得到的原始轴心轨迹图,由图可知,轴心轨迹混成一团,既不能直接判别设备的状态,也无法直接输入深度学习模



图1 滑动轴承试验台

Fig.1 Sliding bearing test rig

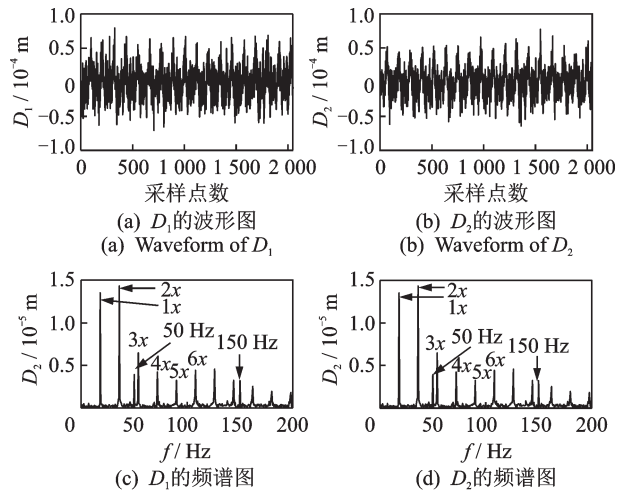


图2 实测转子位移信号

Fig.2 The measured rotor displacement signals

表1 试验基本参数

Tab.1 Basic test parameters

参数	数值
转速/(r·min <sup>-1</sup> )	0~4 000
转子质量/N	50 000
采样频率/Hz	2 048
采样点数	4 096

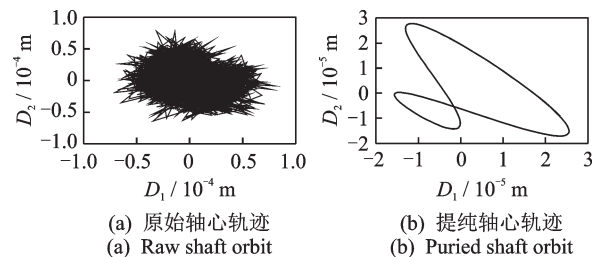


图3 原始轴心轨迹

Fig.3 Raw shaft orbit

型进行自动识别。因此,笔者采用有效奇异值法<sup>[13]</sup>进行轴心轨迹提纯,结果如图3(b)所示。由图3(b)可知,轴心轨迹为外8字形,说明转子存在严重的不对中故障,这一点和原始信号的频谱特征相吻合

( $1x, 2x$ 的幅值都较大)。

采用不同的轴承试验件,在试验台主轴的工作转速范围内逐渐改变转速并采集对应的振动信号,获得大量的试验数据。采用有效奇异值法<sup>[12]</sup>获得4类提纯的轴心轨迹图各100张,随机选取每类轴心轨迹中的80%作为训练集,剩下20%为测试集,具体如表2所示。图4为其中的部分图形。

表2 轴心轨迹数据集

Tab.2 Data set of axis trajectory

轨迹形状	转子状态	训练集	测试集	样本标签
椭圆	不平衡	80	20	0
香蕉	弱不对中	80	20	1
外8	强不对中	80	20	2
花瓣	晃动	80	20	3

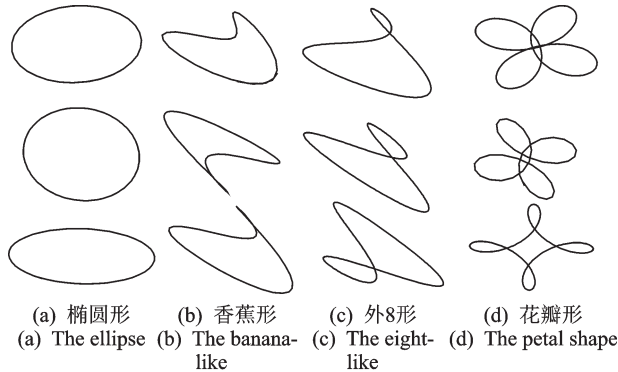


图4 提纯轴心轨迹

Fig.4 Purified axis orbits

## 2 Hu不变矩及其性质

由于信号的振幅、初相位及频率成分等不同,使得轴心轨迹形状各异,表现为其位置、方向及大小等也会不一样。为了实现轴心轨迹识别,需要提取到它的不变特征,其中图形的Hu不变矩特征就是其中最具代表性的一种,它因具有平移、旋转和伸缩不变性等特点,已在模式识别领域得到了广泛应用<sup>[3,6-7]</sup>。

假设 $f(x, y)$ 为图像在 $R^2$ 平面上的灰度密度函数,则其 $s+t$ 阶几何矩定义为

$$m_{st} = - \int_{+\infty}^{-\infty} x^s y^t f(x, y) dx dy \quad (1)$$

其中: $m_{st}$ 为图形的 $s+t$ 阶几何矩,为分段连续函数; $x, y$ 为图形的像素点坐标。

实际应用中,通常采用其离散形式,具体如式(2)所示

$$m_{st} = \sum_x \sum_y f(x, y) x^s y^t \quad (2)$$

对轴心轨迹图进行二值化处理之后,灰度值函数 $f(x, y)$ 的取值只能为0或1,其中轴心轨迹线经过的坐标点灰度值取1,其余情况取0。故可将式(2)简化为

$$m_{st} = \sum_x \sum_y x^s y^t \quad (3)$$

1) 平移不变性。由式(3)可以看出, $m_{st}$ 随着图形坐标的改变而变化,并不满足不变性的要求。为获得平移不变性,需将灰度函数进行零均值化处理得到 $s+t$ 阶中心距 $\mu_{st}$ ,其表达式为

$$\mu_{st} = \sum_x \sum_y (x - \bar{x})^s (y - \bar{y})^t \quad (4)$$

其中: $\bar{x}$ 和 $\bar{y}$ 为图形的质心坐标,表达式为

$$\begin{cases} \bar{x} = m_{10}/m_{00} \\ \bar{y} = m_{01}/m_{00} \end{cases} \quad (5)$$

2) 伸缩不变性。为了使中心距 $\mu_{st}$ 进一步具备伸缩不变性,需对其进行归一化处理为 $\eta_{st}$ ,其表达式为

$$\eta_{st} = \frac{\mu_{st}}{\mu_{00}^{1+\frac{s+t}{2}}} \quad (s+t \geq 2) \quad (6)$$

3) 旋转不变性。为了使归一化中心距 $\eta_{st}$ 进一步具备旋转不变性,Hu利用二阶和三阶归一化中心距构造出了7个不变矩 $M_1 \sim M_7$ ,具体表达式为

$$\begin{cases} M_1 = \eta_{20} + \eta_{02} \\ M_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11} \\ M_3 = (\eta_{30} - 3\eta_{12})^2 + 3(\eta_{21} + \eta_{03})^2 \\ M_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\ M_5 = (\eta_{20} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + 3(\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ M_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\ M_7 = (3\eta_{12} - \eta_{30})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + 3(\eta_{21} - \eta_{03})(\eta_{21} - \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{cases} \quad (7)$$

通过式(7)计算得到的Hu不变矩同时具有平移、旋转及伸缩不变性,可作为轴心轨迹的特征,部分计算结果如表3所示。

由表3可知,同类轴心轨迹图的各阶不变矩的数值变化较大,不同类轴心轨迹图对应的各阶不变矩的数值较为接近。因此,无法直接根据上述Hu不变矩特征识别出轴心轨迹图的类型。

表3 轴心轨迹图的不变矩

Tab.3 Invariant moments of shaft orbits

标签	$M_1$	$M_2$	$M_3$	$M_4$	$M_5$	$M_6$	$M_7$
0	3.18	11.28	17.41	15.41	-32.13	21.05	31.88
0	3.18	10.80	15.02	16.21	31.94	22.30	-32.03
0	3.18	11.48	16.33	16.38	33.86	-22.95	32.74
1	3.16	10.59	14.50	15.52	-31.06	-20.94	-30.55
1	3.17	11.29	15.26	15.11	30.30	21.07	32.17
1	3.16	10.66	14.52	15.32	-30.44	-20.86	30.36
2	3.16	10.33	14.24	16.21	31.52	21.39	-31.70
2	3.16	10.57	14.75	16.13	-32.82	21.90	31.57
2	3.16	10.26	14.28	15.68	31.31	20.91	-30.67
3	3.17	11.91	15.26	15.93	-31.54	22.60	-32.43
3	3.17	10.84	17.90	15.65	32.57	-21.56	-32.56
3	3.17	10.77	17.03	17.72	35.12	-23.19	35.52

### 3 深度卷积自编码故障诊断模型

AE是一种无监督的深度学习模型,即使在样本量较少的情况下也能自动提取到数据高阶特征的简明表达,从而提高数据的分类精度<sup>[14]</sup>,但是它会忽略图像的局部特征;而CNN因具有局部感受野特性,且对图像的位移、旋转、缩放等变化具有很好的适应性,故在图像的局部特征提取方面具有优势,但它忽略了图像中的高阶统计特性<sup>[15]</sup>。笔者综合考虑AE和CNN两者的优势,将CNN与AE模型相结合,构建一种DCAE-FDM模型,如图5所示。由图可知,该模型包括输入模块、编码模块、解码模块及输出模块。

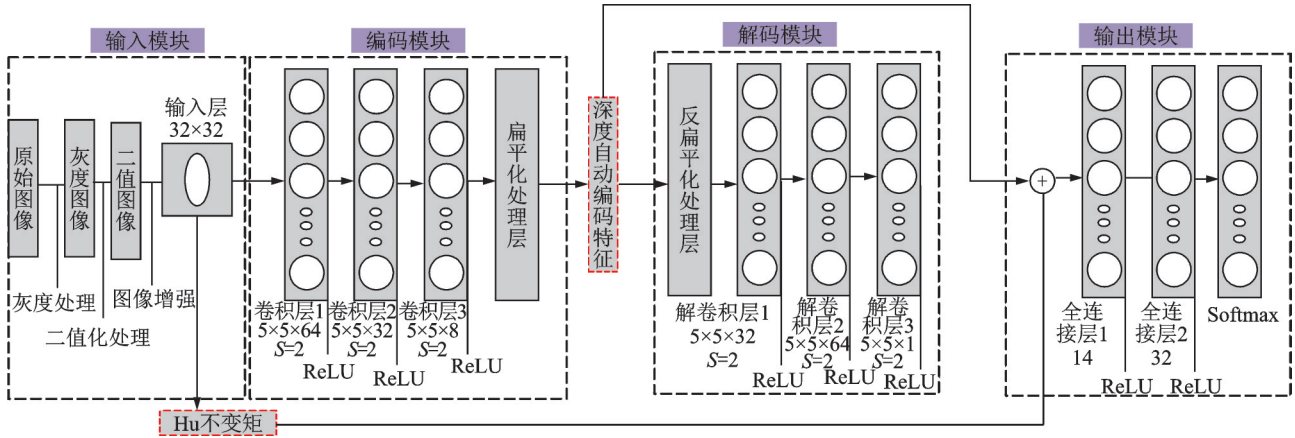


图5 DCAE-FDM模型

Fig5 Model of DCAE-FDM

#### 3.1 输入模块

输入模块主要功能是对输入图像进行预处理。首先,对输入数据集进行色彩空间转换,在python中调用opencv中的cv2.cvtColor()函数将其统一处理为灰度图像。此过程的阈值 $\theta$ 可由式(8)计算

$$\theta = \sum_{i=1}^r \sum_{j=1}^c h_{ij} \quad (8)$$

其中: $r$ 为像素矩阵的行数; $c$ 为像素矩阵的列数;本研究中取 $r=c=32$ ; $h_{ij}$ 为灰度值。

根据式(8)计算得到 $\theta$ ,进一步将图像换转为二值图像,表达式为

$$k_{ij} = \begin{cases} 1 & (h_{ij} > \theta) \\ 0 & (h_{ij} \leq \theta) \end{cases} \quad (9)$$

其次,调用cv2.resize()函数,将二值图像统一缩放为 $32 \times 32$ 尺寸,并采用最近邻算法对图像的边

缘特征进行增强。

#### 3.2 编码模块

编码模块由卷积层和ReLU激活函数交替组成,其中卷积层充当输入轴心轨迹图的特征提取器的功能,而ReLU激活函数将提取到的特征进行非线性映射。卷积层的输出可表示为

$$C_1 = x_j^k = f\left(\sum_{i \in S_j} x_j^{k-1} * w_{ij}^k + b_j^k\right) \quad (10)$$

其中: $C_1$ 为卷积层的输出结果, $x_j^k, x_j^{k-1}$ 分别为第 $k$ 层及其前1层中的第 $j$ 个神经元对应的输入向量; $S_j$ 为卷积核的感受区域, $w_{ij}^k$ 为前1层输入映射到第 $k$ 层的第 $j$ 个卷积核的第 $i$ 个权值系数; $b_j^k$ 为与卷积核相关的偏置项;\*表示卷积操作。

$f$ 为ReLU激活函数,其表达式为

$$f(x_i) = \begin{cases} x & (x_i > 0) \\ 0 & (x_i \leq 0) \end{cases} \quad (11)$$

其中: $x_i$ 为对应的输入值。

通过编码模块可将输入的轴心轨迹图编码到7维空间,表4为提取到的部分编码特征。

由表4可知,对于轴心轨迹图,相同类型的各阶

编码特征差异较大,不同类型对应各阶编码特征的数值较为接近。因此,无法直接根据上述编码特征识别出轴心轨迹图的类型。

表4 轴心轨迹图的编码特征  
Tab.4 Encoding features of shaft orbits

标签	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$	$f_7$
0	170.89	268.42	-5.74	219.16	-177.33	86.07	-164.28
0	170.45	268.07	-5.49	218.62	-176.94	85.77	-164.35
0	170.40	267.69	-5.52	218.93	-176.78	85.87	-163.96
1	169.97	264.66	-6.22	216.44	-174.24	86.48	-161.91
1	170.49	265.81	-6.19	217.41	-175.21	86.49	-162.63
1	170.83	265.38	-6.35	217.37	-175.54	85.76	-161.97
2	168.96	263.28	-6.35	215.31	-174.39	85.02	-160.14
2	169.49	263.39	-6.20	215.91	-173.56	86.05	-161.23
2	169.66	264.32	-6.19	216.48	-174.32	85.89	-161.70
3	170.25	266.22	-5.95	217.69	-175.89	85.71	-162.80
3	169.92	265.48	-5.86	217.25	-175.48	85.26	-162.31
3	169.82	266.30	-5.88	217.09	-176.10	85.40	-162.55

### 3.3 解码模块

解码模块由反卷积层和激活函数交替组成,该模块的作用是从编码特征中恢复出原始输入的近似表达。反卷积层的输出表示为

$$C_2 = \mathbf{x}_j^k = f\left(\sum_{i \in S_j} \mathbf{x}_j^{k-1} \otimes \mathbf{w}_{ij}^k + b_j^k\right) \quad (12)$$

其中: $C_2$ 为反卷积层的输出结果; $\mathbf{x}_j^k, \mathbf{x}_j^{k-1}$ 分别表示第 $k$ 层及其前1层中的第 $j$ 个神经元对应的输入向量; $\mathbf{w}_{ij}^k$ 为前1层输入映射到第 $k$ 层的第 $j$ 个反卷积核的第 $i$ 个权值系数; $b_j^k$ 为与反卷积核相关的偏置项; $\otimes$ 表示反卷积操作; $f$ 为ReLU激活函数,其表达式与式(11)相同。

### 3.4 输出模块

解码模块由反卷积层和激活函数交替组成,该模块的作用是从编码特征中恢复出原始输入的近似表达。反卷积层的输出表示为

$$\text{softmax}(y_i) = \frac{\exp(y_i)}{\sum_{j=1}^n \exp(y_j)} \quad (13)$$

其中: $y_i$ 为神经网络的原始输出。

网络训练的目标函数采用交叉熵损失函数,其计算式为

$$L(m, n) = - \sum_x m(x) \log n(x) \quad (14)$$

其中: $m$ 为样本理想输出的概率分布; $n$ 为预测结果的概率分布; $L(m, n)$ 为两者之间的距离。

## 4 试验分析

本研究的轴心轨迹识别流程具体步骤如下。

1) 样本集构造。采用有效奇异值法<sup>[13]</sup>对采集到的振动信号进行降噪提纯,并进一步合成得到提纯轴心轨迹,具体结果如表2所示。随机选取每类轴心轨迹中的80%作为训练集,剩下20%为测试集。

2) 特征融合。首先,按照式(7)计算出训练集数据的7个Hu不变矩,部分计算结果如表3所示;其次,采用图7中的模型提取训练集的自动编码特征,部分计算结果如表4所示;最后,将两种特征进行拼接得到训练集的融合特征。对测试集采用同样的步骤计算得到测试集的融合特征。

3) 分类器训练与测试。首先,采用训练集的融合特征对输出模块中的BP神经网络进行训练,并保存训练好的模型;其次,利用测试集的融合特征对训练好的模型进行测试,根据相关指标对模型进行评估。

### 4.1 评估指标

常用的4个分类模型评价指标<sup>[15]</sup>分别为准确率(Accuracy)、精确率(Precision)、召回率(Recall)和 $F_1$ 得分值,它们可分别由式(15)~(18)计算得到

$$\text{Acc} = \frac{\text{TN} + \text{TP}}{\text{TP} + \text{FN} + \text{TN} + \text{FP}} \quad (15)$$

$$\text{Pre} = \text{TP} / (\text{TP} + \text{FP}) \quad (16)$$

$$\text{Rec} = \text{TP} / (\text{TP} + \text{FN}) \quad (17)$$

$$F_1 = 2 * \frac{Pre * Rec}{Pre + Rec} \quad (18)$$

其中: TP, FN 分别为正类样本被正确或错误识别的数量; FP 为负类被判定为正类的数量; TN 为负类样本被判定为负类的数量。

上述4个指标中, Pre 和 Rec 指标通常不单独使用, 而  $F_1$  指标是两者的加权调和平均, 且能够使得两者取值最大化, 是常用的模型评估指标。此外, Acc 表示的是正确识别样本的数量与总样本数量的比值, 也常用于模型评估。

### 4.2 试验结果

按照试验步骤分别得到训练集和测试集的融合特征, 采用前者训练BP神经网络作为分类器, 结果如图6所示。图6(a)为损失值变化曲线, 由图可知, 随着训练次数的增加, 损失值不断降低, 最终衰减到接近0。图6(b)为准确率变化曲线, 由图可知, 随着训练次数的增加, 准确率不断上升, 当训练次数接近40时, 准确率达到100%。此后保持恒定, 说明此时的模型已经收敛。




图6 分类器模型的训练结果  
Fig.6 Training results of classifier model

采用测试集的融合特征对上述训练好的分类器进行测试, 并与其他方法进行比较。表5为使用笔者所提方法、深度学习方法(DAE+BP, DAE+SVM)及传统识别方法(Hu+SVM, Hu+BP)进行10次试验的各指标的平均值。

由表5可以看出, 笔者所提方法的各指标均明显优于其他方法, 传统识别方法次之, 深度学习方法效果最差。其原因在于所提方法融合了传统识别方法

表5 不同模型诊断结果

评价指标	所提方法	DAE+BP	DAE+SVM	Hu+BP	Hu+SVM
精确率	98.70	78.20	75.60	94.10	93.20
召回率	98.50	77.90	75.20	92.80	91.60
$F_1$ 得分	98.50	77.70	74.80	92.60	91.60
准确率	98.50	77.88	75.13	92.63	91.63

计算得到的人工特征及深度学习方法自适应提取的深度编码特征, 不仅使得轴心轨迹的特征维度得到扩展, 且使得融合的特征当中包含了更丰富的数据信息; 传统识别方法计算得到的Hu不变矩具有明确的物理含义, 对分类器的性能要求不高, 通过合适调参可获得一定的效果; 深度学习方法对输入数据量较为敏感, 样本容量越大识别效果越好, 而本研究的样本量较小, 这是导致其识别效果差的主要原因。

图7为上述方法的准确率及 $F_1$ 得分值的对比情况。由图可知, 所提方法的准确率和得分值在各次试验中均大于其他方法, 而传统识别方法的这两个值比深度学习的大, 这也验证了前文的分析结果。

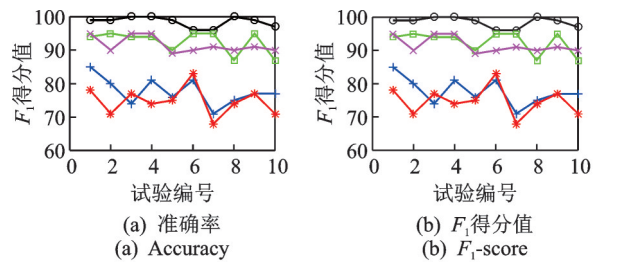


图7 不同方法的准确率及 $F_1$ 得分值的对比情况

Fig.7 Comparison of accuracy and  $F_1$ -score of different methods

### 5 结束语

本研究针对采用单一的人工特征或者深度特征为输入的滑动轴承转子轴心轨迹的识别方法精度较低的问题, 提出了一种融合Hu不变矩及深度卷积自动编码特征的故障诊断模型。首先, 计算出轴心轨迹的具有旋转、平移及伸缩不变性的Hu不变矩特征; 其次, 利用所构造的DCAE-FDM模型自适应提取轴心轨迹的深度自动编码特征; 最后, 将Hu不变矩与深度自动编码特征进行融合, 并将融合特征作为输入对BP神经网络进行训练。试验结果表明, 所提方法在精确率、召回率、 $F_1$ 得分值及准确率等方面均明显优于深度学习方法(DAE+BP, DAE+SVM)及传统识别方法(Hu+SVM, Hu+BP)。

### 参 考 文 献

[1] 张景润, 李伟光, 李振, 等. 基于奇异值差分谱理论的大型转子轴心轨迹提纯[J]. 振动与冲击, 2019, 38(4): 199-205.  
ZHANG Jingrun, LI Weiguang, LI Zhen, et al. Purification a large rotor axis's based on the difference spectrum theory of singular value [J]. Journal of Vibration

- and Shock, 2019, 38(4):199-205. (in Chinese)
- [2] 郭鹏程, 罗兴镒, 王勇劲, 等. 基于粒子群算法与改进BP神经网络的水电机组轴心轨迹识别[J]. 中国电机工程学报, 2011, 31(8):93-97.  
GUO Pengcheng, LUO Xingqi, WANG Yongjin, et al. Identification of shaft centerline orbit for hydropower units based on particle swarm optimization and improved BP neural network [J]. Proceedings of the Chinese Society for Electrical Engineering, 2011, 31(8):93-97. (in Chinese)
- [3] 袁喜来, 刘东, 胡晓, 等. 基于改进不变矩与概率神经网络的水电机组轴心轨迹特征提取研究[J]. 中国农村水利水电, 2019(6):149-152.  
YUAN Xilai, LIU Dong, HU Xiao, et al. Research on the feature extraction of hydropower units shaft orbit based on improved moment invariants and PNN [J]. China Rural Water and Hydropower, 2019(6):149-152. (in Chinese)
- [4] 袁倩, 孙冬梅, 范文. 基于D-S证据理论的轴心轨迹自动识别方法[J]. 机床与液压, 2017, 45(7):167-171.  
YUAN Qian, SUN Dongmei, FAN Wen. Automatic identification method of axis orbits based on D-S evidential theory [J]. Machine Tool & Hydraulic, 2017, 45(7):167-171. (in Chinese)
- [5] 李辉, 白亮, 罗兴镒, 等. 基于模糊聚类的水电机组轴心轨迹多重分形特征识别[J]. 水力发电学报, 2012, 31(4):238-242.  
LI Hui, BAI Liang, LUO Xingqi, et al. Multi-fractal feature recognition for shaft centerline orbit of hydropower units based on fuzzy clustering [J]. Journal of Hydroelectric Engineering, 2012, 31(4):238-242. (in Chinese)
- [6] 李友平, 陈启卷. 基于灰色理论与不变性矩的水电机组轴心轨迹自动识别[J]. 电力系统自动化, 2001, 25(9):19-22.  
LI Youping, CHEN Qijuan. Automatic identification of axis orbit of hydroelectric generating set based on grey theory and moment invariants [J]. Journal of Automation of Electric Power Systems, 2001, 25(9):19-22. (in Chinese)
- [7] 何刘海, 吴桂娇, 王平. 基于支持向量机决策树的航空发动机轴心轨迹识别方法[J]. 中国机械工程, 2019, 30(8):91-96.  
HE Liuhai, WU Guijiao, WANG Ping. Shift orbit recognition method of aero engines based on SVM decision tree [J]. China Mechanical Engineering, 2019, 30(8):91-96. (in Chinese)
- [8] 李松柏, 康子剑, 陶洁. 基于信息融合及堆栈降噪自编码的齿轮故障诊断[J]. 振动与冲击, 2019, 38(5):216-221.  
LI Songbai, KANG Zijian, TAO Jie. Gear fault diagnosis based on information fusion and stacked de-noising auto-encoder [J]. Journal of Vibration and Shock, 2019, 38(5):216-221. (in Chinese)
- [9] 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. (in Chinese)
- [10] 李巍华, 单外平, 曾雪琼. 基于深度信念网络的轴承故障分类识别[J]. 振动工程学报, 2016, 29(2):340-347.  
LI Weihua, SHAN Waiping, ZENG Xueqiong. Bearing fault identification based on deep belief network [J]. Chinese Journal of Vibration Engineering, 2016, 29(2):340-347. (in Chinese)
- [11] 刘星辰, 周奇才, 赵炯, 等. 一维卷积神经网络实时抗噪故障诊断算法[J]. 哈尔滨工业大学学报, 2019, 51(7):89-95.  
LIU Xingchen, ZHOU Qicai, ZHAO Jiong, et al. Real-time and anti-noise fault diagnosis algorithm based on 1-D convolutional neural network [J]. Journal of Harbin Institute of Technology, 2019, 51(7):89-95. (in Chinese)
- [12] 李东东, 王浩, 杨帆, 等. 基于无监督特征学习的行星齿轮箱故障特征提取和检测[J]. 电网技术, 2018, 42(11):3805-3811.  
LI Dongdong, WANG Hao, YANG Fan, et al. Feature extraction and detection of planetary gear box fault using unsupervised feature learning [J]. Power System Technology, 2018, 42(11):3805-3811. (in Chinese)
- [13] 郭明军, 李伟光, 杨期江, 等. 基于有效奇异值数量规律的滑动轴承转子轴心轨迹提纯研究[J]. 振动与冲击, 2019, 38(22):155-161.  
GUO Mingjun, LI Weiguang, YANG Qijiang, et al. Purification of the axis trajectory of a rotor supported by sliding bearings based on the number rule of effective singular values [J]. Journal of Vibration and Shock, 2019, 38(22):155-161. (in Chinese)
- [14] BENGIO Y. Learning deep architectures for AI [J]. Foundations and Trends in Machine Learning, 2009, 2(1):1-12.
- [15] 张习之, 李立君. 基于改进卷积自编码机的油茶果图像识别研究[J]. 林业工程学报, 2019, 4(3):118-124.  
ZHANG Xizhi, LI Lijun. Research of image recognition of camellia oleifera fruit based on improved convolutional auto-encoder [J]. Journal of Forestry Engineering, 2019, 4(3):118-124. (in Chinese)



**第一作者简介:**郭明军,男,1991年6月生,博士。主要研究方向为故障诊断、信号处理。

E-mail:scutgmj@163.com

**通信作者简介:**李伟光,男,1958年4月生,博士、教授。主要研究方向为故障诊断、信号处理及智能制造等。

E-mail:wguangli@scut.edu.cn