

基于深度卷积神经网络的转子轴心轨迹智能识别

钱 虹,王建棋,刘 刚

(上海电力大学 自动化工程学院,上海 200090)

摘 要:转子轴心轨迹作为转子故障的典型特征之一,可以提供更具代表性的故障特征信息。对转子轴心轨迹形状进行准确识别是构建转子故障特征征兆的基础。为提高转子轴心轨迹形状识别的泛化能力,提出一种基于深度卷积神经网络的转子轴心轨迹成像及形状识别方法(DimShapeNet)。将转子轴心轨迹映射到二维数字图像中,利用反灰度化预处理方法,去除二维数字图像中多余的颜色信息;将预处理后的转子轴心轨迹数字图像输入深度卷积神经网络中进行训练。结果表明:经过反灰度化预处理的转子轴心轨迹数字图像在深度卷积神经网络的训练中更有优势;相比于传统的转子轴心轨迹形状识别方法,基于深度卷积神经网络的转子轴心轨迹形状识别方法具有更高的准确性和更好的鲁棒性。

关 键 词:轴心轨迹成像;轴心轨迹形状识别;深度卷积神经网络;反灰度化;故障诊断

中图分类号:TP183 **文献标识码:**A **DOI:**10.16146/j.cnki.rndlge.2022.08.025

[引用本文格式]钱 虹,王建棋,刘 刚. 基于深度卷积神经网络的转子轴心轨迹智能识别[J]. 热能动力工程,2022,37(8): 204-212. QIAN Hong, WANG Jian-qi, LIU Gang. Intelligent recognition of rotor axis trajectory based on deep convolutional neural network [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(8): 204-212.

Intelligent Recognition of Rotor Axis Trajectory based on Deep Convolutional Neural Network

QIAN Hong, WANG Jian-qi, LIU Gang

(School of Automation Engineering, Shanghai University of Electric Power, Shanghai, China, Post Code: 200090)

Abstract: As one of the typical characteristics of rotor faults, the rotor axis trajectory can provide more representative information of rotor faults. Accurate identification of the shape of the rotor axis trajectory is the basis of constructing the characteristic symptoms of rotor faults. In order to improve the generalization ability of the shape identification of rotor axis trajectory, this paper proposes a rotor axis trajectory imaging and its shape identification algorithm based on deep convolutional neural network called DimShapeNet. The analytic expression of rotor axis trajectory is mapped to two-dimensional digital image. By using anti-grayscale method to preprocess the rotor axis trajectory image, the redundant color information of two-dimensional digital image is removed. Then, the preprocessed digital images of rotor axis trajectory are input into deep convolutional neural network for training. The experimental results show that the rotor axis trajectory digital image after anti-grayscale preprocessing has more advantages in the training of deep convolutional neural network. Compared with the traditional shape identification method of rotor axis trajectory, the shape identification method of rotor axis trajectory based on deep convolutional neural network has higher accuracy and better robustness.

收稿日期:2021-08-09; 修订日期:2021-10-14

基金项目:上海市 2019 年度“科技创新行动计划”高新技术领域项目(19511103700)

Fund-supported Project: Shanghai 2019 "Science and Technology Innovation Action Plan" High-tech Field Project(19511103700)

作者简介:钱 虹(1967-),女,上海人,上海电力大学教授。

通讯作者:王建棋(1996-),男,江苏宿迁人,上海电力大学硕士研究生。

Key words: axis trajectory imaging, axis trajectory shape identification, deep convolution neural network, anti-grayscale, fault diagnosis

引 言

转子轴心轨迹是转轴中心的振动轨迹,通过观察和监测转子轴心轨迹,可以形象、直观地获取设备的运行状况。转子正常运行时,转子轴心轨迹通常是一个正圆或者长短轴相近的椭圆形,一旦发生故障,其轴心轨迹的形状也会随之发生变化。转子发生不平衡、不对中、单点局部碰摩和多点局部碰摩故障时,对应的轴心轨迹分别为不规则的椭圆形、香蕉形、内“8”形和花瓣形^[1-3]。因此,对转子轴心轨迹形状进行准确识别有助于提高转子故障诊断的准确性。

目前,通过实时采集旋转机械诊断监测管理系统(Turbine Diagnosis Management, TDM)机组^[4],可以为故障诊断人员提供转子轴心轨迹形状,协助专家深入分析机组运行状态^[5]。但是这种基于“人机”对话方式实现的转子轴心轨迹形状识别大多依靠技术人员的经验进行主观判断,严重影响诊断的准确性和智能化。因此,利用智能算法对转子轴心轨迹形状进行自动识别,可以进一步提高转子诊断的准确性,实现智能运维。文献[6]利用不变矩和傅里叶描述子提取轴心轨迹的图像特征,采用 D-S 证据理论对轴心轨迹形状进行识别。文献[7]采用高度函数描述轴心轨迹图像特征,利用特征训练 BP 神经网络实现轴心轨迹形状识别的目标。文献[8]利用二维形状不变矩提取轴心轨迹的图形特征,采用支持向量机进行训练和学习。文献[9]将轴心轨迹按象限划分为 4 个区域,分别计算 4 个区域的信息熵作为特征。文献[10]提出基于组合矩和随机森林模型的转子轴心轨迹识别方法。以上方法都是基于轴心轨迹的形态学特征对轴心轨迹形状进行特征提取,并通过机器学习的方法对轴心轨迹进行分类。这些方法对轴心轨迹的规则程度具有较高要求,并且对每种轴心轨迹可能出现的形态考虑不全,泛化能力差,无法适应复杂多变的实际环境。近年来,深度卷积神经网络(Deep Convolutional Neural

Network, DCNN) 因具有强大的自适应特征学习能力,在图像特征提取和识别方面获得了广泛的应用^[11-13]。文献[14]利用 DCNN 对滑动轴承转子轴心轨迹进行识别,但是由于采用二值化方法对轴心轨迹图像进行预处理,在图像中引入多余噪声,使得对不规则轴心轨迹图像的识别率较低,鲁棒性较差。

针对转子轴心轨迹轮廓不清晰造成的误识别、不规则转子轴心轨迹形状识别的鲁棒性不足等问题,本文提出一种基于反灰度预处理的深度卷积神经网络的转子轴心轨迹成像及形状识别方法(Dim-ShapeNet)。将转子轴心轨迹在平面直角坐标系中的位置映射到二维数字图像中,利用反灰度化方法对二维数字图像进行不同波长的融合预处理,加强最大值池化操作过程中的轨迹轮廓信息,同时在充分考虑转子轴心轨迹空间信息特征的基础上,采用 8 层深度学习的 DCNN 提取预处理后的数字图像的局部和全局化拓扑结构特征,提高对不规则转子轴心轨迹形状识别的鲁棒性。实验证明,本文提出的方法对各种不同形态的香蕉形、花瓣形、内“8”形、外“8”形和椭圆形 5 种转子轴心轨迹形状具有良好的识别能力,且具有较好的鲁棒性。

1 转子轴心轨迹成像

转子轴心轨迹可以表示为关于时间 t 的参数方程:

$$\begin{cases} x = f(t) = \sum_{k=1}^N A_k \sin(k\omega t + \alpha_k) \\ y = g(t) = \sum_{k=1}^N B_k \sin(k\omega t + \beta_k) \end{cases} \quad (1)$$

式中: A_k, B_k — k 倍频分量; ω — 角速度, rad/s; α_k, β_k — 初始位置相位。

一个采样周期内,转子轴心在平面直角坐标系中的位置集合为:

$$T = \{(x, y) \mid x = f(t), y = g(t), t \in \mathbb{R}^n\} \quad (2)$$

建立从平面直角坐标系到二维数字图像的映射关系为:

$$\varphi: T \rightarrow I \quad (3)$$

$$I = h(x, y, \lambda) \quad (4)$$

式中: x, y —平面某点的坐标; λ —光的波长。

根据三基色原理,将 I 表示为 3 个基色分量 I_R, I_G, I_B 之和^[15],即

$$I = I_R + I_G + I_B \quad (5)$$

其中,

$$\begin{cases} I_R = h_R(x, y, \lambda_R) \\ I_G = h_G(x, y, \lambda_G) \\ I_B = h_B(x, y, \lambda_B) \end{cases} \quad (6)$$

式中: $\lambda_R, \lambda_G, \lambda_B$ —3 个基色的波长; I_i — $m \times n$ 的数字图像矩阵,数字图像中的每个像素对应于矩阵中相应的元素:

$$I_i = \begin{bmatrix} h(0,0,\lambda_i) & h(0,1,\lambda_i) & \cdots & h(0,n-1,\lambda_i) \\ h(1,0,\lambda_i) & h(1,1,\lambda_i) & \cdots & h(1,n-1,\lambda_i) \\ \vdots & \vdots & & \vdots \\ h(m-1,0,\lambda_i) & h(m-1,1,\lambda_i) & \cdots & h(m-1,n-1,\lambda_i) \end{bmatrix} \quad (7)$$

由于颜色信息并不能反应转子轴心轨迹的形态特征,保留颜色信息只会增大数据规模,因此将数字图像进行灰度化处理^[16]:

$$I^* = \sum c_i I_i, i = R, G, B \quad (8)$$

式中: I_i — I 的分量; c_i —转换系数; I^* —灰度图像。

转子轴心轨迹数字图像经过灰度化处理后,轨迹轮廓由一系列不同程度的黑色组成,即由像素值较小的数值构成。在经过最大值池化操作时,这些构成轨迹轮廓的小像素值会被丢弃,造成图像的信息丢失。为了防止这种情况的出现,对灰度化处理后的数字图像再进行取反操作,即:

$$X = 255E - I^* \quad (9)$$

式中: $X \in \mathbb{N}^{m \times n}$ —反灰度图像的像素矩阵, $E \in \mathbb{N}^{m \times n}$ 中的所有元素均为 1。

经过反灰度化处理后的图像作为 DCNN 的输入,当经过最大值池化操作时,由于轨迹轮廓由像素值较大的数值构成,使得与轨迹轮廓相关的像素值被保存下来,防止了最大值池化操作中信息丢失的情况发生。转子轴心轨迹成像的过程如图 1 所示。




图 1 转子轴心轨迹成像过程

Fig. 1 The process of rotor axis trajectory imaging

2 基于 DCNN 的转子轴心轨迹形状识别

DCNN 是一种专门用来处理具有类似网络结构数据的神经网络,其核心模块是卷积层和池化层。通常,卷积层和池化层交替连接,实现对数据的逐层剖析,达到对输入数据进行深层次特征提取的目的。DCNN 一般由输入层、卷积层、池化层、全连接层和输出层组成,其典型网络结构如图 2 所示。




图 2 DCNN 的典型结构图

Fig. 2 The typical structure of DCNN

采用 3 组卷积层、池化层和 2 组全连接层组成的 DCNN 模型对预处理后的数字图像提取局部和全局拓扑结构特征,输出层使用 Softmax 激活函数,实现对香蕉形、花瓣形、内“8”形、外“8”形和椭圆形 5 种转子轴心轨迹形状的分类。

卷积层通过若干卷积核逐层对特征图进行卷积运算,通过激活函数得到每层卷积网络的特征映射。输入的反灰度图像 X 经过第 1 个卷积层运算后得到的特征映射为:

$$X_j^{\text{conv},1} = f(H_j^{\text{conv},1}) \quad (10)$$

$$H_j^{\text{conv},1} = X * k_{1j}^{\text{conv},1} + b_j^{\text{conv},1} \quad (11)$$

式中: $k_{1j}^{\text{conv},1}$ —第 1 个卷积层中的卷积核矩阵; $b_j^{\text{conv},1}$ —对卷积后特征图的偏置; $H_j^{\text{conv},1}$ —第 1 个卷积层的第 j 个通道的净激活; $f(\cdot)$ —激活函数; $X_j^{\text{conv},1}$ —第 1 个卷积层的第 j 个通道的输出; $*$ —卷积运算。

池化层是一种下采样操作,将特征图特定区域内的相邻像素合并为单一像素,使模型更加关注于特征本身而不是特征所在的具体位置,并且可以减小特征图尺寸,进而减少模型学习过程中的参数数量。通过第 1 个池化层运算后得到的特征映射为:

$$X_j^{\text{pool},1} = f(H_j^{\text{pool},1}) \quad (12)$$

$$H_j^{\text{pool},1} = \beta_j^{\text{pool},1} \cdot \text{down}(X_j^{\text{conv},1}) + b_j^{\text{pool},1} \quad (13)$$

式中: $X_j^{\text{conv},1}$ —池化层的输入; $X_j^{\text{pool},1}$ —池化层的输出; $\beta_j^{\text{pool},1}$ —第 1 个池化层中下采样函数的权重; $\text{down}(\cdot)$ —下采样函数,即对输入特征图 $X_j^{\text{conv},1}$ 通过滑动窗口方法划分为多个不重叠的 $n \times n$ 图像块,然后对每个图像块内的像素求最大值,将图像在两个维度上都缩小了 n 倍。

通过交替的卷积层和池化层运算后得到的特征映射为:

$$X_j^{\text{pool},3} = f(H_j^{\text{pool},3}) \quad (14)$$

$$H_j^{\text{pool},3} = \beta_j^{\text{pool},3} \cdot \text{down}(X_j^{\text{conv},3}) + b_j^{\text{pool},3} \quad (15)$$

$$X_j^{\text{conv},3} = f(H_j^{\text{conv},3}) \quad (16)$$

$$H_j^{\text{conv},3} = \sum_{i=1}^{c_i^{\text{conv},3}} X_i^{\text{pool},2} * k_{ij}^{\text{conv},3} + b_j^{\text{conv},3} \quad (17)$$

$$X_j^{\text{pool},2} = f(H_j^{\text{pool},2}) \quad (18)$$

$$H_j^{\text{pool},2} = \beta_j^{\text{pool},2} \cdot \text{down}(X_j^{\text{conv},2}) + b_j^{\text{pool},2} \quad (19)$$

$$X_j^{\text{conv},2} = f(H_j^{\text{conv},2}) \quad (20)$$

$$H_j^{\text{conv},2} = \sum_{i=1}^{c_i^{\text{conv},2}} X_i^{\text{pool},1} * k_{ij}^{\text{conv},2} + b_j^{\text{conv},2} \quad (21)$$

式中: $X_j^{\text{pool},l}$ —第 l 个池化层的第 j 个通道的输出; $X_j^{\text{conv},l}$ —第 l 个卷积层的第 j 个通道的输出; $k_{ij}^{\text{conv},l}$ —第 l 个卷积层中的卷积核矩阵; $b_j^{\text{conv},l}$ —第 l 个卷积操作后特征图的偏置; $H_j^{\text{conv},l}$ —第 l 个卷积层的第 j 个通道的净激活; $c_i^{\text{conv},l}$ —第 l 个卷积层输入的通道数目。

将最后一个池化层的特征映射整合为一维的列向量作为全连接层,全连接层的特征映射为:

$$X^{d,1} = f(H^{d,1}) \quad (22)$$

$$H^{d,1} = \omega^{d,1} \cdot \text{Flatten}(X^{\text{pool},3}) + b^{d,1} \quad (23)$$

式中: $X^{d,1}$ —第 1 个全连接层的输出; $\text{Flatten}(\cdot)$ —展平函数,将上一层的输出展开成一维列向; $H^{d,1}$ —第 1 个全连接层的净激活; $\omega^{d,1}$ —第 1 个全

连接网络的权值; $b^{d,1}$ —第 1 个全连接层的偏置。

第 2 个全连接层的输出映射为:

$$X^{d,2} = f(H^{d,2}) \quad (24)$$

$$H^{d,2} = \omega^{d,2} \cdot X^{d,1} + b^{d,2} \quad (25)$$

输出层采用 Softmax 实现多分类问题。对香蕉形、花瓣形、内“8”形、外“8”形、椭圆形 5 类样本的训练集 $\{x^i\}_{i=1}^N$, 其样本标签为 $\{y^i\}_{i=1}^N$, 其中 $y^i = 0, 1, \dots, 4$ 。预测某一未知样本为某一类别的概率 $P(y^i = c | x^i)$ 。其数学模型可以表示为:

$$P(y^i = c | x^i) = e^{\theta_j^{\text{T}} x^i} / \sum_{j=0}^4 e^{\theta_j^{\text{T}} x^i} \quad (26)$$

式中: $\theta_j, j = 0, 1, \dots, 4$ —模型的参数; $1 / \sum_{j=0}^4 e^{\theta_j^{\text{T}} x^i}$ —归一化函数,用于归一化概率分布,使得所有概率之和为 1。

使用分类交叉熵作为损失函数,用于衡量网络输出的概率分布和标签的真实分布之间的距离,通过将这两个分布的距离最小化训练网络,可使输出结果尽可能接近真实标签。其数学表达式为:

$$L = - \sum_{i=1}^N [y_i \log \hat{y}_i + (1 - y_i) \log(1 - \hat{y}_i)] \quad (27)$$

式中: N —样本总数; y_i —样本的真实标签; $\hat{y}_i$ —网络输出的预测标签。

DCNN 通过误差反向传播对参数进行学习,通过链式求导法对整个网络的梯度传播进行计算^[17]并更新网络参数:

$$k_{ij}^{\text{conv},l} \leftarrow k_{ij}^{\text{conv},l} - \eta \frac{\partial L}{\partial k_{ij}^{\text{conv},l}} \quad (28)$$

$$b_j^{\text{conv},l} \leftarrow b_j^{\text{conv},l} - \eta \frac{\partial L}{\partial b_j^{\text{conv},l}} \quad (29)$$

$$\beta_j^{\text{pool},l} \leftarrow \beta_j^{\text{pool},l} - \eta \frac{\partial L}{\partial \beta_j^{\text{pool},l}} \quad (30)$$

$$b_j^{\text{pool},l} \leftarrow b_j^{\text{pool},l} - \eta \frac{\partial L}{\partial b_j^{\text{pool},l}} \quad (31)$$

$$\omega^{d,l} \leftarrow \omega^{d,l} - \eta \frac{\partial L}{\partial \omega^{d,l}} \quad (32)$$

3 结果与分析

针对各种不同形态的香蕉形、花瓣形、内“8”形、外“8”形和椭圆形 5 种转子轴心轨迹形状进行

智能识别。首先,采用一对正交的轴向传感器对转子的振动信号进行采集,利用滤波后的振动信号生成转子轴心轨迹数字图像。然后,对转子轴心轨迹数字图像进行反灰度化预处理,利用 DCNN 对训练集图像进行训练,在验证集上衡量模型表现。训练结束后,利用测试集和鲁棒性数据集对最终的轴心轨迹识别结果进行评判。

3.1 模型构建

DCNN 模型通过对输入图像的卷积、池化等交替操作,实现对原始信息的特征提取,再利用若干全连接层完成具体的轴心轨迹分类任务。使用的转子轴心轨迹数据集内容如表 1 所示。DCNN 的具体结构参数如表 2 所示。

表 1 转子轴心轨迹数据集

Tab. 1 The dataset of rotor axis trajectory

轨迹类型	训练集	验证集	测试集	鲁棒性数据集	样本标签
香蕉形	550	20	20	10	0
花瓣形	550	20	20	10	1
内“8”形	534	20	20	10	2
外“8”形	550	20	20	10	3
椭圆形	550	20	20	10	4

表 2 DCNN 结构参数

Tab. 2 The structure parameters of DCNN

网络层	卷积核	通道数	步长	输出形状	激活函数
输入层	-	1	-	(128,128,1)	-
卷积层 1	(7,7)	16	(2,2)	(61,61,16)	ReLu
池化层 1	(2,2)	-	(2,2)	(30,30,16)	-
卷积层 2	(5,5)	32	(2,2)	(13,13,32)	ReLu
池化层 2	(2,2)	-	(2,2)	(6,6,32)	-
卷积层 3	(3,3)	32	(2,2)	(2,2,32)	ReLu
池化层 3	(2,2)	-	(2,2)	(1,1,32)	-
全连接层 1	-	-	-	32	ReLu
全连接层 2	-	-	-	64	ReLu
输出层	-	-	-	5	Softmax

其中,激活函数 ReLu 的数学表达式为:

$$f(X) = \max(0,X)$$
 (33)

3.2 模型训练

利用构建的 DCNN 模型对轴心轨迹图像进行

学习,初始学习率设置为 0.005;训练周期为 150;使用 Adam 优化器,每次从训练集中输入 100 个样本;使用验证集对训练结果进行衡量。为防止过拟合,对全连接层 1 采用 Dropout 技术,并在全连接层 2 中添加 L2 正则化项。训练过程中的误差学习曲线如图 3 所示。




图 3 误差学习曲线

Fig. 3 The learning curve of error

3.3 模型测试

利用训练好的分类模型对测试集中的转子轴心轨迹形状进行识别验证,识别结果的准确性如图 4 所示。




图 4 DimShapeNet 模型的准确性

Fig. 4 The accuracy of DimShapeNet model

除了准确性外,利用混淆矩阵对模型进行评价。混淆矩阵的每一列表示一个预测的类别,每一列的数据总数表示该类别中预测的数据数。每行表示数据的实际类别,每行的数据总数表示属于该类别的样本数量。对于混淆矩阵,对角线上的值越大,矩阵越好。其他位置的值越小,矩阵越好。DimShapeNet 模型的混淆矩阵如图 5 所示。




图 5 DimShapeNet 模型的混淆矩阵

Fig.5 The confusion matrix of DimShapeNet model

图 4 显示了 DimShapeNet 模型的总体准确率为 97.00%。由图 5 可知,模型对香蕉形识别的准确率为 95.00%,对内“8”形识别的准确率为 95.00%,对外“8”形识别的准确率为 95.00%,其他 2 种转子轴心轨迹形状识别的准确率为 100%。

DimShapeNet 模型在准确性、宏查准率、宏查全率和宏 F1 这 4 种评价指标^[18]上的表现均达到 97%,能够对多种不同形状的转子轴心轨迹进行准确、全面的识别。

除了在测试集上对所提方法的表现进行测试,本文还验证了所提方法的鲁棒性。针对 5 种转子轴心轨迹图像,每种选取 10 张形状较为不规则的图形组成鲁棒性数据集,如图 6 所示。




图 6 鲁棒性数据集

Fig.6 The robustness dataset

鲁棒性测试结果如图 7 ~ 图 8 所示。相比于识别规则形状的转子轴心轨迹图像,DimShapeNet 模型在较为复杂的转子轴心轨迹图像识别中准确性有

所下降,但整体的准确率仍可以达到 92.00%。




图 7 鲁棒性数据集上的准确性

Fig.7 The accuracy in robustness dataset




图 8 鲁棒性数据集上的混淆矩阵

Fig.8 The confusion matrix in robustness dataset

3.4 对比分析

为了说明经过反灰度化预处理的转子轴心轨迹图像在识别中的优势,使用相同的网络结构和超参数,分别对灰度图像、RGB 图像和二值图像进行训练和测试,实验结果如表 3 和图 9 ~ 图 10 所示。

表 3 不同图像类型的对比结果

Tab.3 Comparison results of different image types

图像类型	准确 性/%	宏查准 率/%	宏查全 率/%	宏 F1/%	训练时 间/s
反灰度	97.00	97.10	97.00	97.00	672
灰度	91.00	91.28	91.00	91.10	675
RGB	95.00	95.49	95.00	94.89	1012
二值	88.00	88.23	88.00	87.84	675




图 9 不同图像类型的识别结果比较

Fig. 9 The comparison of recognition results of different image types




图 10 不同图像类型的训练时间比较

Fig. 10 The comparison of training time of different image types

由图 9 可知,在相同的网络结构和超参数的前提下,使用二值化方法对原始转子轴心轨迹图像进行预处理,分类结果的准确性、宏查准率、宏查全率和宏 F1 最低,因为在二值化的预处理过程中,会向图像中引入多余的噪声,使得误判的概率增加。使用灰度化方法对原始转子轴心轨迹图像进行预处理,分类结果的准确性、宏查准率、宏查全率和宏 F1 低于反灰度化预处理方法,因为经过灰度化预处理的转子轴心轨迹图像,在最大值池化操作过程中图像信息丢失,影响最终的训练精度。从图 10 中可以看出,只对 RGB 图像进行尺寸上的统一,其训练时间明显高于其他 3 种图像类型。因为 RGB 图像中包含 3 个通道的信息,使得网络参数增多,进而增加了训练时间。经过反灰度化预处理的轴心轨迹识别结果在准确性、宏查准率、宏查全率和宏 F1 上的结果均高于其他 3 种图像预处理方法。因此,经过反灰度化处理的转子轴心轨迹图像在使用 DCNN 进行学习和识别中更具有优势。

除了所提方法外,还对比了其他几种传统的转

子轴心轨迹形状识别方法,实验结果如表 4 和图 11 所示。

表 4 不同识别方法的对比结果

Tab. 4 Comparison results of different recognition methods

方法	准确 性/%	宏查准 率/%	宏查全 率/%	宏 F1/%	鲁棒 性/%
DimShapeNet	97.00	97.10	97.00	97.00	92.00
BP	83.00	83.61	83.00	81.97	78.00
Hu-BP	93.00	93.07	93.00	92.94	76.00
Hu-SVM	85.00	86.80	85.00	84.97	52.00




图 11 不同方法的识别结果比较

Fig. 11 The comparison of recognition results of different methods

从图 11 中可以看出,DimShapeNet 模型在准确性、宏查准率、宏查全率和宏 F1 中都具有较好的识别效果。由于 DimShapeNet 模型具有强大的特征学习能力和非线性拟合能力,因此具有最好的转子轴心轨迹形状识别效果。使用 BP 神经网络对转子轴心轨迹形状进行识别时,需要将图像中的像素逐行展开,并输入全连接层中。该方法会带来过于复杂的模型和过高的存储开销,并且图像在同一列临近的像素经过展开后可能相距较远,它们构成的模式可能难以被模型识别,因此 BP 神经网络方法在针对转子轴心轨迹形状识别中表现最差。通过提取转子轴心轨迹的 Hu 不变矩作为特征向量,然后利用 BP 神经网络对转子轴心轨迹形状进行识别的方法相比直接使用 BP 神经网络的方法在识别准确率上有了较大的提升,但是由于 BP 神经网络为浅层的网络结构,学习能力有限,故识别效果不佳。而 SVM 方法由于其分类器是线性分类器,并不擅长处理非线性问题。因此,本文所提方法相比于传统的转子轴心轨迹形状识别方法具有更高的识别准

确率。

比较 4 种方法在鲁棒性数据集上的表现,如图 12 所示。DimShapeNet 模型在针对不规则轴心轨迹的识别中,准确性明显高于其他 3 种方法。相比于其他 3 种浅层结构的识别方法,DCNN 深层次的网
络结构可以充分提取输入数据的局部和全局化拓扑结构特征,提高泛化性能的同时具有很好的鲁棒性。




图 12 不同方法的鲁棒性比较

Fig. 12 The comparison of robustness by different methods

4 总 结

(1) 本文所提方法可以有效地对 5 种不同形状的转子轴心轨迹进行精准识别。识别准确率、宏查
准率、宏查全率和宏 F1 均达到 97%。

(2) 对比使用 RGB 图像、灰度图像和二值图像的识别效果,经过反灰度化预处理的转子轴心轨迹
数字图像在深度卷积神经网络的训练中更有优势。

(3) 对比 BP 神经网络、Hu 矩 + BP 神经网络以及 Hu 矩 + SVM 等传统轴心轨迹识别方法,本文所
用的 DimShapeNet 模型在进行转子轴心轨迹形状识别中具有更高的准确率和更好的鲁棒性。

通过实现转子轴心轨迹形状的智能识别,为转
子智能诊断提供了重要的故障特征,为后续与其他故障特征结合实现更加精准的转子智能诊断奠定了
基础。

参考文献:

[1] 孟凡刚,黄延忠,冯永志,等. 重型燃气轮机转子不对中故障动

力学数值仿真研究[J]. 热能动力工程,2021,36(6):51-56.
MENG Fan-gang, HUANG Yan-zhong, FENG Yong-zhi, et al. Dy-
namic numerical simulation of rotor misalignment fault of heavy du-
ty gas turbine[J]. Journal of Engineering for Thermal Energy and
Power,2021,36(6):51-56.
[2] BENLTY D E, HATCH C T. 旋转机械诊断技术[M]. 北京:机
械工业出版社,2014.
BENLTY D E, HATCH C T. Fundamentals of rotating machinery
diagnositics[M]. Beijing:China Machine Press,2014.
[3] 张学延,张卫军,何国安. 火电厂旋转机械振动诊断及治理技
术[M]. 北京:中国电力出版社,2019.
ZHANG Xue-yan, ZHANG Wei-jun, HE Guo-an. Vibration diagno-
sis and treatment technology of rotating machinery in thermal power
plant[M]. Beijing:China Electric Power Press,2019.
[4] 徐创学,张学延,冯挺有,等. 基于云服务的火电机组专家远程
诊断系统[J]. 热力发电,2019,48(9):58-63.
XU Chuang-xue, ZHANG Xue-yan, FENG Ting-you, et al. Expert
remote diagnosis system for thermal power units based on cloud
service[J]. Thermal Power Generation,2019,48(9):58-63.
[5] 戈建新,陶有宏,夏 杰,等. 超临界 630 MW 机组汽轮机高中
压转子低频振动故障诊断与处理[J]. 热力发电,2018,47(7):
75-80.
GE Jian-xin, TAO You-hong, XIA Jie, et al. Fault diagnosis and
treatment of low frequency vibration of high and medium pressure
rotor in a supercritical 630 MW steam turbine[J]. Thermal Power
Generation,2018,47(7):75-80.
[6] 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):167-171,139.
YUAN Qian, SUN Dong-mei, FAN Wen. Automatic identification
method of axis orbits based on D-S evidential theory[J]. Machine
Tool & Hydraulics,2017,45(7):167-171,139.
[7] 孙国栋,艾成汉,周 振,等. 基于高度函数的旋转机械轴心轨
迹识别方法[J]. 中国测试,2017,43(9):118-122.
SUN Guo-dong, AI Cheng-han, ZHOU Zhen, et al. Axis orbit iden-
tification of rotating machine based on height function[J]. China
Measurement & Test,2017,43(9):118-122.
[8] 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):
969-974.
HE Liu-hai, WU Gui-jiao, WANG Ping. Shift orbit recognition
method of aero-engines based on SVM decision tree[J], China Me-
chanical Engineering,2019,30(8):969-974.
[9] 温广瑞,陈 征,张志芬. 基于模糊 C 均值聚类和转子轴心轨
迹特征的转子状态诊断[J]. 振动与冲击,2019,38(15):

27 – 35.

WEN Guang-rui, CHEN Zheng, ZHANG Zhi-fen. Rotor state diagnosis based on fuzzy C-mean value clustering and its axial center orbit features[J]. Journal of Vibration and Shock, 2019, 38(15): 27 – 35.

[10] 蔡文伟, 张景润, 李伟光, 等. 基于组合矩和随机森林的转子轴心轨迹识别[J]. 机床与液压, 2020, 48(21): 189 – 196.

CAI Wen-wei, ZHANG Jing-run, LI Wei-guang, et al. Identification of rotor shaft orbit based on combined moment invariants and random forest[J]. Machine Tool & Hydraulics, 2020, 48(21): 189 – 196.

[11] OLIVIER J, VIKTOR S, BRAM V, et al. Convolutional neural network based fault detection for rotating machinery[J]. Journal of Sound and Vibration, 2016, 377: 331 – 345.

[12] WANG Li-hua, ZHAO Xiao-ping, WU Jia-xin, et al. Motor fault diagnosis based on short-time Fourier transform and convolutional neural network[J]. Chinese Journal of Mechanical Engineering, 2017, 30(6): 1357 – 1368.

[13] LI Hong-mei, HUANG Jin-ying, JI Shu-wei. Bearing fault diagnosis with a feature fusion method based on an ensemble convolutional neural network and deep neural network[J]. Sensors, 2019, 19(9): 1 – 18.

[14] 郭明军, 李伟光, 杨期江, 等. 深度卷积神经网络在滑动轴承转子轴心轨迹识别中的应用[J]. 振动与冲击, 2021, 40(3): 233 – 239, 283.

GUO Ming-jun, LI Wei-guang, YANG Qi-jiang, et al. Application of deep convolution neural network in identification of journal bearing rotor center orbit[J]. Journal of Vibration and Shock, 2021, 40(3): 233 – 239, 283.

[15] 朱秀昌, 刘 峰, 胡 栋. 数字图像处理与图像通信(第4版)[M]. 北京: 北京邮电大学出版社, 2016.

ZHU Xiu-chang, LIU Feng, HU Dong. Digital image processing and image communication (4th Edition)[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2016.

[16] 吴 娱. 数字图像处理[M]. 北京: 北京邮电大学出版社, 2017.

WU Yu. Digital image processing[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2017.

[17] 常 亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300 – 1312.

CHANG Liang, DENG Xiao-ming, ZHOU Ming-quan, et al. Convolutional neural networks in image understanding[J]. Acta Automatica Sinica, 2016, 42(9): 1300 – 1312.

[18] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.

ZHOU Zhi-hua. Machine learning[M]. Beijing: Tsinghua University Press, 2016.

(姜雪梅 编辑)