

DOI: 10.13382/j.jemi.B2003813

# 基于 WDCNN-SVM 深度迁移学习的 燃气轮机转子故障诊断方法\*

唐竞鹏<sup>1,2</sup> 王红军<sup>1,2</sup> 钟建琳<sup>1,2</sup> 刘淑聪<sup>1,2</sup> 张翔<sup>1,2</sup> 徐伍峰<sup>3</sup>(1. 北京信息科技大学机电工程学院 北京 100192; 2. 高端装备制造智能感知与控制  
北京市国际科技合作基地 北京 100192; 3. 南京航空航天大学航空学院 南京 210016)

**摘要:** 针对在使用深度学习对燃气轮机转子故障诊断过程中,因振动信号样本中正常运行数据多、故障数据少而使得模型故障诊断准确率低的问题,提出了一种采用深度迁移学习对燃气轮机转子进行故障诊断的方法。首先,使用典型行业样本数据集预训练第一层宽卷积核深度卷积神经网络(WDCNN)模型,给予模型初始的权重。其次,在源域中,使用某型燃气轮机试车获得的大量正常运行样本更新 WDCNN 模型的权重;在目标域中,利用源域训练的卷积层提取燃气轮机的正常和故障数据样本特征,然后使用支持向量机(support-vector machines, SVM)进行分类识别,从而达到燃气轮机故障识别的目的。试车数据实验结果表明,该方法能够实现 96% 的识别准确率,验证了将轴承数据集预训练的深度学习模型迁移到燃气轮机转子领域进行故障诊断的可行性。

**关键词:** 燃气轮机转子; 振动分析; 迁移学习; 故障诊断

**中图分类号:** TK477 **文献标识码:** A **国家标准学科分类代码:** 470

## Gas turbine rotor fault diagnosis method based on WDCNN-SVM deep transfer learning

Tang Jingpeng<sup>1,2</sup> Wang Hongjun<sup>1,2</sup> Zhong Jianlin<sup>1,2</sup> Liu Shucong<sup>1,2</sup> Zhang Xiang<sup>1,2</sup> Xu Wufeng<sup>3</sup>

(1. School of Mechanical and Electrical Engineering, Beijing Information Science &amp; Technology University, Beijing 100192, China; 2. Intelligent Perception and Control of High-end Equipment Beijing International Science and Technology Cooperation Base, Beijing 100192, China; 3. College of Aerospace Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

**Abstract:** In industries for gas turbine rotor, there are a large number of normal operation vibration signal sample data and few fault data, which caused fault diagnosis accuracy lower. A gas turbine rotor deep transfer learning fault diagnosis method is proposed. First, a first-layer wide convolutional kernel deep convolutional neural network (WDCNN) model is pre-trained with a typical industry sample dataset, obtained the model initial weights. Second, in the source domain, the weights of the WDCNN model are updated using a large number of normal operation samples obtained from the test drive of a certain type of gas turbine; In the target domain, the normal and fault data sample characteristics of the gas turbine are extracted by using the convolutional layer trained in the source domain, and then the support vector machines (SVM) are used for classification identification, so as to achieve the gas turbine fault identification. The experimental results of the test data show that the method identification accuracy is 96%, which verifies the feasibility of migrating the pre-trained deep learning model of the bearing dataset to the field of gas turbine rotor for fault diagnosis.

**Keywords:** gas turbine rotor system; vibration analysis; transfer learning; fault diagnosis

## 0 引言

燃气轮机作为一种高价值的动力设备,稳定的运行状态、较高的可靠性和安全性、较低的运行和维护成本是用户最关心的问题。转子系统作为整机的核心部分,因其高速、高温、高压、高应力的工作条件,不可避免地会产生一些故障,而一旦产生故障会对机组安全运行造成严重影响。因此,对燃气轮机转子系统进行故障诊断具有重要意义。

近年来,随着 VGG<sup>[1]</sup>、ResNet (residual neural network)<sup>[2]</sup>等深度学习模型在 ILSVRC (imageNet large scale visual recognition challenge) 竞赛上获得了越来越高的目标检测和图像分类精度,深度学习在故障识别领域也取得了突破性的应用。He 等<sup>[3]</sup>基于短时傅立叶变换获得的简单频谱矩阵,构建了优化的深度学习结构,大内存存储检索神经网络来诊断轴承故障。Lv 等<sup>[4]</sup>基于堆叠稀疏自动编码器,提出了一种用于学习故障数据的深度架构,以最大程度地减少信息丢失。Jia 等<sup>[5]</sup>使用标准化稀疏自动编码器和本地连接网络,将特征提取和故障识别合并到通用学习过程中,实现对机械健康状况的有效识别。

在燃气轮机领域,陈宇飞<sup>[6]</sup>提取了燃气轮机不同故障状态下振动信号的特征值,使用自组织特征映射 (self-organizing feature map, SOM) 神经网络对燃气轮机故障进行分类。蒋龙陈等<sup>[7]</sup>针对燃气轮机故障信号为变速非平稳信号的特点,使用非线性调频分量分解方法对燃气轮机机匣振动信号进行时频分析,并利用卷积神经网络对燃气轮机转子进行故障诊断。崔建国等<sup>[8]</sup>采用核主元分析 (kernel principal component analysis, KPCA) 方法对燃气轮机试验台上获得的主泵等主要部件原始信号进行处理,构建核主元特征向量,并创建深度学习故障诊断模型,对燃气轮机进行了故障诊断技术研究。闫丽萍等<sup>[9]</sup>为提高燃气轮机气路故障诊断精度,提出了一种基于遗传算法自适应调整深度置信网络 (deep belief network, DBN) 初始参数的优化算法。蒋龙陈等<sup>[10]</sup>针对某燃气轮机气流激振故障建立了基于峰值保持降采样和粒子群优化的 DBN 故障模型。刘隆波等<sup>[11]</sup>提出了一种基于小波变换和 BP 神经网络的方法,实现了对燃气轮机转子不平衡、齿轮缺陷、紧固件松动 3 种典型故障状态的识别。

随着算法和用于算法验证的开源数据集<sup>[12]</sup>的发展,迁移学习在解决小样本问题方面展现出了更大的优势。如 Tong 等<sup>[13]</sup>使用凯斯西储大学数据集 (CWRU) 验证了其在可变工况下通过特征迁移学习进行区域自适应识别轴承故障的方法。Sobie 等<sup>[14]</sup>从滚动轴承动力学的高分辨率模拟中获得的信息生成训练数据,同时使用机械故

障预防技术协会 (MFPT) 数据集验证了提出算法的优越性。Wen 等<sup>[15]</sup>使用帕德博恩大学数据集验证了提出的基于 ResNet-50 的迁移卷积神经网络轴承故障诊断方法的可行性。Guo 等<sup>[16]</sup>使用辛辛那提大学智能维护系统中心 (IMS) 等数据集证明了提出的未标记数据机器智能故障诊断方法的可行性。Wang 等<sup>[17]</sup>使用西安交通大学轴承数据集 (XJTU-SY bearing datasets) 评估了预测滚动轴承剩余使用寿命混合方法的有效性。

但对于燃气轮机转子系统,因其整机封闭式的设计准则,使得难以直接获取转轴上的振动信息。工程上,一般通过燃气轮机的整机振幅超限预警来提示机器发生故障,进而停机检修。另外,不同型号的燃气轮机往往其故障振动特征的表现形式不同,同型号机组之间也存在获取的正常运行数据多、故障数据少且故障模式较为单一的问题,加之涉及行业保密,难以形成一个通用的完备故障数据库。

所以,卷积神经网络 (convolutional neural networks, CNN) 虽然已在旋转机械故障诊断中得到了应用,但由于需要大样本训练的特性,面对燃气轮机正常工况数据海量而故障数据缺乏和故障模式不完备等问题,并没有充分发挥自身强大的自主学习能力。另一方面,传统神经网络算法的样本处理对人工专业信号处理和提取特征依赖较大,因此算法能力受限。综上,本文提出一种将轴承数据集预训练的模型迁移到燃气轮机转子领域进行故障诊断的方法。

## 1 基于 WDCNN-SVM 的深度迁移学习方法

提出的 WDCNN-SVM 方法可分为 3 部分:1) 选用标准轴承的原始振动加速度数据作为输入,预训练 WDCNN 模型,在获得较为理想的分类效果后,保存整个模型;2) 将预训练的模型导入源域,使用新的 Flatten 层和 Softmax 层替换对应的旧层,冻结块 1,微调块 2~5,在带标签的燃气轮机正常数据集上进行训练,更新模型权重;3) 在目标域中,以燃气轮机转子的部分正常样本和故障样本数据集为输入,将源任务中的前 3 个块迁移至目标任务中,建立特征映射模型,将目标域映射到一个新的特征空间,得到目标域数据集所有的映射特征,利用 SVM 对这些映射特征进行分类。整体模型结构如图 1 所示。

### 1.1 轴承数据预训练 WDCNN 模型

WDCNN 模型<sup>[18]</sup>是由 5 个基础模块组成的神经网络,如图 1 所示(左),每个基础模块都包含了一个卷积层、批量归一化层 (batch normalization, BN)、激活层 (activation) 和最大池化层 (max pooling)。其中,前一个块的输出作为下一个块的输入,第 1 模块中的卷积层使用了  $64 \times 1$  大卷积核、其他模块的卷积层均为  $3 \times 1$  小卷




图 1 模型结构

Fig. 1 Diagram of model structure

积核,卷积计算如式(1)所示,该结构的优势在于直接以端到端的方式对输入的一维振动信号进行较好的特征提取,而无需手动统计各种特征。

$$x_j^l = f\left(\sum_{i=1}^M x_i^{l-1} * k_{ij}^l + b_j^l\right) \quad (1)$$

式中:  $x_j^l$  为  $l$  层的第  $j$  个特征映射;  $f(\cdot)$  为激活函数;  $M$  为输入特征映射的个数;  $x_i^{l-1}$  为  $l-1$  层的第  $i$  个特征映射;  $*$  为卷积操作;  $k_{ij}^l$  为可训练的卷积核;  $b_j^l$  为偏置。

将样本按 7 : 3 的比例随机划分为训练集和测试集,以近似为 0 的随机值初始化 WDCNN 模型的权重,使用训练集数据训练模型,经过网络的不断迭代训练,误差不断被计算更新。测试集数据测试模型,当迭代完成后,如果获得了 95% 以上的分类精度,则保存整个模型,为下一步的模型迁移做准备。训练期间,模型利用反向传播更新权值、阈值和卷积核参数,模型参数的更新和保存如图 2 所示。

## 1.2 模型迁移

将轴承数据预训练的 WDCNN 模型导入仅有燃机转子正常数据集的源域,为避免已使用的轴承标签对新的转子数据集训练的影响,分别使用新的 Flatten 层和




图 2 预训练阶段权重更新流程

Fig. 2 The flow chart of weight update in pre-training phase

Softmax 层替换预训练模型的对应层,以识别新的正常的转子数据特征。为了充分利用在轴承数据集上预训练 WDCNN 模型的特征提取功能,在获得转子正常样本数据集后,只冻结 WDCNN 的第一层卷积层,即卷积层的参数不随训练迭代而改变。使用转子正常样本数据集训练模型,根据式(2)~(5)更新其余卷积层和完全连接层中的权重,通过反向传播对网络进行超参数优化,以最大程度地减少了预测标签和真实标签之间的误差。经过足够的迭代之后,对设计的模型进行了微调,并将深层结构与所有参数保存,流程如图 3 所示。




图 3 模型迁移阶段权重更新

Fig. 3 The flow chart of weight update in model migration stage

完全连接层的权重更新:

$$W^l(t+1) = W^l(t) - \eta \frac{\partial E}{\partial W^l} \quad (2)$$

$$b^l(t+1) = b^l(t) - \eta \frac{\partial E}{\partial b^l} \quad (3)$$

卷积层的权重更新:

$$k_{ij}^l(t+1)=k_{ij}^l(t)-\eta\frac{\partial E}{\partial k_{ij}^l} \tag{4}$$

$$b_j^l(t+1)=b_j^l(t)-\eta\frac{\partial E}{\partial b_j^l} \tag{5}$$

式中： $t$  为迭代次数； $\eta$  为学习率； $W^l$  为第  $l$  层的权重； $E$  为均方误差函数。

1.3 特征迁移

经过模型迁移训练后,该模型已具备基本的转子数据识别能力,将一直被冻结权重的第 1 层卷积层、被更新权重后的第 2 层和第 3 层卷积层作为特征提取层映射到目标域中,并使用燃气轮机的部分正常样本数据和故障样本数据作为输入,将卷积层提取的特征向量输入到 SVM 分类器中进行故障分类,流程如图 4 所示。




图 4 特征迁移流程

Fig. 4 The flow chart of feature transfer

2 实验验证与分析

2.1 研究对象

以某型双转子燃气轮机为研究对象,如图 5 所示,其转子系统主要由压气机、涡轮、转轴等组成。低压涡轮通过低压转轴连接低压压气机,高压涡轮通过套在低压转轴上的高压转轴连接高压压气机。




图 5 某型燃气轮机结构示意图

Fig. 5 Schematic diagram of gas turbine structure

由于燃气轮机复杂且高温的内部环境,业内常采用整机测振的方式,通过在不同位置、角度的多次实验与分析,选取了在低压压气机机匣前端的径向位置上安装一个速度传感器作为前测点,在高压压气机与燃烧室之间机匣径向位置上安装一个速度传感器作为后测点,以及

在燃气机内部安装测量高低压转子转速传感器的测试方案。

2.2 数据预处理

采集到的燃气轮机转子数据由于软件供应商出于商业保密进行了封装,无法直接获取到原始数据,因此在使用神经网络方法判断燃气轮机转子状态时,需对采集到的燃气轮机整机信号进行预处理,处理流程如图 6 所示,经过软件存储分析,然后将历史数据转换为可以打开编辑的 txt 文档,为了更加方便和快速地读取和存储数据,使用 MATLAB 软件将 txt 文档转换为 mat 文件,依据对数据的时域、频域及时频域分析,最后制成样本并作为方法模型的输入。




图 6 数据预处理流程

Fig. 6 The flow chart of data preprocessing

振动速度的有效值(root mean square ,RMS)反应了周期内系统的动能,式(6)可以表示振动的强烈程度,经过企业的实践验证,选取  $RMS=8$  作为燃气轮机振动评价上限,超过 8 的部分判定为超限故障;另外,振幅超过转频的部分也被判断为一种故障类型;其余不超限的部分为正常类型。

$$RMS=\sqrt{\frac{1}{N}\sum_{k=1}^N X^2(k)} \tag{6}$$

式中： $N$  为测量次数； $X(k)$  为第  $k$  个测量值。

2.3 轴承数据预训练 WDCNN 模型

选取凯斯西储大学轴承数据集中 0 马力(horsepower, HP)下驱动端的 10 类数据,采样频率 12 kHz,如表 1 所示,每类数据取 700 个训练样本,200 个验证样本,每个样本长度为 2 048 个点,对 WDCNN 模型进行训练,获得 95% 以上的分类精度后,保存整个模型。其中,WDCNN 模型的结构参数如表 2 所示,除第 1 层卷积层采用了  $64\times 1$  的大卷积核(步长为  $16\times 1$ )外,其他卷积层均采用了  $3\times 1$  的小卷积核(步长为  $1\times 1$ )。为更好的提取一维原始信号的特征,前 4 层卷积层采用边界补零

方式,第 5 层卷积层和池化层均未采取边界补零。

表 1 轴承数据样本设置

| Table 1 Samples setting of bearing datasets |      |         |           |           |
|---------------------------------------------|------|---------|-----------|-----------|
| 标签                                          | 故障位置 | 损伤直径/mm | 训练样本      | 验证样本      |
| 0                                           | 无    | 0       | 700×2048  | 200×2 048 |
| 1                                           | 滚动体  | 0.177 8 | 700×2 048 | 200×2 048 |
| 2                                           | 滚动体  | 0.355 6 | 700×2 048 | 200×2 048 |
| 3                                           | 滚动体  | 0.533 4 | 700×2 048 | 200×2 048 |
| 4                                           | 内圈   | 0.177 8 | 700×2 048 | 200×2 048 |
| 5                                           | 内圈   | 0.355 6 | 700×2 048 | 200×2 048 |
| 6                                           | 内圈   | 0.533 4 | 700×2 048 | 200×2 048 |
| 7                                           | 外圈   | 0.177 8 | 700×2 048 | 200×2 048 |
| 8                                           | 外圈   | 0.355 6 | 700×2 048 | 200×2 048 |
| 9                                           | 外圈   | 0.533 4 | 700×2 048 | 200×2 048 |

表 2 WDCNN 网络结构设置

| Table 2 Setting of WDCNN model |         |           |       |        |    |
|--------------------------------|---------|-----------|-------|--------|----|
| 编号                             | 网络层     | 卷积核大小     | 卷积核数目 | 输出大小   | 零补 |
| 1                              | 卷积 1    | 64×1/16×1 | 16    | 128×16 | 是  |
| 2                              | 池化 1    | 2×1/2×1   | 16    | 64×16  | 否  |
| 3                              | 卷积 2    | 3×1/1×1   | 32    | 64×32  | 是  |
| 4                              | 池化 2    | 2×1/2×1   | 32    | 32×32  | 否  |
| 5                              | 卷积 3    | 3×1/1×1   | 64    | 32×64  | 是  |
| 6                              | 池化 3    | 2×1/2×1   | 64    | 16×64  | 否  |
| 7                              | 卷积 4    | 3×1/1×1   | 64    | 16×64  | 是  |
| 8                              | 池化 4    | 2×1/2×1   | 64    | 8×64   | 否  |
| 9                              | 卷积 5    | 3×1/1×1   | 64    | 6×64   | 否  |
| 10                             | 池化 5    | 2×1/2×1   | 64    | 3×64   | 否  |
| 11                             | 全连接     | 100       | 1     | 100×1  |    |
| 12                             | Softmax | 10        | 1     | 10     |    |

轴承数据预训练 WDCNN 的训练与验证精度如图 7 所示,由图 7 可知,使用验证集验证模型时,经过 8 次迭代后就获得了 99% 的分类识别精度。而且,轴承数据训练集和验证集的分类效果分别如图 8 和 9 所示,模型对训练集中 10 类数据均达到完全分类,在验证集中,仅将一个滚动体故障(标签为 2)错分为正常样本(标签为 0)。由此可知,使用轴承预训练的 WDCNN 模型取得了较好的分类结果。

2.4 模型迁移

在源域中,为了提高模型对燃气轮机转子数据的泛化能力,依据燃气轮机工作功率的不同将燃气轮机转子正常类型的数据细分为 0.1 工况、0.35 工况、0.6 工况、0.8 工况和 1.0 工况。如表 3 所示,每类工况数据取 2 100 个训练样本,600 个验证样本,每个样本长度为 2 048 个点,对预训练的 WDCNN 模型进行权重更新。为




图 7 轴承数据集的精度

Fig. 7 Precision figure of bearing datasets




图 8 轴承数据训练集的分类效果

Fig. 8 Classification effect of training set of bearing datasets

避免燃气轮机转子正常数据集标签与 2.3 节轴承标签的分类冲突,分别使用新的 Flatten 层和 Softmax 层替换预训练 WDCNN 模型的对层。

表 3 燃气轮机转子数据样本设置

| Table 3 Samples setting of the gas turbine rotor |    |         |    |             |           |
|--------------------------------------------------|----|---------|----|-------------|-----------|
| 标签                                               | 类型 | 工况      | 域  | 训练样本        | 验证样本      |
| 0                                                | 正常 | 0.1 工况  | 源域 | 2 100×2 048 | 600×2 048 |
| 1                                                | 正常 | 0.2 工况  | 源域 | 2 100×2 048 | 600×2 048 |
| 2                                                | 正常 | 0.35 工况 | 源域 | 2 100×2 048 | 600×2 048 |
| 3                                                | 正常 | 0.6 工况  | 源域 | 2 100×2 048 | 600×2 048 |
| 4                                                | 正常 | 0.8 工况  | 源域 | 2 100×2 048 | 600×2 048 |
| 5                                                | 正常 | 1.0 工况  | 源域 | 2 100×2 048 | 600×2 048 |

为了充分利用在轴承数据集上预训练 WDCNN 模型的特征提取功能,冻结第 1 层卷积层,即第 1 层卷积层参数不随训练迭代而改变。在训练过程中,首先设置第 2 层到第 5 层卷积层的学习速率为 0.000 1,批大小 (batch) 设置为 128,迭代次数为 30。因为第 5 层卷积层




图 9 轴承数据验证集的分类效果

Fig. 9 Classification effect of validation set of bearing datasets

为最后一层卷积层,需从第 1 层开始训练,为加快训练速度与获得更优效果,经过不同量级的调试,将第 5 层卷积层的学习率调为 0.01。转子正常数据训练与验证精度如图 10 所示,验证集虽在迭代 18 次时可能因数据误判出现了较低的认识精度,但在 23 次迭代后,获得了较为稳定的 95% 的分类精度结果,证明预训练的 WDCNN 模型经过权重更新后仍有较好的分类性能。




图 10 转子正常数据集的精度图

Fig. 10 Precision figure of gas turbine normal rotor datasets

2.5 特征迁移

将预训练好的 WDCNN 模型经过源域燃气轮机转子正常样本训练,微调了网络参数后迁移到目标域对燃气轮机数据进行特征提取,将卷积层提取的特征向量输入到 SVM 分类器中进行故障分类。在目标域中,使用燃气轮机转子正常样本(0.35 工况)、超限(振幅超 8)和振幅超转频 3 种类型的数据,时域图如图 11 所示。

样本设置如表 4 所示,每种数据取 2 100 个训练样本,600 个验证样本,每个样本长度为 2 048 个点。




图 11 燃气轮机不同状态下的振动信号

Fig. 11 Vibration signals of gas turbine under different conditions

表 4 燃气轮机转子数据样本设置

Table 4 Samples setting of the gas turbine rotor

| 标签 | 类型 | 表现      | 域   | 训练样本        | 验证样本      |
|----|----|---------|-----|-------------|-----------|
| 0  | 故障 | 超限      | 目标域 | 2 100×2 048 | 600×2 048 |
| 1  | 故障 | 振幅超转频   | 目标域 | 2 100×2 048 | 600×2 048 |
| 2  | 正常 | 0.35 工况 | 目标域 | 2 100×2 048 | 600×2 048 |

学习率、迭代次数等训练相关参数称为卷积神经网络的超参数,影响训练算法的时间和成本,在特征迁移的过程中采用了择优选择的方法,最终选用学习率为 0.000 1,迭代次数为 100,批大小为 128。

在故障样本少的目标任务中,首先使用了 Softmax 分类器对卷积层提取的特征进行分类,使用验证集验证的

分类效果如图 12 所示,在对超限(标签为 0)故障识别中,有 163 组数据被误认为是振幅超过转频(标签为 1),因此,Softmax 对两类故障识别的效果较差。




图 12 使用 Softmax 分类器的验证集分类效果  
Fig. 12 Classification effect of Softmax

SVM<sup>[19]</sup>使用部分支持向量做超平面决策,无需依赖全部数据,在解决小样本分类上有着出色的性能,所以将卷积层提取的特征向量输入到 SVM 分类器中进行故障分类。选用径向基函数(radial basis function, RBF)做 SVM 的核函数;gamma 参数定义了单个训练示例的影响达到的程度,设置为自动模式,低值表示“远”,高值表示“接近”;参数 C 权衡了训练示例的正确分类与决策函数裕度的最大化之间的权衡,选取默认值 1。分类的混淆矩阵结果如图 13 所示。




图 13 使用 SVM 分类器的验证集分类效果  
Fig. 13 Classification effect of SVM

从图 13 可以看出,使用 SVM 分类器的模型能够很好地识别转子正常(标签为 2)类型;在对超限(标签为

0)和振幅超过转频(标签为 1)两种故障类型的识别中,仅出现了 11 组和 59 组的小概率误判情况,原因可能是一方面两种信号中都存在了噪声干扰,导致分类错误,另一方面都属于整机测振信号,其包含了相似的频率和幅值成分,从而出现分类误判。为了排除试验的随机性,分别进行了 10 组试验,得到平均训练分类准确率为 99%,平均验证分类准确率为 96%。

2.6 与其他方法的对比实验

为验证提出方法的有效性,同样以目标域中燃气轮机转子正常样本(0.35 工况)、超限(振幅超 8)和振幅超转频 3 种类型数据样本中的训练集训练 CNN 和 SVM 两种经典分类模型,并使用同样的验证集验证模型性能。其中,CNN 算法仍包含 5 层卷积层,但每层均采用 3×1 小卷积核,卷积核数目除第 1 层为 16 外,其余均为 32。SVM 的参数设置与 2.5 节相同。在联合分布适配(joint distribution adaptation, JDA)<sup>[20]</sup>迁移方法的对比实验中,将燃气轮机转子正常样本(0.35 工况)、超限(振幅超 8)和振幅超转频 3 种类型数据样本均分到源域和目标域中,使用 JDA 方法适配缩减源域数据和目标域数据的差异,将变换后的源域样本归一化后输入到 DBN 中,并使用验证集验证 JDA-DBN 模型的分类性能。同时,为避免偶然性,每种方法分别进行 10 次实验,取 10 次实验的平均值作为最终实验结果。结果如表 5 所示,本文提出的迁移方法比 JDA-DBN 迁移方法高出了 6%的准确率,表明模型经过轴承数据预训练并获得权重后具有更好的特征提取和分类能力。而仅使用 SVM 时因为其浅层结构,只获得了 85%的识别精度,限制了识别率的进一步提升。在仅使用 CNN 作为模型时,由于故障样本数量的限制,没有充分发挥卷积网络的泛化能力,因此其识别率较迁移方法相比仍然有差距。

表 5 不同方法的分类效果  
Table 5 Experimental results of different methods  
(%)

| 方法      | 训练准确率 | 验证准确率 |
|---------|-------|-------|
| SVM     | 89    | 85    |
| CNN     | 90    | 88    |
| JDA-DBN | 92    | 90    |
| 本文      | 99    | 96    |

3 结 论

本文所提出基于 WDCNN-SVM 深度迁移学习的燃气轮机转子故障诊断方法相较于其他故障诊断方法具有以下优势:充分发挥了轴承等公开数据集故障种类齐全、数据样本丰富的优势,使用其预训练模型,并将学习到的

权重迁移到燃气轮机转子领域中进行故障诊断,精度较高,可以给维修人员提供维修策略或建议,有利于解决燃气轮机转子正常运行数据多、故障数据少而难以形成均衡类别训练模型的问题。

## 参考文献

- [1] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]. 3rd International Conference on Learning Representations, 2015:1-14.
- [2] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016:70-78.
- [3] HE M, HE D. Deep learning based approach for bearing fault diagnosis [J]. IEEE Transactions on Industry Applications, 2017, 53(3): 3057-3065.
- [4] LV F, WEN C, BAO Z, et al. Fault diagnosis based on deep learning [C]. Proceedings of the American Control Conference, 2016: 6851-6856.
- [5] JIA F, LEI Y, GUO L, et al. A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines [J]. Neurocomputing, 2018, 272(6):19-28.
- [6] 陈宇飞. 基于神经网络的燃气轮机故障诊断方法研究[D]. 保定:华北电力大学, 2015.  
CHEN Y F. Research on gas turbine fault diagnosis method based on neural network [D]. Baoding: North China Electric Power University, 2015.
- [7] 蒋龙陈, 王红军, 张顺利, 等. 基于卷积神经网络的燃气轮机故障诊断研究[J]. 北京信息科技大学学报(自然科学版), 2020, 35(5): 25-29.  
JIANG L CH, WANG H J, ZHANG SH L, et al. Research on gas turbine fault diagnosis based on convolutional neural network [J]. Journal of Beijing Information Science and Technology University (Natural Science Edition), 2020, 35(5): 25-29.
- [8] 崔建国, 刘瑶, 于明月, 等. 基于深度学习与信息融合的燃气轮机故障诊断[J]. 机械设计与制造, 2019(12): 28-31.  
CUI J G, LIU Y, YU M Y, et al. Gas turbine fault diagnosis based on deep learning and information fusion [J]. Mechanical Design and Manufacturing, 2019(12): 28-31.
- [9] 闫丽萍, 董学智, 张永军, 等. 基于深度置信网络的燃气轮机气路故障诊断方法[J]. 工程热物理学报, 2020, 41(4): 840-844.  
YAN L P, DONG X ZH, ZHANG Y J, et al. Gas turbine gas path fault diagnosis method based on deep belief network [J]. Journal of Engineering Thermophysics, 2020, 41(4): 840-844.
- [10] 蒋龙陈, 王红军, 张顺利. 燃气轮机气流激振深度置信网络故障诊断模型[J]. 电子测量与仪器学报, 2021, 35(2): 115-121.  
JIANG L CH, WANG H J, ZANG SH L. Depth confidence network fault diagnosis model for gas turbine airflow excited vibration [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 115-121.
- [11] 刘隆波, 黄金娥, 沈君贤. 基于小波神经网络的燃气轮机故障诊断研究[J]. 应用科技, 2019, 46(4): 11-15.  
LIU L B, HUANG J E, SHEN J X. Research on gas turbine fault diagnosis based on wavelet neural network [J]. Applied Science & Technology, 2019, 46(4): 11-15.
- [12] ZHENG H, WANG R, YANG Y, et al. Cross-domain fault diagnosis using knowledge transfer strategy: A Review [J]. IEEE Access, 2019, 7(12):9260-9290.
- [13] TONG Z, LI W, ZHANG B, et al. Bearing fault diagnosis under variable working conditions based on domain adaptation using feature transfer learning [J]. IEEE Access, 2018, 6: 76187-76197.
- [14] SOBIE C, FREITAS C, NICOLAI M. Simulation-driven machine learning: Bearing fault classification [J]. Mechanical Systems and Signal Processing, 2018, 99(4): 3-19.
- [15] WEN L, LI X, GAO L. A transfer convolutional neural network for fault diagnosis based on ResNet-50 [J]. Neural Computing and Applications, 2020, 32(10): 6111-6124.
- [16] GUO L, LEI Y, XING S, et al. Deep convolutional transfer learning network: A new method for intelligent fault diagnosis of machines with unlabeled data [J]. IEEE Transactions on Industrial Electronics, 2019, 66(9): 7316-7325.
- [17] WANG B, LEI Y, LI N, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. IEEE Transactions on Reliability, 2020, 69(1): 401-412.
- [18] 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.
- [19] ZHOU D, ZHANG H, WENG S. A new gas path fault diagnostic method of gas turbine based on support vector machine [J]. Journal of Engineering for Gas Turbines and Power, 2015, 137(10):102605.

[20] LONG M, WANG J, DING G, et al. Transfer feature learning with joint distribution adaptation [ C ]. Proceedings of the IEEE International Conference on Computer Vision, 2013:2200-2207.

作者简介



**唐竞鹏**,2017 年于潍坊学院获得学士学位,现为北京信息科技大学硕士研究生,主要研究方向为智能制造、燃气轮机故障诊断关键技术研究。  
E-mail:2497878080@qq.com

**Tang Jingpeng** received a B. Sc. degree from Weifang University in 2017 . He is currently a M. Sc. candidate at Beijing Information Science and Technology

University. His main research interests include intelligent manufacturing and gas turbine fault diagnosis.



**王红军**(通信作者),2005 年于北京理工大学获得博士学位,现为北京信息科技大学教授,主要研究方向为高端装备智能感知与控制、故障诊断与维护。  
E-mail:wanghj86@163.com

**Wang Hongjun** ( Corresponding author) received her Ph. D. degree from Beijing Institute of Technology in 2005. Now she is a professor at Beijing Information Science and Technology University. Her main research interests include High-end equipment intelligent perception and control, fault diagnosis and maintenance.