

DOI: 10.13382/j.jemi.B2206036

多通道卷积神经网络和迁移学习的 燃气轮机转子故障诊断方法*

苏静雷^{1,2,3} 王红军^{1,2,3} 王政博^{1,2,3} 刘淑聪^{1,2,3} 王楠^{1,2,3} 张顺利^{1,2,3}

(1.北京信息科技大学机电工程学院 北京 100192;2.北京信息科技大学高端装备智能感知与控制北京市国际科技合作基地 北京 100192;3.北京信息科技大学机电系统测控北京市重点实验室 北京 100192)

摘要:燃气轮机结构复杂,工况严苛,实际针对运行过程中转子系统故障样本难以获取,样本量少导致故障诊断精度低的问题,提出一种多通道卷积神经网络(multi-channel convolutional neural network, MCCNN)深度迁移学习的燃气轮机转子故障诊断方法。该方法首先以轴承一维原始振动信号为输入,将数据重新排列组合模拟转换二维图像,有效避免实际转换图像的繁琐操作。用西储大学(CWRU)的公开轴承数据和西安交通大学(XJTU)公开轴承数据对MCCNN模型进行训练更新权重并诊断,取得了100%和99.95%的故障分类准确率。以CWRU轴承故障数据集为源域,燃气轮机转子故障数据集为目标域,利用迁移学习将从源域训练得到的模型参数保留,输入目标域数据集进行训练,并对燃气轮机故障数据进行分类,分类准确率达到97.78%,由实验结果可知多通道卷积神经网络和迁移学习适应任务需要,可以在转子系统故障样本量少的情况下解决问题。

关键词:燃气轮机;多通道卷积;故障诊断;迁移学习方法

中图分类号: TN07;TK477 文献标识码: A 国家标准学科分类代码: 470

Fault diagnosis method of gas turbine rotor with multi-channel convolutional neural network and transfer learning

Su Jinglei^{1,2,3} Wang Hongjun^{1,2,3} Wang Zhengbo^{1,2,3} Liu Shucong^{1,2,3} Wang Nan^{1,2,3} Zhang Shunli^{1,2,3}

(1. School of Mechanical and Electrical Engineering, Beijing Information Science & Technology University, Beijing 100192, China; 2. High-End Equipment Intelligent Perception and Control Beijing International Scientific Cooperation Base, Beijing Information Science & Technology University, Beijing 100192, China; 3. Beijing Key Laboratory of Measurement and Control of Mechanical and Electrical System, Beijing Information Science & Technology University, Beijing 100192, China)

Abstract: In view of the complex structure and severe working conditions of gas turbine, a multi-channel convolutional neural network (MCCNN) deep transfer learning gas turbine rotor fault diagnosis was proposed for the problem that it was difficult to obtain the rotor system fault samples during operation and the fault diagnosis accuracy was low due to the small sample size. The method firstly, took the one-dimensional raw vibration signal of the bearing as the input, then rearranged and combined the data to simulate the converted two-dimensional image, effectively avoiding the tedious operation of the actual converted image. The MCCNN model was trained with the public bearing data from Case Western Reserve University (CWRU) and Xi'an Jiaotong University (XJTU) to update the weights and diagnose. The fault classification accuracy is up to 99.95% ~ 100%. CWRU bearing fault datasets were used as the source domain and the gas turbine rotor fault datasets were used as the target domain, the model parameters obtained from the source domain training were retrained by using transfer learning method for the target domain datasets and the classification accuracy for the gas turbine fault data was 97.78%. The experimental results demonstrated that multi-channel convolutional neural networks and transfer learning model is suitable to the task needs and can solve the problem with a small sample size of rotor system.

Keywords: gas turbine; multi-channel convolution; fault diagnosis; transfer learning method

0 引言

燃气轮机在现代工业中扮演着至关重要的作用,在工业领域得到广泛的应用。若发生故障停机,轻则影响工厂生产,导致经济损失,重则影响人员安全,造成人员生命财产损失。机械故障诊断的发展过程大致经历了3种方法,即基于物理模型的方法、基于信号处理的方法、基于数据驱动的方法^[1]。基于物理模型的方法主要是获取设备的数据信号,建立模型对数据处理结果进行分析,从而得到诊断结果,这需要深入了解机器的工作机理。基于信号处理的方法旨在探索先进的信号去噪和滤波技术,突出故障特征信息,这需要大量的故障表征理论和数学基础。由于现代测量设备的愈加成熟,能够满足燃气轮机转子全生命周期、多传感器的数据需求,采用数据驱动技术的诊断方法成为研究热点,藉由海量的数据通过人工智能手段实现故障的检测和日常运行数据的监测,分析提取特征信息,对系统进行故障诊断和性能评估。该方法不需要大量的领域专家知识和知识的表达式推理机制,也不需要建立精确的复杂系统模型,但常常需要大量的精确数据。

人工智能方法包括机器学习和深度学习,在机器学习中,学习任务之间是相互独立的,由于工况的不断变化导致训练数据和测试数据不再服从独立同分布假设,因此现有机器学习技术无法训练出有效的通用模型。当两者数据分布不同时,在训练集训练好的学习系统无法取得满意表现,需要进行重新训练。深度学习能够自动地从大量数据中提取特征,满足机械故障诊断对自适应特征提取的要求。科研人员已经应用了许多不同的深度学习模型,如堆叠自动编码器^[2](stacked autoencoder, SAE)、深度置信网络(deep belief networks, DBN)、递归神经网络(recursive neural network, RNN)、卷积神经网络^[3](convolutional neural networks, CNN)等,侯荣涛等^[4]、余萍等^[5]使用堆叠自动编码器进行轴承故障诊断优于BP神经网络;李益兵等^[6]使用的粒子群优化的深度置信网络准确率高,鲁棒性好;林天骄等^[7]使用的空洞卷积神经网络处理旋转机械故障诊断分类准确率达99%。这些例子表明深度学习模型在机械故障智能诊断中得到了越来越广泛的应用。对于现实环境中的某些机器,要获取大量的标签数据是非常困难的。另外,即使标记数据可以从某些机器上获得,但由于数据分布的不同,用该标记数据训练的智能故障诊断方法可能无法将从其他机器上获得的未标记数据分类。这就限制了智能故障诊断在无标签数据集和稀疏数据集中的应用。在燃气轮机转子数据中,故障数据较少,难以获得足够的标签数据集,大量数据为正常运行数据。如何利用少量故障数据

训练出分类模型则需要迁移学习的帮助。

迁移学习最初由Pratt^[8]在1992年神经信息处理系统进展大会上提出,发现经过甄别的参数初始化比随机参数初始化训练收敛更快;Pan等^[9]在2009年对迁移学习做了细致的分类。按照迁移学习方法采用的技术划分,可以把迁移学习方法大体上分为:基于特征选择的迁移学习算法研究;基于特征映射的迁移学习算法研究;基于权重的迁移学习算法研究。如今迁移学习发展迅猛,前沿进展有传递迁移学习、深度迁移学习^[10]、迁移强化学习、对抗迁移学习^[11]等。

在迁移学习中,虽然源任务和目标任务不同,但可以从不同源任务的不同数据中挖掘与目标任务相关的知识并帮助目标任务的学习。可通过模型迁移将在轴承数据库中训练得到的权重保留,再利用燃气轮机转子故障数据微调模型得到最终的模型。避免了模型从零开始训练燃气轮机转子故障数据不足的问题。刘飞等^[12]将ResNet18与迁移学习结合同样使用CWRU数据集验证取得了95.2%的准确率;曹梦婷等^[13]将GRU, CNN和迁移学习结合使用CWRU数据集验证取得了98%平均准确率;唐竞鹏等^[14]使用WDCNN和迁移学习针对燃气轮机转子数据取得了96%的平均准确率。可见很多网络都可以适用迁移学习方法以改进模型,提升准确率、减少训练时间,然而论文中一般使用二维卷积神经网络,需要把故障数据转换为二维图片,转换的方式和生成的图像不尽相同,在输入给卷积网络的过程中,分辨率或有折损,使得数据在预处理步骤上繁琐且易丢失数据精度造成网络在判断上不够准确。本文将使用数据重排列以模拟图片的方式,省去实际转换为图片的步骤,将数据准确的反映给网络以便分类更加精确。

1 理论研究

迁移学习是把在某领域获取的知识迁移到对另一个领域的学习中,运用已存有的知识对不同但相关领域问题进行求解的一种新的机器学习方法^[15]。它放宽了传统机器学习中的两个基本假设:1)用于学习的训练样本与新的测试样本满足独立同分布的条件;2)必须有足够可利用的训练样本才能学习得到一个好的分类模型^[16]。因此利用迁移学习可以解决故障数据稀疏问题,只需少量数据即可训练出故障诊断模型。迁移学习中有两个基本领域,源域和目标域,其对应内容如下:

1)源域 D_s 轴承监测数据服从数据分布 $P(X_s)$,样本空间 X_s 包含健康状态标签信息,为识别工程实际轴承的健康状态提供所需的先验知识。

2)目标域 D_t 轴承监测数据服从数据分布 $P(X_t)$,样本空间 X_t 无健康状态标签信息,是诊断模型的应用对象。

3) 源域与目标域之间应具有相关的典型故障类别,且源域须满足目标域的故障诊断知识需要。要求源域数据的标记空间 s 须涵盖目标域数据的标记空间 t 。

迁移学习之所以能够利用稀疏故障数据训练模型,是因为在卷积神经网络的卷积阶段(卷积层、ReLU 层和池化层)提取了输入的一般特征,而全连接阶段的层(全连接层、Softmax 层、分类层)更具体于任务。因此,作为一个整体迁移到新任务的前部的特征提取层可以被视为针对类似任务的训练有素的特征提取工具,最后几层作为待训练的分类器。即使只有少量的训练数据,使用迁移的权重参数作为初始化也可以提高总体性能。相比于传统机器学习,迁移学习有其明显的优势,如表 1 所示。

表 1 迁移学习与传统机器学习对比

Table 1 Comparison between transfer learning and traditional machine learning

矛盾	传统机器学习	迁移学习
大数据与少标注	增加人工标注,但高费用高耗时	数据的迁移标注
大数据与若计算	需要强大计算能力,难推广	模型迁移
普适化模型与个性化需求	通用模型无法满足个性化需求	模型自适应调整
特定应用	冷启动问题无法解决	数据迁移

目前使用的迁移学习方法主要是基于卷积神经网络(convolutional neural network, CNN)模型的迁移,也就是保留模型在源域中训练得到的权重,再结合目标域的分类目标,重构分类全连接层,用目标域的数据训练、微调模型,使其适应新的分类要求,减少训练时间,达到更好的分类效果。

卷积神经网络是一种应用广泛的深度学习模型,具有强大的图像处理能力。CNN 由若干卷积层(Convolutional layer)、池化层(pooling layer)、全连接层(fully connected layer)组成。由于卷积层学到的是局部模式,且具有平移不变性,因此对于感知任务可以高效地利用数据。此外,CNN 的多层次结构可以从大量数据中提取深层次关系,避免了人工特征提取的操作,即实现了特征工程自动化。数据预处理方法也都是将轴承振动数据转化为二维图片输入网络进行分类,如图 1 所示。

图 1 中将已经训练好的图片分类 CNN 模型的权重迁移至新模型中,将振动数据转化为二维时域图片,送入模型进行训练,实现故障分类。

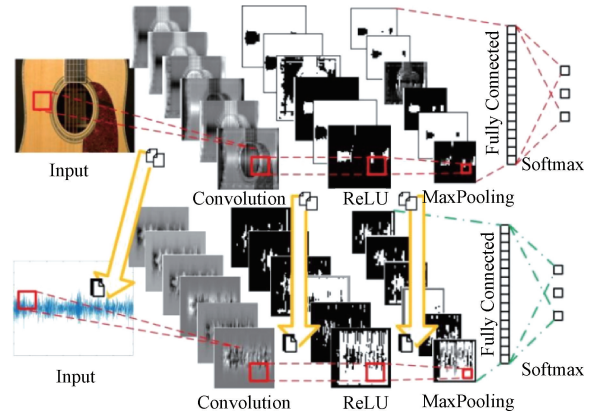


图 1 CNN 模型迁移示意图

Fig. 1 CNN transfer learning diagram

一时段的数据独立出来,转化为二维图片,标记标签,再送入模型中训练。这样的做法一是将同时段各传感器数据分隔开来单独计算,不能全面整体表达故障特征信息,不利于故障数据的分类与检测;二是将一维数据转化为二维图片增加了数据预处理的步骤和时间、占据了更多的计算机资源,不够高效。

卷积神经网络具有强大的图像处理能力,图像一般为 RGB 模式,每种颜色为一个通道,每种颜色的深浅由 0~255 表示,如图 2 所示。一般神经网络训练数据预处理步骤会将一维振动信号排列成矩阵形式再转化为图片,然后将图片送入卷积神经网络中训练,然而即使不将振动信号转为图像,仅将信号值以类似的映射方式转换为“像素矩阵”,将每个传感器接收的振动信号作为一个通道以实现数据预处理,即可送入卷积神经网络中,无需将信号实际转为图片,这样做提高了效率节约了资源,而且可以达到同样的效果。




图 2 RGB 3 通道图片示意图

Fig. 2 RGB 3-channel picture

2 多通道卷积神经网络诊断方法

2.1 数据预处理

现代监测机械设备往往在仪器设备的不同位置放置多个传感器同时采集数据,分析数据时将多个传感器同

由传感器得到的振动数据是一维的,但可以将其进行二维排列成矩阵,排列方式定义如式(1)所示:

$$(a_1, a_2, \dots, a_n) = \begin{pmatrix} a_{1,1} & \dots & a_{1,m} \\ \vdots & \ddots & \vdots \\ a_{m,1} & \dots & a_{m,m} \end{pmatrix},$$

$$\begin{pmatrix} a_{m+1,1} & \dots & a_{m+1,m} \\ \vdots & \ddots & \vdots \\ a_{2m,1} & \dots & a_{2m,m} \end{pmatrix}, \dots \quad (1)$$

首先选定矩阵的边长 m , 将 n 个振动数据点按顺序横向依此排列, 在排满第 1 个矩阵后, 再排列第 2 个矩阵, 以此类推。

机械设备振动数据往往需要多个传感器同时采集, 将不同位置的 n 个传感器数据并行排列, 同时将每个传感器数据按顺序排列成 $m \times m$ 二维矩阵。此时 $n \times m \times m$ 个数据点将打包作为一个数据单元。如图 3 所示。

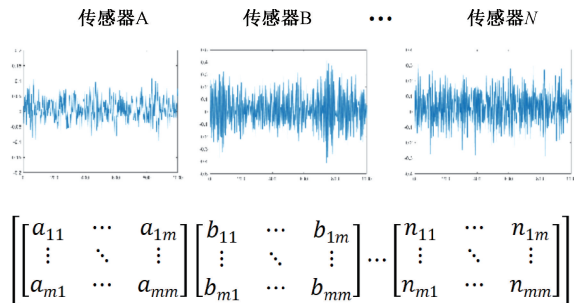


图 3 一个数据单元
Fig. 3 One data unit

无需将振动数据转为二维图像, 直接输入振动数据重排列即可完成数据预处理。若以 $m = 32$ 为例, 重新排列组合凯瑟西楚大学轴承数据集并将之转化为图片, 效果如图 4 所示。

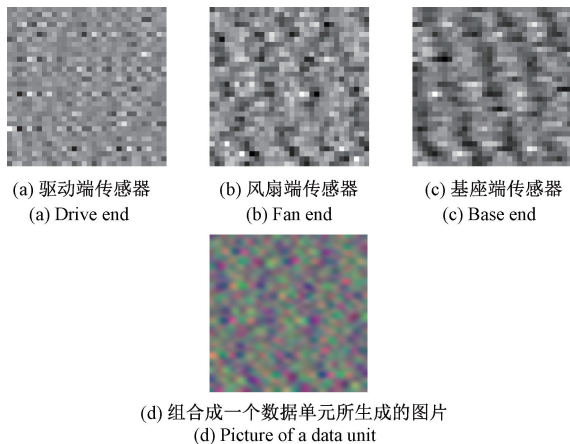


图 4 像素矩阵对应的图像
Fig. 4 Pictures of pixel matrix

2.2 MCCNN 网络结构

MCCNN 网络由 4 个基础模块组成的网络, 每个模块

都包括一个卷积层 (Convolutional layer), 一个归一化层 (Batch normalization), 一个最大池化层 (Max pooling), 如图 5 所示。首先第一个基础模块设置 32×32 大卷积核, 其余模块使用 3×3 小卷积核, 激活函数使用 ReLU, 即:

$$ReLU(x) = \max(x, 0) \quad (2)$$

模型参数如表 2 所示, 较大的卷积核用于抑制高频噪声, 利用卷积层提取振动信号的浅层特征, 再利用连续小卷积核扩展网络深度, 提高网络性能^[17]。

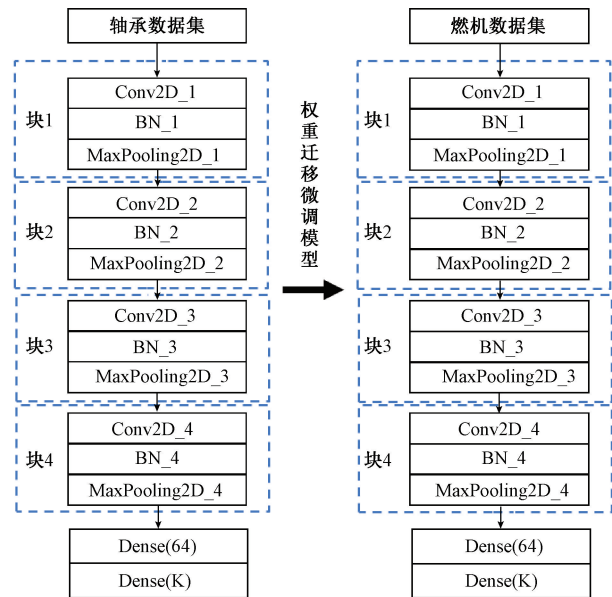


图 5 MCCNN 网络模型
Fig. 5 MCCNN model

表 2 MCCNN 参数设置

Table 2 MCCNN configuration

层名称	卷积核大小	输出大小	是否补零
C1	32×32	(32, 32, 16)	是
C2	3×3	(16, 16, 32)	是
C3	3×3	(8, 8, 64)	是
C4	3×3	(2, 2, 128)	否
Dense	/	64	/
Dense	/	10	/

全连接层首先使用 64 个神经元过渡, 最后一层分类按照故障数量自定义个数, 并使用 softmax 函数激活, 即:

$$softmax(x)_i = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)} \quad (3)$$

再将权重迁移至结构相同的卷积网络 (只调整最后分类层参数), 将块 1 和块 2 模块权重参数冻结, 块 3 与块 4 权重参数参与燃气轮机转子数据的训练、微调权重。

2.3 燃气轮机转子故障诊断步骤

燃气轮机转子故障诊断步骤如图 6 所示。

步骤 1) 构建 MCCNN 模型。

步骤 2) 使用凯瑟西储大学公开轴承数据集, 将不同位置的 3 个传感器数据并行排列, 同时将每个传感器数据按顺序排列成 32×32 二维矩阵。此时 $3 \times 32 \times 32$ 个数据点将打包作为一个数据单元。如图 3 所示。

步骤 3) 训练模型, 交叉验证模型准确率, 得到初始权重。

步骤 4) 通过安装在燃气轮机试验设备上的传感器收集振动信号。

步骤 5) 依照步骤 2 数据预处理方法, 将一维振动数据预处理为 p 个二维数据单元, 为每个数据单元标记标签。

步骤 6) 用燃气轮机转子数据训练模型, 验证模型准确率。

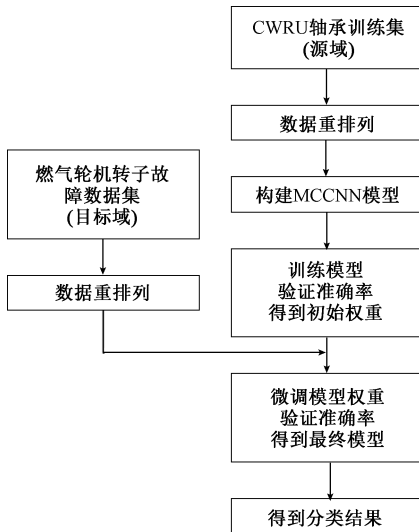


图 6 MCCNN 诊断步骤

Fig. 6 MCCNN diagnosis procedures




图 7 CWRU 滚动轴承振动信号采集实验台

Fig. 7 CWRU rolling bearing vibration signal acquisition experiment platform

米制马力电机负载。每组数据都有 3 个传感器, 分别为驱动端、风扇端和基座端, 3 个传感器数据每个数据取 102 400 个点, 按序以 1 024 个数据点为一组, 以 32×32 的布局排列成矩阵, 并行排列, 即共 100 个 $3 \times 32 \times 32$ 个数据单元, 每个故障均有 4 种不同的电机负载, 最终每种故障尺寸有 400 组数据, 每种故障测试样本有 80 组数据。故障标签如表 3 所示。

表 3 轴承故障及其标签

Table 3 Bearing faults and corresponding labels

故障名称	结构参数	训练样本	标签
IR	0.007"	400×3×1 024	0
	0.014"	400×3×1 024	1
	0.021"	400×3×1 024	2
OR	0.007"	400×3×1 024	3
	0.014"	400×3×1 024	4
	0.021"	400×3×1 024	5
B	0.007"	400×3×1 024	6
	0.014"	400×3×1 024	7
	0.021"	400×3×1 024	8
N	\	400×3×1 024	9

MCCNN 模型训练结果如图 8 所示, 训练准确率稳步上升, 约 10 轮训练预测精度达到 100%, 验证集预测精度开始较低, 后逐渐上升, 约 30 轮训练达到 100%, 测试集结果同样也为 100%, 混淆矩阵如图 9 所示, 表明 MCCNN 能够有效识别故障特征, 鉴别分类故障。




图 8 CWRU 数据集训练精度

Fig. 8 CWRU dataset training accuracy

3 实验验证

3.1 西储大学轴承数据集

实验首先使用凯瑟西储大学 (Case Western University, CWRU) 公开轴承数据集训练初始参数, 该数据集广泛的被研究人员用于开展轴承故障诊断研究。

平台由一个 1.5 kW (2 马力) 的电动机、一个扭矩传感器/译码器、一个功率测试计、电子控制器组成, 如图 7 所示。

其轴承健康状态包括了正常状态 (normal, N)、内圈故障 (inner race fault, IF)、外圈故障 (outer race fault, OF)、滚动体故障 (ball fault, BF) 4 种, 轴承故障尺寸包括了 0.007 in、0.014 in、0.021 in、0.028 in; 振动数据包含 4 种不同运行状态下的振动数据, 分别为 0、1、2 和 3

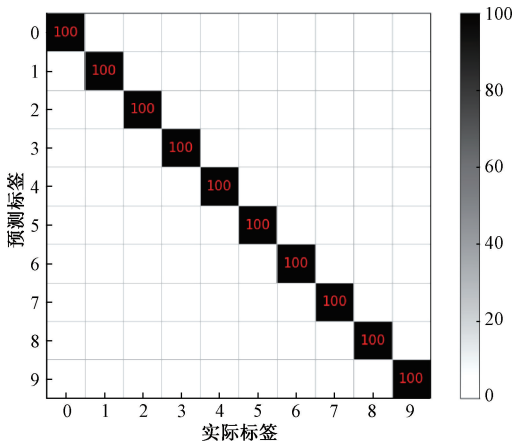


图9 CWRU滚动轴承振动信号采集实验台
Fig. 9 CWRU rolling bearing vibration signal acquisition experiment platform

3.2 西安交通大学轴承数据集

西安交通大学轴承实验台是由交流电动机、电动机转速控制器、转轴、支撑轴承、液压加载系统和测试轴承等组成,测试了轴承在3种不同工况下,每个工况5个轴承的加速寿命试验,获取测试轴承的全寿命周期监测数据,如图10所示。




图10 西安交通大学轴承实验台
Fig. 10 XJTU bearing platform

数据集共含有15个全生命周期且已知失效部位的轴承数据,试验选取外圈、内圈、保持架故障轴承数据以及全故障包括外圈、内圈、滚动体、保持架的轴承数据,如表4所示。

表4 西安交通大学轴承数据故障及标签

Table 4 XJTU bearing dataset faults and labels

工况	轴承名称	故障类型	标签
1	Bearing1_1	外圈	0
	Bearing1_4	保持架	1
2	Bearing2_1	内圈	2
3	Bearing3_2	内圈、滚动体、保持架、外圈	3

每个轴承数据集由两个传感器采集的数据组成,其中第1列为水平方向的振动信号,第2列为垂直方向的振动信号。按照2.1节数据预处理方式,将每列数据以32×32格式排列成数据矩阵,两列数据并排排列组成2×32×32的一个数据单元。每个轴承选取3200组数据单元,2500组用于训练,700组用于测试,如表5所示,经过5轮交叉验证训练结果如图11、12所示。

表5 西安交通大学轴承数据训练样本数

Table 5 Number of training and testing dataset of XJTU

工况	轴承名称	训练	测试
1	Bearing1_1	2500	700
	Bearing1_4	2500	700
2	Bearing2_1	2500	700
3	Bearing3_2	2500	700




图11 XJTU数据集训练精度
Fig. 11 XJTU dataset training accuracy




图12 XJTU预测结果混淆矩阵
Fig. 12 XJTU prediction confusion matrix

结果显示,测试集准确率达到99.95%,表明MCCNN模型对于西安交通大学数据集的有效性。

3.3 燃气轮机转子数据集

由于燃气轮机转子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,如图 13 所示,选取了在低压压气机机匣前端的径向位置上安装一个加速度传感器(传感器 1)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加速度传感器(传感器 2)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。

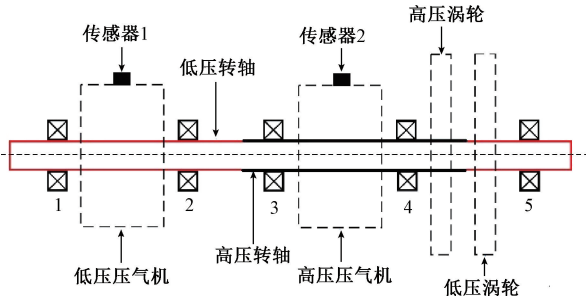


图 13 燃气轮机传感器布置示意图

Fig. 13 Position of sensors of gas turbine

首先进行数据预处理。将采集到的燃气轮机转子的试车台测试数据进行预处理。去掉奇异值和噪声,计算其有效值 RMS:

$$RMS = \sqrt{\frac{1}{N} \sum_{k=1}^N X^2(k)} \quad (4)$$

试车台前测点数据的 RMS 值,如图 14 所示,图中下方实线为前测点滤波信号的有效值,上方实线为高压转速曲线,中间一条虚线是振动超限值曲线,按照产品检测标准,振动 RMS 值超过 8 的状态为异常状态^[18-20]。




图 14 振动超限示意图

Fig. 14 Vibration transfinite diagram

建立燃机故障类型数据库并作为模型的环境,数据类型集合包括前侧点正常数据、后侧点正常数据、前侧点气流激振、转子弯曲、转子不平衡故障、后侧点气流激振共 6 类。

将由 3.1 节 CWRU 轴承数据集训练 MCCNN 模型,训练精度达到 98% 以上时,将模型保存,训练参数保留。构建新的 MCCNN 模型,将输入端的输入参数改为 (32, 32, 2),以匹配燃气轮机转子试验台只有前侧点和后侧点两个传感器;将末端 softmax 分类层的 10 个神经元替换

成 6 个以匹配新的故障类型数量;再将保存的模型参数读取录入;为了充分利用在轴承数据集上预训练 MCCNN 模型的特征提取功能,冻结前两层卷积层不进行参数更新,即前两层卷积层参数不随训练迭代而改变,只更新后两层卷积层参数。在训练过程中,首先设置第 3 层和第 4 层卷积层的学习速率为 0.000 1,批大小 (batch) 设置为 64,迭代次数为 40。数据预处理部分将传感器 1 和传感器 2 所得数据重新排列为 32×32×2 为一组的数据单元,再将数据送入权重迁移后的 MCCNN 模型中训练,样本数据的 80% 作为训练集,20% 作为测试集验证模型的诊断精度。数据选取各工况典型故障类型作为分类标签,如表 6 所示:

表 6 燃气轮机转子工况与故障标签

Table 6 Working conditions and labels of gas turbine rotor

数据类型	训练集	测试集	标签
前侧点正常	1 200	300	0
后侧点正常	1 200	300	1
前侧点气流激振	1 200	300	2
转子弯曲	1 200	300	3
转子不平衡	1 200	300	4
后侧点气流激振	1 200	300	5

经过权重迁移的模型和未经过权重迁移模型的验证集准确率结果对比如图 15 所示。




图 15 燃气轮机转子故障分类验证集准确率对比

Fig. 15 Comparison of testing accuracy between transfer learning and non-transfer

权重迁移模型的测试集混淆矩阵结果如图 16 所示。测试集的准确率达到 97.78%, 相比于未经权重迁移的准确率 91.49% 提升明显,证明所提的 MCCNN 模型经权重迁移后可以提取出故障特征并取得较好的分类结果。

4 结论

本文构建了一个多通道卷积神经网络,将同一时间不同的传感器采集到的数据作为独立的通道重新排列,

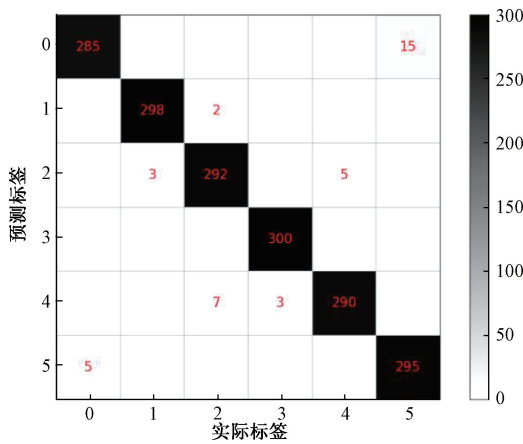


图16 燃气轮机转子故障分类测试集混淆矩阵

Fig. 16 Confusion matrix of faults classification

使得 MCCNN 在进行卷积操作时综合判断不同的传感器数据,经过 CWRU、XJTU 公开轴承数据集的验证并取得 100% 和 99.95% 的分类准确率,随后将从 CWRU 数据集训练得到的权重迁移至新模型,用于燃气轮机转子数据集的再训练再分类,最终取得了 97.78% 的准确率结果,相比于未经迁移的模型仅取得 91.49% 的准确率提升明显,证明使用 CWRU 轴承数据集训练并将权重迁移至新 MCCNN 模型再作用于燃气轮机转子数据集上是有效的。

参考文献

- [1] 汪祖民,张志豪,秦静,等. 基于卷积神经网络的机械故障诊断技术综述[J]. 计算机应用, 2022, 42(4): 1036-1043.
- WANG Z M, ZHANG ZH H, QIN J, et al. Review of mechanical fault diagnosis technology based on convolutional neural network [J]. Journal of Computer Applications, 2022, 42(4): 1036-1043.
- [2] 苏靖涵,张潇. 基于深度迁移自编码器的变工况下滚动轴承故障诊断方法[J]. 计算机测量与控制, 2021, 29(7): 85-90, 99.
- SU J H, ZHANG X. Fault diagnosis method of rolling bearing under variable working conditions based on deep migration self encoder [J]. Computer Measurement and Control, 2021, 29(7): 85-90, 99.
- [3] 李俊卿,刘静. 结合卷积神经网络和迁移学习的电机轴承故障诊断方法[J]. 华北电力大学学报(自然科学版), 2023, 50(1): 76-83, 91.
- LI J Q, LIU J. Motor bearing fault diagnosis method based on convolution neural network and transfer learning [J]. Journal of North China Electric Power University, 2023, 50(1): 76-83, 91.
- [4] 侯荣涛,周子贤,赵晓平,等. 基于堆叠稀疏自编码的滚动轴承故障诊断[J]. 轴承, 2018(3): 49-54, 60.

- HOU R T, ZHOU Z X, ZHAO X P, et al. Fault diagnosis of rolling bearing based on stack sparse self-encoding [J]. Bearings, 2018(3): 49-54, 60.
- [5] 余萍,曹洁. 优化堆叠降噪自动编码器滚动轴承故障诊断[J]. 太阳能学报, 2021, 42(11): 307-314.
- YU P, CAO J. Fault diagnosis of rolling bearing of optimized stacking noise reduction automatic encoder [J]. Acta Energaie Solaris Sinica, 2021, 42(11): 307-314.
- [6] 李益兵,王磊,江丽. 基于 PSO 改进深度置信网络的滚动轴承故障诊断[J]. 振动与冲击, 2020, 39(5): 89-96.
- LI Y B, WANG L, JIANG L. Fault diagnosis of rolling bearing based on PSO improved depth confidence network [J]. Journal of Vibration and Shock, 2020, 39(5): 89-96.
- [7] 林天骄,宋浏阳,李石,等. 基于空洞卷积神经网络的旋转机械故障诊断方法[J]. 测控技术, 2020, 39(12): 98-104.
- LIN T J, SONG L Y, LI SH, et al. Fault diagnosis method of rotating machinery based on atrous convolution-convolutional neural network [J]. Measurement & Control Technology, 2020, 39(12): 98-104.
- [8] PRATT L Y. Discriminability-based transfer between neural networks [C]. Advances in Neural Information Processing Systems, 1993: 204-211.
- [9] PAN S J, YANG Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [10] 雷亚国,杨彬,杜兆钧,等. 大数据下机械装备故障的深度迁移诊断方法[J]. 机械工程学报, 2019, 55(7): 1-8.
- LEI Y G, YANG B, DU ZH J, et al. Deep migration diagnosis method of mechanical equipment fault under big data [J]. Journal of Mechanical Engineering, 2019, 55(7): 1-8.
- [11] 杨健,李立新,廖晨茜,等. 面向滚动轴承故障诊断的改进对抗迁移学习算法研究[J]. 中国测试, 2021, 47(9): 15-19, 40.
- YANG J, LI L X, LIAO CH Q, et al. Research on improved anti migration learning algorithm for rolling bearing fault diagnosis [J]. China Measurement & Testing Technology, 2021, 47(9): 15-19, 40.
- [12] 刘飞,陈仁文,邢凯玲,等. 基于迁移学习与深度残差网络的滚动轴承快速故障诊断算法[J]. 振动与冲击, 2022, 41(3): 154-164.
- LIU F, CHEN R W, XING K L, et al. Fast fault diagnosis algorithm of rolling bearing based on transfer learning and deep residual network [J]. Journal of Vibration and Shock, 2022, 41(3): 154-164.

- [13] 曹梦婷,谷玉海,王红军,等.基于 GRU 与迁移学习的滚动轴承故障诊断[J].现代制造工程,2022,496(1):143-147.
CAO M T, GU Y H, WANG H J, et al. Fault diagnosis of rolling bearing based on GRU and transfer learning[J]. Modern Manufacturing Engineering, 2022, 496 (1): 143-147.
- [14] 唐竞鹏,王红军,钟建琳,等.基于 WDCNN-SVM 深度迁移的燃气轮机转子故障诊断方法[J].电子测量与仪器学报,2021,35(11):115-123.
TANG J P, WANG H J, ZHONG J L, et al. Fault diagnosis method of gas turbine rotor based on WDCNN-SVM deep migration [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (11): 115-123.
- [15] 杨强,童咏昕.迁移学习:回顾与进展[J].中国计算机学会通讯,2018,14(9):36-42.
YANG Q, TONG Y X. Transfer learning: Review and progress[J]. China Computer Federation, 2018,14(9):36-42.
- [16] 张雪松,庄严,闫飞,等.迁移学习研究进展[J].自动化学报,2019,45(7):1224-1243.
ZHANG X S, ZHUANG Y, YAN F, et al. Research progress of transfer learning[J]. Acta Automatica Sinica, 2019,45(7):1224-1243.
- [17] 赵宇凯,徐高威,刘敏.基于 VGG16 迁移学习的轴承故障诊断方法[J].航天器环境工程,2020,37(5):446-451.
ZHAO Y K, XU G W, LIU M. Method for fault diagnosis of bearing based on transfer learning with VGG16 model[J]. Spacecraft Environment Engineering, 2020, 37 (5): 446-451.
- [18] 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, ZHANG SH L. Fault

diagnosis model of depth confidence network for gas turbine airflow excited vibration[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (2): 115-121.

- [19] 谢春玲,戴景民.燃气轮机故障诊断技术研究综述与展望[J].汽轮机技术,2010,52(1):1-3.
XIE CH L, DAI J M. Summary and prospect of research on gas turbine fault diagnosis technology [J]. Steam Turbine Technology, 2010,52(1):1-3.
- [20] 贺雅,胡明辉.多转子燃气轮机不平衡部位辨识方法研究[J].机械设计与制造,2020(12):187-190.
HE Y, HU M H. Research on identification method of unbalanced parts of multi-rotor gas turbine [J]. Machinery Design and Manufacturing, 2020 (12): 187-190.

作者简介



苏静雷,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: 727922586@qq.com

Su Jinglei now is a B. Sc. candidate of 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.