

基于深度学习的航空发动机齿轮故障诊断*

万安平¹, 杨洁², 王景霖³, 陈挺¹, 缪徐¹, 黄佳湧¹, 杜翔¹

(1. 浙大城市学院机电系 杭州, 310015) (2. 浙江大学机械工程学院 杭州, 310027)

(3. 故障诊断与健康管理技术航空科技重点实验室 上海, 201601)

摘要 传统的机械故障诊断方法需要将采集的故障波信号进行信号处理,再结合神经网络进行特征提取与分类,不仅流程复杂、耗费时间,而且识别准确率不高。针对此问题,采用一维卷积神经网络(one dimensional convolutional neural network,简称 1D-CNN)对试验获取的某航空发动机的齿轮故障振动数据进行特征提取与分类,建立齿轮故障一维卷积神经网络模型,对航空发动机轴承进行故障诊断。试验与分析结果表明:采用该神经网络模型对齿轮进行分类,其准确率可达 80%,相较于采用传统的前馈神经网络 63.9% 的识别准确率,提高了 15.07%;与采用支持向量机(support vector machine,简称 SVM)对故障进行分类识别相比,该方法准确率提高了 15.89%。本方法能够直接将波形振动信号作为输入,通过卷积、池化等一系列操作,输出最后的分类结果,简化了传统方法先进行信号处理再通过机器学习诊断的步骤,为航空发动机故障诊断提供一种可行方法。

关键词 航空发动机;故障诊断;多传感器信息融合;深度学习;卷积神经网络

中图分类号 V240.2;V232

引言

自 20 世纪末至今,伴随信息技术的不断发展,人工神经网络由于其具有强大的并行处理能力、非线性函数逼近能力、自组织、自学习和自适应等特点^[1],在航空航天领域的应用愈发广泛,已成为现阶段航空飞行器故障诊断的关键手段之一。航空发动机因其机械结构复杂、工作环境恶劣,在使用较长时间后其内部零件容易产生机械损伤,使得工作性能大幅度降低,其机械故障一般可分为气路故障、附件故障和旋转机械故障 3 类^[2]。例如,构成其旋转机构的轴系零件,在表面磨损等失效问题下,容易导致发动机组件产生巨大的振动和噪声,降低运行效率,严重时还会引起整个机组的破坏,造成巨大的经济损失^[3-4]。

航空发动机的故障诊断识别主要是对旋转机械如齿轮和轴承的故障类别进行特征挖掘分类和预测。振动信号分析法^[5]是航空发动机齿轮和轴承故障诊断中应用最为广泛的研究方法,通过采集不同损伤情况的齿轮和轴承工作过程中的振动加速度信号,应用机器学习手段对信号进行分类与预测,挖掘故障数据的潜在特征,对故障诊断效率和准确率有着极大的提升。Liu 等^[6]提出了一种基于局部均值

分解理论的解调分析方法,先利用局部均值分解将行星齿轮箱振动信号分解为一系列乘积函数,再对乘积函数做傅里叶频谱分析,成功提取了风机行星齿轮箱齿轮局部裂纹故障特征频率。祝文颖等^[7]将一种改进的经验小波变换应用于行星齿轮箱振动信号分析,通过滤波将信号分解为 1 组调幅-调频的单分量成分,有效地提取出行星齿轮箱局部故障特征频率。上述方法要经过繁杂的信号处理过程,往往需要相关人员掌握大量的信号处理知识和丰富的专家诊断经验,对于内外多激励干扰情况的航空发动机振动信号很难提取到早期的故障特征。随着机器学习技术的发展和完善,研究人员将机器学习模型应用于故障诊断,提高了诊断准确性。

卷积神经网络^[8]可以对海量数据进行处理,能够有效提取数据特征并进行分类,而航空发动机运作过程中产生的数据量庞大,很适合采用卷积神经网络进行分析。韩涛等^[9]利用多小波变换与卷积神经网络对轴承复合故障进行了分析。张西宁等^[10]利用卷积自编码器对卷积核与反卷积核进行优化,建立了一个深度自编码器用于滚动轴承的故障诊断。陈仁祥等^[11]将小波变换与卷积神经网络相结合,利用小波变换提取出轴承振动信号中的时频矩阵并输

* 国家自然科学基金资助项目(51705455);航空科学基金资助项目(20183333001);中国博士后基金特别资助项目(2018T110587)

收稿日期:2021-04-02;修回日期:2021-05-25

入卷积神经网络来提取高维特征,根据这些特征实现轴承不同故障状态的分类。上述文献所列方法均通过将信号处理技术与机器学习的神经网络进行结合,将一维时域信号数据转化为时频数据,再通过卷积神经网络基于时频图像进行图像分析,其操作过程十分繁琐,对信号分析能力的要求很高。因此,舍弃原始信号处理过程,直接对采集的振动信号进行神经网络模型的搭建,并达到较高的故障分类准确率,具有重要意义。

一维卷积神经网络能够直接对时域信号进行特征挖掘,其采集的一维时域振动信号作为样本空间输入网络,完成故障类型识别和诊断。Chao等^[12]采用一维卷积神经网络进行高速轴向柱塞泵空化强度识别,其输入信号为多通道振动信号,将每个通道算作1个维度,极大地提高了识别准确率。Wang等^[13]将滚动轴承的振动与声学信号相结合,共同作为一维卷积神经网络的输入。Bao等^[14]将一维卷积神经网络用于应力时变数据的识别,有效识别了导管式海洋平台的故障损伤。因此,笔者将一维卷积神经网络用于航空发动机齿轮与轴承的故障类型识别。

1 卷积神经网络

目前,卷积神经网络(convolutional neural network,简称CNN)在各个领域都有着非常成功的应用,尤其在图像处理^[15]和语音识别^[16]方面有着独特的优势。典型的一维卷积神经网络^[17]一般包括输入层、卷积层、池化层、全连接层和输出层,如图1所示。

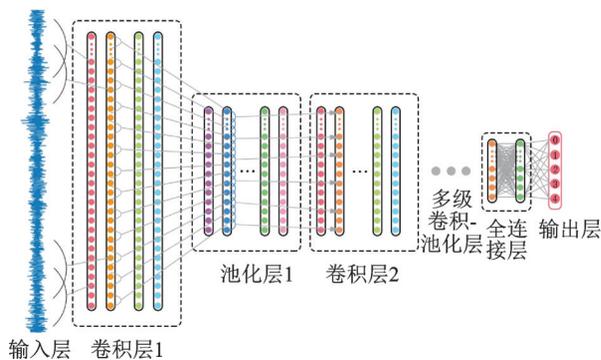


图1 一维卷积神经网络结构图
Fig.1 Structure diagram of 1D-CNN

CNN的输入层可以对多维数据进行标准化处理,即在学习数据导入CNN之前,需要对输入数据进行标准化处理,这种操作有助于提高算法的运行效率和学习性能。

在卷积层,卷积核对上一层的输出进行卷积,并使用非线性激活函数构造输出特征。每一层的输出

是多个输入特征的卷积结果,其数学模型^[18]为

$$y_i^{l+1}(j) = \omega_i^l \cdot x^l(j) + b_i^l \tag{1}$$

其中: ω_i^l 为第*i*个滤波核在*l*层的权重; b_i^l 为第*i*个滤波核在*l*层的偏置; $x^l(j)$ 为第*l*层的第*j*个神经元的输入; $y_i^{l+1}(j)$ 为第*j*个神经元在*l+1*层的输入,即*l*层的输出;符号“ \cdot ”表示内核与该局部区域的点积。

卷积运算后,激活函数对每次卷积的逻辑值输出进行非线性变换。激活函数的作用是将原本线性不可分的多维特征变换到另一个空间,增强这些特征的线性可分性。笔者采用Relu函数作为激活函数,当输入值大于0时,该函数的导数值总是1,因此克服了梯度消失的问题。

池化层以减少神经网络参数为主要目的,通过数据采样将大的矩阵缩小为小的矩阵,从而减少了计算量,防止过拟合。在实际应用中,常用最大值池化和平均值池化,取感知域的最大值或平均值作为输出。全连接层将最后一个池化层的输出展开为一维向量,同时作为全连接层的输入,然后在输入和输出之间建立全连接网络。全连接层可以在卷积层或池化层整合已区分的局部信息。输出层通常使用softmax分类器来创建分类标签,softmax分类器是由逻辑回归衍生的一种多类分类形式。

目前,用于图像处理的卷积神经网络一般为二维,即将一个二维图像每个像素的灰度值作为数据输入,而一维卷积神经网络的输入是一个多通道一维向量。1D-CNN卷积原理如图2所示,其卷积核采用一维结构,每个卷积层和池化层的输出都是一维向量。

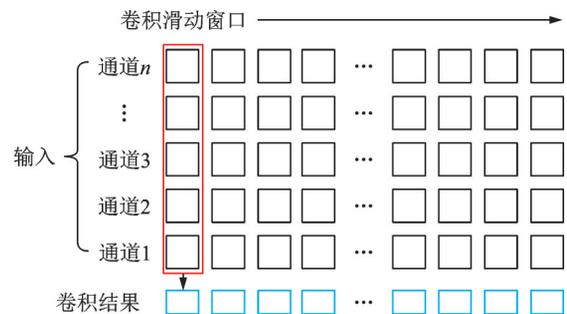


图2 1D-CNN卷积原理
Fig.2 Convolution principle of 1D-CNN

2 故障诊断模型

2.1 模型结构

基于卷积神经网络的基本原理,笔者建立如图3所示的一维卷积神经网络模型流程,用于航空发动机齿轮故障信号的特征提取与分类。具体步骤如下:

1) 数据采集,本研究采用某直升机传动系统试验台和主减试验台的平行齿轮相关数据,共约 30×10^4 条数据;

2) 数据预处理,对数据进行标签化、切片及归一化处理,将数据转换为用于监督学习的数据类型;

3) 将数据划分为训练集和测试集,搭建 1D-CNN 模型,并将训练集和测试集数据代入模型进行训练;

4) 将验证集数据代入模型进行预测;

5) 用模型训练中的准确率和均方根误差对模型进行评价,两者越小,则模型预测准确率越高。

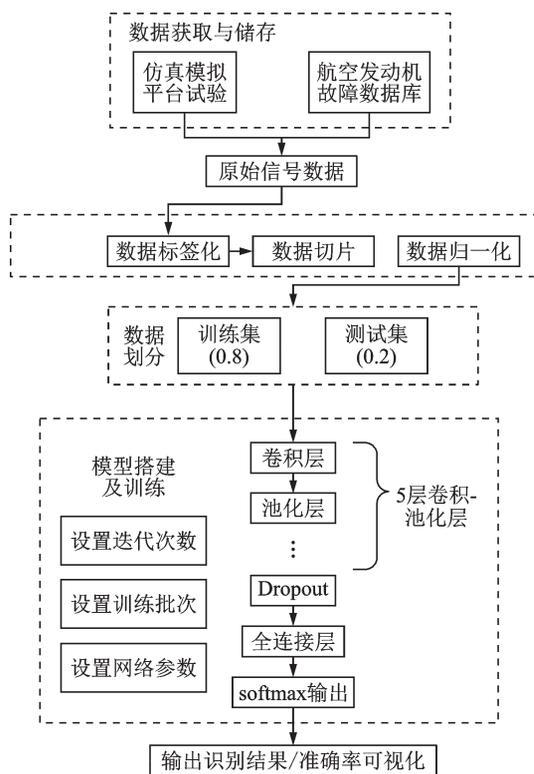


图3 一维卷积神经网络模型流程图

Fig.3 Flow chart of 1D-CNN model

归一化后的原始数据直接导入到 1D-CNN 中。1D-CNN 具有强大的特征提取能力,其中隐藏在原始数据中的非线性特征可以通过卷积层和池化层交替进行自动提取,在全连接层完成自适应特征学习。这样,1D-CNN 算法就消除了传统算法中人工提取特征的过程,实现了端到端信息处理。

笔者提出的 1D-CNN 的具体结构由 5 个卷积层、5 个池化层、1 个全连接层和 1 个 softmax 输出层组成。经过第 1 层卷积层后,信号被转换成 1 组特征映射,然后通过最大值池化对其进行下采样。在这些操作重复 4 次后,将最后一个池化层的特性连接到全连接层,再通过 Relu 函数激活全连接层,传递到 softmax 层,最终得到每个分类的概率值,其中概

率最大的类别被视为识别结果。

该模型有 5 个卷积层和池化层。卷积核的大小如下:第 1 层为 64×1 ;第 2 层和第 3 层为 32×1 ;第 4 层和第 5 层为 16×1 。池化核的大小如下:第 1 层为 16×1 ;第 2~5 层均为 2×1 。全连接层神经元节点数为 100,softmax 层有 5 个输出,分别对应试验中齿轮故障的 5 种状态,其振动信号提取的参数如表 1 所示。

表 1 振动信号特征提取的参数

Tab.1 Parameters of vibration signal feature extraction

层序号	层类别	核的大小和步长	核的信道数
1	卷积层 1	$64 \times 1/1 \times 1$	16
2	池化层 1	$16 \times 1/16 \times 1$	16
3	卷积层 2	$32 \times 1/1 \times 1$	64
4	池化层 2	$2 \times 1/2 \times 1$	64
5	卷积层 3	$32 \times 1/1 \times 1$	128
6	池化层 3	$2 \times 1/2 \times 1$	128
7	卷积层 4	$16 \times 1/1 \times 1$	128
8	池化层 4	$2 \times 1/2 \times 1$	128
9	卷积层 5	$16 \times 1/1 \times 1$	128
10	池化层 5	$2 \times 1/2 \times 1$	128
11	全连接层	100	1
12	Softmax 层	5	1

2.2 评价指标

常用于机器学习的预测评价指标包括均方根误差 (root mean square error, 简称 RMSE)、平均绝对误差 (mean absolute error, 简称 MAE) 及平均绝对百分比误差 (mean absolute percentage error, 简称 MAPE) 等。笔者采用 RMSE 作为损失函数,来评价模型迭代时的收敛情况,采用模型训练准确率输出作为进一步评估模型识别效果的标准,并与传统的机器学习方法进行对比。RMSE 的计算式为

$$e_{\text{RMSE}} = \frac{1}{N} \sqrt{\sum_{i=1}^N (\hat{L}_i - L_i)^2} \quad (2)$$

其中: N 为训练样本总数; \hat{L}_i 为识别结果; L_i 为真实标签。

3 试验研究与分析

3.1 试验数据集

为了评估所提方法的性能,使用了真实的齿轮数据。数据来源于某直升机传动系统试验台和主减试验台的平行齿轮相关数据,发动机齿轮数据采集平台如图 4 所示。

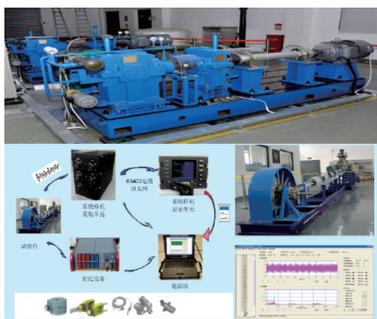


图 4 发动机齿轮数据采集平台
Fig.4 Engine gear data acquisition platform

3.2 数据预处理

3.2.1 数据标签化

本研究所采用的数据为某直升机传动系统试验台和主减试验台的平行齿轮与深沟球轴承的振动加速度信号数据。每个故障类别测定时,在不同位置和方向安装 9 个传感器,即采用多信号传感器融合的方法进行故障类型识别,这有利于提高神经网络模型的识别准确率。由于轴承故障诊断方式与齿轮相同,都是采用一维卷积神经网络对振动信号进行分类,因此仅讨论齿轮故障诊断。

本研究检测的齿轮故障类别主要为齿根裂纹、齿面磨损、断齿、缺齿和正常齿轮。采用一维卷积神经网络对齿轮的故障类别进行分类和识别,需要对原始振动信号数据进行标记,齿轮数据集的标签如表 2 所示。

表 2 齿轮数据集标签
Tab.2 Labels of gear data set

样本数量 (训练集/测试集)	故障类别	分类标签
4 800/1 200	正常齿轮	0
4 800/1 200	缺齿	1
4 800/1 200	断齿	2
4 800/1 200	齿面磨损	3
4 800/1 200	齿根裂纹	4

3.2.2 数据切片

一维卷积神经网络的优点在于提取输入数据的空间关联特性。原始的振动信号数据为多通道一维向量,空间关系不明显,需将其转换为适用于卷积神经网络的数据结构。本研究采取将各传感器视作不同的通道,选择数据切片长度为 50,即每 50 个离散数据合并为 1 个数据点,将振动信号截取为多小段振动数据,如图 5 所示。

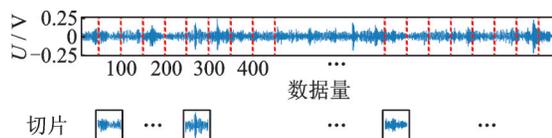


图 5 数据切片
Fig.5 Data slicing

3.2.3 数据归一化

神经网络普遍采用基于梯度下降的反向传播算法进行模型的训练,将数据归一化到一个标准的区间更有利于模型的训练和求解^[19]。采用最小-最大值归一化方法将向量中各元素缩放至[0,1]区间,其计算式为

$$X_{norm} = (X - X_{min}) / (X_{max} - X_{min}) \quad (3)$$

其中: X 为原始值; X_{max} , X_{min} 分别为最大、最小值; X_{norm} 为归一化后的值。

3.3 模型训练

航空发动机齿轮数据经数据预处理后即可输入搭建完成的一维卷积神经网络中进行训练。训练过程中将数据集划分为训练集和测试集,训练集用于估计模型中的超参数,使模型能够反映现实数据的特征,测试集用来评估模型的识别性能。通常在数据量较大时,采取 4:1 的比例划分训练集与测试集。本研究数据量为 30 000 条(如表 2 所示的 5 组数据,每组 6 000 条),适用于此比例。

模型学习率影响深度学习模型的训练效率,当学习率过小时,会导致网络的损失值下降缓慢;当学习率过大时,参数更新的幅度异常显著,导致网络迅速收敛到局部最优点,而非全局最优。深度学习常采用的学习率为 0.1,0.01,0.001 及 0.000 1,学习率越低,损失值降低的速度就越慢。使用较低的学习率可以确保模型不错过任何一个局部极小值,但也需要花费更长的时间来进行收敛。当数据量庞大时,学习率一般选择较大,避免花费过多的时间。本研究数据为 30 000 个,选择学习率为 0.01。结果表明,经过 26 轮迭代模型即可收敛。

模型训练次数对神经网络训练效果的影响很大,当次数选择过小时,容易造成欠拟合,即模型未能准确学习所有特征;当次数选择过大时,会造成过拟合,即模型将训练集中不涉及标签分类的特殊特征纳入到特征学习中去,导致测试集的识别准确率下降。笔者采用枚举法,在学习率为 0.01 的基础上选择次数为 50,100,250 及 500 进行训练,试验结果表明,当训练轮次大于 26 轮后,模型即可收敛;而当回合数大于 100 时,模型出现过拟合现象,测试集准确率和损失值出现反向变化。避免过拟合的方法常

采用添加正则项、扩增数据集、提前终止训练以及添加 Dropout 层。本研究数据集已经足够大,因此采用在模型中添加正则项(降低模型数学式中 w 的复杂度),全连接层前添加 1 层 Dropout 层(过滤 20% 的模型参数),训练 100 次即停止,避免训练轮数过多而降低故障诊断效果。

3.4 结果分析与对比验证

针对航空发动机齿轮故障数据建立的一维卷积神经网络进行准确度和损失值分析,并与传统的前馈神经网络进行对比,显示出一维卷积神经网络在齿轮故障分类方面的优势。

准确度表明一个神经网络实现分类的效果,其采用识别样本标签与其真实类别标签相同的样本数量占总样本的百分比来表示。损失函数是用来测量预测类别与真实类别之间的误差,笔者采用 MSE 作为误差的衡量标准。神经网络模型的准确度越高,误差越小,表明该模型的应用效果越好。

通过 100 次模型迭代,可以得到如图 6 所示的一维卷积神经网络准确度和损失值变化趋势图。由图可知:前 5 次迭代,模型准确率迅速上升,随着迭代次数的不断增加,模型对样本类别的识别准确率在不断上升后逐渐趋于缓慢平稳,训练样本和测试样本的准确率最终都达到 80% 左右;损失函数值随迭代次数的增加而不断降低,测试样本最终达到 0.427,而训练样本的损失值依旧不断降低,在增加模型迭代次数后,其值不断接近于 0。前 50 次模型迭代,测试集的识别效果优于训练集的识别效果;但 50 次迭代之后,测试集识别效果逐渐趋于平稳,甚至有变差的迹象,可能是模型仍然存在一定的过拟合。根据数据量,进一步调整模型训练参数,增大 Dropout 的比例,避免过拟合现象的发生。

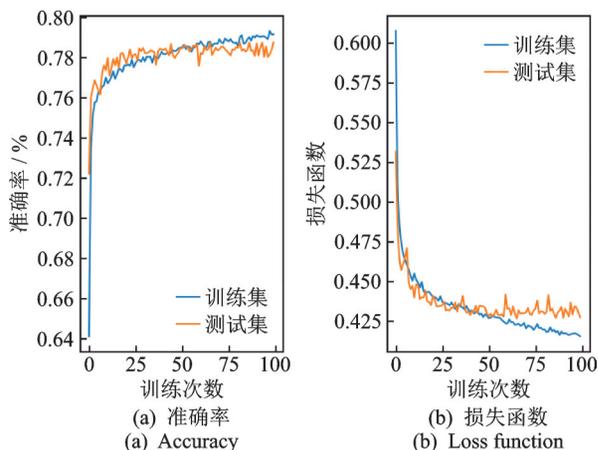


图 6 1-D CNN 模型准确率和损失函数变化趋势图

Fig.6 Trend of accuracy and loss function of 1-D CNN mode

表 3 所示为不同机器学习方法对本研究数据的识别效果,图 7 为前馈神经网络模型准确率和损失函数变化趋势图。可以看到,采用一维卷积神经网络对航空发动机齿轮故障进行分类识别,其测试集准确率可达 78.97%,即有近 80% 的数据分类结果与真实标签相同,有 20% 左右的分类结果错误。相较于采用传统的前馈神经网络 63.9% 的识别准确率,提高了 15.07%。与采用 SVM 对故障进行分类识别相比,该方法准确率提高了 15.89%,并且其均方根误差值也相对更小。因此,对类似于航空发动机齿轮故障振动信号的波形数据,笔者采用的一维卷积神经网络表现出较优的识别效果。

表 3 各机器学习方法识别效果

Tab.3 Recognition effect of each machine learning method

模型名称	RMSE	准确率/%
前馈神经网络	0.751	63.90
支持向量机	0.690	63.08
卷积神经网络	0.427	78.97

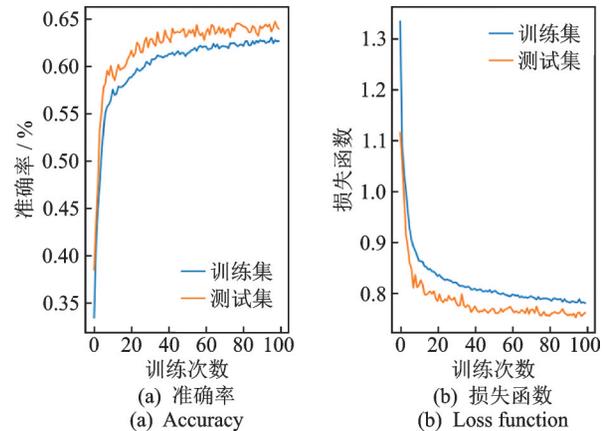


图 7 前馈神经网络模型准确率和损失函数变化趋势图

Fig.7 Trend of the accuracy and loss function of BP mode

笔者建立的一维卷积神经网络识别准确度还有待提高,原因如下:①神经网络超参数的定义依旧采用经验法或模型迁移,没有准确的原则来保证参数的选取达到最优化;②原始数据采集无法确保每一条数据都与分类结果有着极大相关性,关联度不高的数据对最终的识别准确率有极大的干扰。

4 结束语

在分析了机械旋转部件故障诊断的基础上,将一维卷积神经网络应用于航空发动机齿轮故障类别诊断,其识别准确度达到了 78.97%,相较于传统的前馈神经网络和支持向量机有明显的提升。该一维卷积神经网络能够直接将波形振动信号作为输入,通过卷积、池化等一系列操作,输出最后的分类结果,简化了传统的先进行信号处理再通过机器学习

诊断的繁琐步骤,为航空发动机故障诊断提供了一种可行方法。

参 考 文 献

- [1] 蒋东翔,王风雨,周明,等.模糊自组织神经网络在航空发动机故障诊断中的应用[J].航空动力学报,2001,16(1):80-82.
JIANG Dongxiang, WANG Fengyu, ZHOU Ming, et al. Application of fuzzy self-organizing neural network in aero-engine fault diagnosis[J]. Journal of Aerospace Power, 2001,16(1):80-82. (in Chinese)
- [2] 田晶,李有儒,艾延廷.一种基于Deep-GBM的航空发动机中介轴承故障诊断方法[J].航空动力学报,2019,34(4):756-763.
TIAN Jing, LI Youru, AI Yanting. A fault diagnosis method for aero engine intermediate bearing based on deep GBM [J]. Journal of Aerospace Power, 2019, 34(4):756-763. (in Chinese)
- [3] JIAO J Y, ZHAO M, LIN J, et al. Hierarchical discriminating sparse coding for weak fault feature extraction of rolling bearings[J]. Reliability Engineering and System Safety,2019, 184:41-54.
- [4] ZHAO M, JIA X D. A novel strategy for signal denoising using reweighted SVD and its applications to weak fault feature enhancement of rotating machinery [J]. Mechanical Systems and Signal Processing, 2017, 94:129-147.
- [5] 秦宁.基于振动信号分析的滚动轴承故障诊断研究[D].大连:大连理工大学,2020.
- [6] LIU W Y, ZHANG W H, HAN J G, et al. A new wind turbine fault diagnosis method based on the local mean decomposition[J]. Renewable Energy, 2012, 48:411-415.
- [7] 祝文颖,冯志鹏.基于改进经验小波变换的行星齿轮箱故障诊断[J].仪器仪表学报,2016,37(10):2193-2201.
ZHU Wenying, FENG Zhipeng. Fault diagnosis of planetary gearbox based on improved empirical wavelet transform[J]. Chinese Journal of Scientific Instrument, 2016,37(10):2193-2201. (in Chinese)
- [8] LECUN Y, BOTTOU L. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [9] 韩涛,袁建虎,唐建,等.基于MWT和CNN的滚动轴承智能复合故障诊断方法[J].机械传动,2016,40(12):139-143.
HAN Tao, YUAN Jianhu, TANG Jian, et al. Intelligent composite fault diagnosis method of rolling bearing based on MWT and CNN [J]. Journal of Mechanical Transmission, 2016,40(12):139-143. (in Chinese)
- [10] 张西宁,向宙,唐春华.一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用[J].西安交通大学学报,2018,52(7):1-8,59.
ZHANG Xining, XIANG Zhou, TANG Chunhua. A deep convolutional self coding network and its application in rolling bearing fault diagnosis[J]. Journal of Xi'an Jiaotong University, 2018,52(7):1-8,59.(in Chinese)
- [11] 陈仁祥,黄鑫,杨黎霞,等.基于卷积神经网络和离散小波变换的滚动轴承故障诊断[J].振动工程学报,2018,31(5):883-891.
CHEN Renxiang, HUANG Xin, YANG Lixia, et al. Rolling bearing fault diagnosis based on convolution neural network and discrete wavelet transform [J]. Journal of Vibration Engineering, 2018, 31(5):883-891. (in Chinese)
- [12] CHAO Q, TAO J, WEI X, et al. Cavitation intensity recognition for high-speed axial piston pumps using 1-D convolutional neural networks with multi-channel inputs of vibration signals[J]. AEJ-Alexandria Engineering Journal, 2020, 59(6):4463-4473.
- [13] WANG X, MAO D, LI X. Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network[J]. Measurement, 2021, 173(6):108518.
- [14] BAO X X, FAN T X, SHI C, et al. One-dimensional convolutional neural network for damage detection of jacket-type offshore platforms [J]. Ocean Engineering, 2021,219:108293.
- [15] TAN Y X, YAO H G. Deep capsule network handwritten digit recognition [J]. International Journal of Advanced Network, Monitoring and Controls, 2021, 5(4):1-8.
- [16] SUN C, ZHANG M, WU R J, et al. A convolutional recurrent neural network with attention framework for speech separation in monaural recordings [J]. Scientific Reports,2021,11(1):1434.
- [17] ZHANG K S, ROBINSON N, LEE S W, et al. Adaptive transfer learning for EEG motor imagery classification with deep convolutional neural network [J]. Neural Networks, 2021,136:1-10.
- [18] ZHANG W, PENG G L, LI C H, 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.
- [19] GIBSON A, PATERSON J. Deep learning: a practitioner's approach [M]. Boston: O'Reilly Media, 2017:324-325.



第一作者简介:万安平,男,1983年11月生,博士,副教授。主要研究方向为复杂装备健康管理及维修决策。
E-mail:wanap@zucc.edu.cn

通信作者简介:陈挺,男,1989年10月生,博士。主要研究方向为人工智能低温制冷设备故障诊断。
E-mail:chenting@zucc.edu.cn