

基于卷积残差编码网络的水泥辊压机故障诊断

徐 铭¹, 徐 航¹, 陈 洋², 束正华¹, 胡江颖¹, 汪 诚¹

1. 安徽智质工程技术有限公司, 安徽 芜湖 241000

2. 上海智质科技有限公司, 上海 201801

摘要:目的 为提高水泥生产效率, 避免因主要机械设备故障导致的生产停止, 需要对水泥生产线中的主机设备辊压机进行故障诊断。方法 提出卷积残差 Transformer 编码网络, 此模型第一部分是包含 4 个卷积层的卷积块, 每个卷积层中包含卷积、池化、批规范化和激活函数, 用以提取输入数据的局部特征; 对提取到的特征增加残差后输入 Transformer 编码模块, Transformer 编码模块包含多头注意力机制和前馈神经网络, 用以对输入的特征进行再次提取, 得到编码的输出后再次增加残差; 最后经过全连接层和 Softmax 层进行分类以实现故障的诊断。结果 在凯斯西储大学公开轴承数据集进行模型可用性的初步验证, 然后在辊压机上安装传感器收集正常运行和故障运行的振动数据作为实证数据集, 其中凯斯西储大学测试集预测准确率为 99.75%, 对辊压机数据测试集的识别准确率为 96.55%, 故障的查全率达到 98.32%。结论 使用卷积提取故障数据特征, 然后用注意力机制突出重要特征的方法能对辊压机实际生产中的运行状态进行有效的判断, 特别是对故障状态的识别率更高。

关键词: 辊压机; 故障诊断; 卷积网络; Transformer 编码

中图分类号: TQ172.63; TD183 **文献标识码:** A **doi:** 10.16055/j.issn.1672-058X.2026.0002.017

Fault Diagnosis of Cement Roller Press Based on Convolutional Residual Coding Network

XU Ming¹, XU Hang¹, CHEN Yang², SHU Zhenghua¹, HU Jiangying¹, WANG Cheng¹

1. Anhui Zhizhi Engineering Technology Co., Ltd., Wuhu 241000, Anhui, China

2. Shanghai Zhizhi Technology Co., Ltd., Shanghai 201801, China

Abstract: Objective To improve the efficiency of cement production and prevent production stoppages caused by major mechanical equipment failures, fault diagnosis for roller presses in cement production lines is essential. **Methods** A convolutional residual Transformer coding network was proposed. The first part of this model was a convolution block containing four convolutional layers. Each convolutional layer contained convolution, pooling, batch normalization, and activation functions to extract local features from the input data. The extracted features were then fed into a Transformer coding module after adding residuals. This Transformer coding module incorporated a multi-head attention mechanism and a feedforward neural network to further extract features from the input. After obtaining the encoded output, the residuals were added again. The difference was finally classified through the fully connected layer and softmax layer to achieve fault diagnosis. **Results** A preliminary verification of the model usability was carried out on the public bearing data set of Case Western Reserve University, and then sensors were installed on the roller press to collect vibration data of normal operation and fault operation as an empirical data set. The prediction accuracy on the Case Western Reserve University test set was 99.75%, while the identification accuracy on the roller press data test set was 96.55%, with a fault recall rate of

收稿日期: 2024-02-28 **修回日期:** 2024-05-20 **文章编号:** 1672-058X(2026)02-0133-06

基金项目: 国网辽宁省电力有限公司科技项目资助(2023YF-21).

作者简介: 徐铭(1987—), 男, 安徽芜湖人, 从事故障诊断与设备管理研究。

通信作者: 徐航(1997—), 男, 河南周口人, 硕士研究生, 从事故障诊断与数据挖掘研究. Email: 599989195@qq.com.

引用格式: 徐铭, 徐航, 陈洋, 等. 基于卷积残差编码网络的水泥辊压机故障诊断[J]. 重庆工商大学学报(自然科学版), 2026, 43(2): 133-138.

XU Ming, XU Hang, CHEN Yang, et al. Fault diagnosis of cement roller press based on convolutional residual coding network [J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(2): 133-138.

98.32%. **Conclusion** The method of using convolution to extract fault data features and employing an attention mechanism to highlight important features enables effective assessment of the operational status of the roller press in actual production, particularly achieving a higher recognition rate for fault states.

Keywords: roller press; fault diagnosis; convolutional network; Transformer coding

水泥作为一种重要的建筑材料,广泛用于房屋、桥梁、道路、隧道等各种基础设施的建设中。近年来,随着经济的发展,人们对基础设施有越来越高的需求,使得对水泥的需求也产生了巨大提升。水泥生产中涉及破碎、燃烧、研磨等多种工艺,会产生高温、粉尘等影响正常环境的因素,影响设备运行状态和水泥的生产效率,因此需要对设备进行监控,预防因设备故障导致的停工停产。辊压机是 80 年代发展起来的一种水泥粉磨系统主机设备,其利用高压料层挤压粉碎原理,将给入的物料变为易磨的料饼,可大幅降低粉碎的能耗^[1],是水泥生产中必不可少的设备,对其进行故障诊断存在重要意义。

故障诊断发展已久,早期的故障诊断一般通过专家对设备的观察来实现。随着故障诊断技术和各类传感器的发展,基于数据驱动的故障诊断应用范围越来越广。此类方法在进行诊断时首先对监测数据采样分段,然后提取数据的特征,最后对设备故障进行分类诊断。如俞建明等^[2]在进行设备故障监测时使用小波包对离线监测数据进行分解,并计算出包络谱能量,在信号重构后进行故障特征提取,此方法能检测出设备的早期故障并有效降低误报率;普会杰等^[3]将设备振动信号频域特征转换为与故障信息相关的固有流形特征,减小源域和目标域的分布差异,通过实验证明此方法能提高滚动轴承的平均诊断准确率。此类方法提取特征依赖专家的先验知识,特征提取能力有限,易受机械系统变化的影响,对未知特征的提取存在一定局限^[4]。

相比于此类方法,深度学习通过模型训练自适应地提取振动信号中所包含的各种特征,可替代传统故障诊断中的特征工程步骤,节省了大量人力物力,因而近些年来在故障诊断研究中应用越加广泛^[5]。周翔宇等^[6]针对设备工作环境差、噪声多导致故障信号难以识别和故障样本分布不一致导致模型泛化能力弱的情况,使用频率降采样和卷积神经网络来减少噪声对频域信号的影响,通过和常用的 SVM、DNN 等模型对比发现,此方法对轴承故障有更高的识别准确率;宋晓承等^[7]提出一种双通道网络算法,该方法结合卷积神经网络和循环神经网络,并使用多头自注意力机制代替卷积中的池化来增加模型的稳定性、泛化性和对更深层次特征的提取能力,该方法在凯斯西储大学的轴承

故障数据上可获得 99% 的分类精度;张珂等^[8]针对轴承工作环境复杂和样本不足的问题,结合卷积和注意力机制提出了多模态注意力卷积神经网络,并在多种转频故障数据上进行实验分析,实验结果表明该方法能有效提高变工况轴承故障诊断的精度;李秋婷等^[9]基于卷积注意力和残差网络提出轴承故障诊断模型和基于多头注意力的滚动轴承故障诊断模型,经验证两个模型在凯斯西储大学轴承数据集上的最高诊断准确率均达到 99% 以上;韩争杰等^[10]基于注意力机制改进残差神经网络来解决滚动轴承在不同工况中诊断准确率低、泛化性弱的问题,并在凯斯西储大学数据集上进行实验,结果表明该方法在同工况和不同工况情况下均能显著提高 ResNet 模型的准确率和泛化性;卢浩龙^[11]等将 Transformer 和图神经网络结合,通过扩大特征感受野,增加图结构信息提高特征信息量,来解决故障诊断中复杂工况下提取信号的弱特征问题,该方法在凯斯西储大学轴承数据集和滚动轴承实验平台上最高诊断准确率为 99.86%,平均准确率达到 98% 以上,能够进行多工况条件下轴承的故障分类,但图神经网络存在过平滑问题,即当层数增加时节点可能变得相似,导致模型不能区分不同的节点。

经过对相关文献的研究发现,早期故障诊断虽然也能取得较好的效果,但却过于依赖专家的先验知识,对人的要求过高。深度学习方法能自适应提取故障信号中包含的各种特征,在故障诊断中的应用逐渐增多,但也存在不同工况情况下准确率低、泛化性弱的问题。因而增强对数据特征的提取成为重点研究方向之一。

基于此,本文构建模型卷积残差 Transformer 编码(CRTE, Convolutional Residual Transformer Encoding)网络。该模型使用卷积对辊压机数据进行初步提取,然后使用基于多头自注意力机制的 Transformer 编码器关注重要特征,并添加残差连接来添加原始数据信息,通过对特征的双重处理增强模型泛化性,在实验数据集和生产数据集上进行实验,结果表明模型可行性和实用性较好。

1 理论基础

1.1 CNN 理论基础

卷积神经网络(Convolutional Neural Network, CNN)最初用于图像的分类领域。作为深度学习网络的一种,卷积神经网络可以自主学习数据的不同特征,避免

人工手动进行特征提取和重建,且存在局部连接和权重共享的特点,在故障诊断中应用较多^[12]。CNN 由卷积层、池化层和全连接层堆叠构成,其中卷积层和池化层用来提取数据特征,全连接层用来分类^[13]。

实际应用时,将输入数据与卷积核进行卷积操作来获取特征,不同大小的卷积核对数据的感受野不同,故通过多个卷积层的堆叠,网络能够学到不同数据范围的特征^[14];池化层通常紧跟在卷积层之后,用来减小特征的维度并保留特征的主要信息,常用的有最大池化和平均池化;全连接层用于将卷积和池化所获得输入数据的主要特征进行整合^[15],并用激活函数增加非线性拟合能力,最后使用损失函数判断网络输出结果和真实标签间的差异,通过反向传播算法调整网络的参数,不断减小目标损失来达到训练的目的。

卷积层中的卷积操作实际上是输入和卷积核进行互相关运算。运算过程中,核函数从输入数据左上角开始,从左到右、从上到下进行滑动,当卷积的窗口滑动到一个位置时,该窗口中的数据 and 卷积核按元素相乘,相乘的结果再相加,即为卷积运算得到的值。这一过程可用图 1 表示。




图 1 卷积运算
Fig. 1 Convolution operation

1.2 残差网络

由于卷积出色的特征提取能力,经常与其他模块结合组成网络模型,但其应用时也存在一定的缺陷。在构建网络模型时,网络提取的特征会随着网络层次的加深而变得丰富。但是神经网络进行优化时需要梯度进行反向传播,反向传播中使用的链式求导会带来累乘效应。在此过程中,若过深的模型梯度小于 1,梯度链式求导将导致模型的某些参数梯度快速缩小至 0 附近,使得模型无法继续优化;而当梯度大于 1 时,累乘又会导致某些参数的梯度非常大,导致参数变化过大,模型无法收敛。而残差网络可以通过跳跃连接缓解这一情况^[16]。

残差网络最早由何凯明等^[17]提出,该网络的基本思想:网络的每个附加层都应该更容易包含原始函数。一个残差网络由多个残差块组成,假设网络通过输入 x 拟合目标 $f(x)$,则残差块接收输入 x ,经残差块映射后得到输出 $f(x)-x$,然后将输入 x 跳过残差块,与输出相加得到拟合目标 $f(x)$,而不是通过 x 直接拟合 $f(x)$ 。一个残差块可用图 2 表示。




图 2 残差块结构
Fig. 2 Residual block structure

1.3 Transformer 理论基础

Transformer 是一种完全基于注意力机制处理序列到序列任务的深度学习模型。注意力机制来源于人类视觉的注意力,其通过概率分配的方式,对重要信息赋予更高的权重,从而突出重要信息,减少甚至忽略不重要的信息。注意力机制可以根据输入的特征和任务需求,动态地调整不同的输入权重,从而提升模型的表现和泛化能力^[18-19]。

当使用同一组输入同时充当查询、键和值的时候,注意力机制称为自注意力。对于一组输入数据 X ,当使用点积计算自注意力得分时,计算过程为

(1) 对输入数据作变换,得到查询 (Q)、键 (K) 和值 (V),公式可表示为

$$Q = W^Q X \tag{1}$$

$$K = W^K X \tag{2}$$

$$V = W^V X \tag{3}$$

其中, W^Q 、 W^K 、 W^V 分别表示对 X 进行变换的矩阵。

(2) 使用点积计算自注意力得分,公式表示为

$$\text{Softmax}\left(\frac{Q * K^T}{\sqrt{d_k}}\right) V \tag{4}$$

多头注意力是指在使用注意力机制时,使用多个注意力头来捕捉数据不同方面的信息,每个注意力头关注信息不同,然后将不同注意力头结合。类似地,当使用同一组输入充当查询、键和值的时候称为多头自注意力机制。

Transformer 编码器模块由多个相同的层叠加而成,每个层包含两个子层,第一个子层为多头自注意力汇聚,第二个子层是基于位置的前馈神经网络。

1.4 模型构建

根据对已有文献的了解和上述理论基础的研究,本文使用卷积、残差连接和以多头自注意力机制为基础的 Transformer 编码块构建卷积残差编码模型。整个模型由卷积和 Transformer 编码两大模块组成。其中卷积部分共包含 4 个卷积层,每个卷积层使用多通道的一维卷积、BatchNorm 层、最大池化层和 ReLU 激活函数组成。卷积块使用一维卷积对输入的数据执行卷积运算,对卷积的结果使用最大池化来计算卷积特征图中的一个窗口内的最大值,最大池化可以在减小特征图尺

寸的同时保留最重要的特征,池化的结果通过 BatchNorm 层进行批规范化操作。批规范化与数据的标准化类似,是将分散的数据统一,此操作可将数据特征分布变得稳定,从而可以使用更大的学习率,加速模型的收敛速度。ReLU 激活函数用来增加网络的非线性特征,提高模型的拟合能力。卷积模块得到的输出增加残差连接后作为 Transformer 编码器模块的输入。该模块使用多头自注意力机制来突出更应该关注的特征,多头自注意力机制的查询(Q)、键(K)和值(V)都来自前一个编码器层的输出,并在每个子层采用残差连接,最终输出一个和输入数据维度相同的向量。对此向量增加残差连接后经过全连接层和 Softmax 层得到最终的输出。模型结构如图 3 所示。




图 3 模型结构

Fig. 3 Model structure

2 仿真实验与结果分析

2.1 实验数据与实验环境

为充分验证该方法的有效性,本文在两个数据集上进行模型的验证,分别是西储大学轴承数据集和用传感器采集水泥生产线辊压机的实际振动数据(后面简称为辊压机数据)。实验设计:首先在西储大学轴承数据集上进行模型的初步实验,该数据集在不同的文献中使用较多,且均能取得较好的分类精度,在该数据集上效果一般的模型,可能不具有深入研究的必要,所以取该数据初步验证模型的可用性;当在该数据集上取得较好的效果时,在辊压机数据上进行实证分析,其中使用的辊压机正常和故障数据总长度均为 1 024 000,对这两类数据分别随机切分出 2 000 个长度为 1 024 的片段,作为实验的总数据集,然后从 4 000 个样本中随机选择 70% 作为训练集,20% 作为验证集,10% 作为测试集,并使用和实证分析完全相同的设置进行消融实验。消融实验模型设置为去除卷积模块、去除 Transformer 编码模块,两种情况的模型分别简记为 RTE、CR。对比不同情况下模型在辊压机数据集上的表现,来验证这两个重要模块设置的有效性。

实验使用 Python 语言进行,使用的深度学习框架为 Pytorch,模型训练在 NVIDIA GeForce RTX 3060 上进行,优化器为 Adam,损失函数为交叉熵损失函数,初始学习率为 0.000 01,每隔 50 步衰减为原来的 0.9。

训练好的模型在测试集上测试,用准确率($f_{accuracy}$)、查准率($f_{precision}$)、查全率(f_{recall})、 F_1 分数 4 个

指标来衡量结果,4 个指标的计算公式可表示为

$$f_{accuracy} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \quad (5)$$

$$f_{precision} = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (6)$$

$$f_{recall} = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (7)$$

$$F_1 = \frac{2 * f_{precision} * f_{recall}}{f_{precision} + f_{recall}} \quad (8)$$

其中, N_{TP} 、 N_{FP} 、 N_{FN} 、 N_{TN} 分别表示样本为正类且被预测为正类、负类被预测为正类、正类被预测为负类、负类被预测为负类。

2.2 实验结果分析

将建立的模型在凯斯西储大学轴承数据集进行实验。使用 12 kHz 采样频率的驱动端轴承数据,该数据集共 10 类数据,其中 9 类为不同的故障,一类为正常数据,每类切分出 2 000 个样本进行实验,并为每类数据增加标签。标签与数据类型的对应关系如表 1 所示。

表 1 数据与标签对应

Table 1 Data corresponding to labels

数据类型	标 签
滚动体故障,直径 0.018 cm	0
滚动体故障,直径 0.036 cm	1
滚动体故障,直径 0.053 cm	2
内圈故障,直径 0.018 cm	3
内圈故障,直径 0.036 cm	4
内圈故障,直径 0.053 cm	5
外圈故障,直径 0.018 cm	6
外圈故障,直径 0.036 cm	7
外圈故障,直径 0.053 cm	8
正常数据	9

由于只是初步验证模型是否可行,这里只进行一次实验,使用训练完成后的模型在测试集上进行测试,并绘制测试集的混淆矩阵,结果如图 4 所示。

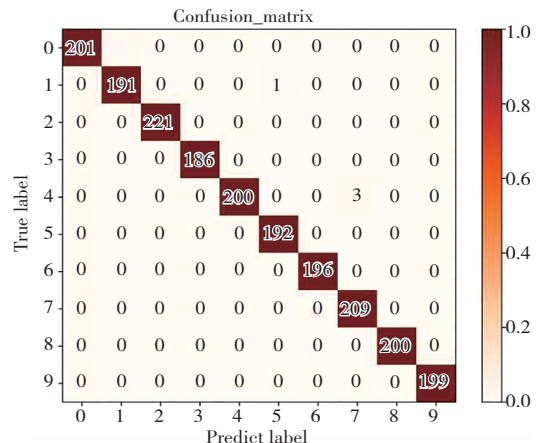


图 4 测试集混淆矩阵

Fig. 4 Confusion matrix of the test set

从图 4 可以看出,测试集 10 类样本的 2 000 个样本中,有 5 个样本没有分类正确,标签 0 中有一个样本被模型识别为标签 1,标签 1 中有一个样本被模型识别为标签 5,标签 4 中有 3 个样本被识别为标签 7,其余样本均能被模型准确识别。测试集全体样本的识别准确率为 99.75%,效果较好,可在辊压机数据集上进一步实验。

辊压机数据仅有正常和故障两个类别,为避免模型训练的偶然性,这里设置 10 个不同的随机种子划分数据集,在各数据集上分别实验,然后将 10 次实验的结果结合作为模型实际结果,同样绘制出结果的混淆矩阵,结果如图 5 所示。

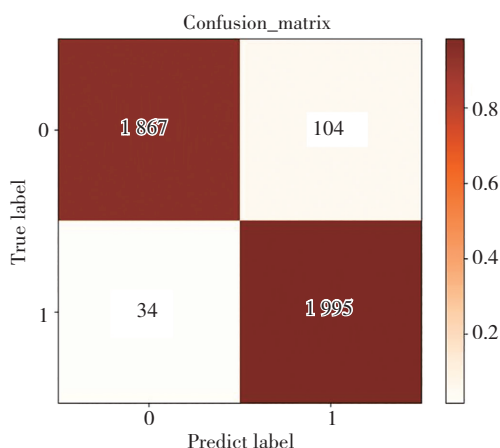


图 5 辊压机数据测试集混淆矩阵

Fig. 5 Confusion matrix of the roller press data test set

图 5 中,标签 0 表示正常数据,标签 1 表示故障数据,每次实验有 200 个测试样本。从图中可以看出:10 次实验的 2 000 个测试集样本中,总体准确率达到 96.55%,模型对正常和故障的查全率分别为 94.72%和 98.32%,均达到了较高的程度,可以认为该方法在对实际辊压机进行故障诊断时有较好的效果。

使用上文提到的消融实验和数据集划分方法进行消融实验,消融实验结果也使用 10 次随机训练的结合作为最终结果。选择准确率、查准率、查全率、 F_1 分数 4 个指标来衡量不同模型的表现情况。由于对设备的故障检测主要目的是识别出设备的故障情况,因此这里指标的计算以故障作为正类,正常作为负类。此种情况下,准确率表示所有样本中预测正确的概率,查准率表示所有预测为故障的样本中有多少样本真的存在故障,查全率表示所有故障样本中有多少被识别出来, F_1 分数是查准率和查全率的调和平均。指标最终的计算结果如表 2 所示。

表 2 辊压机数据测试集结果

指 标	CRTE	RTE	CR
$f_{accuracy}$	96.55	92.00	94.30
$f_{precision}$	95.05	87.77	92.14
f_{recall}	98.32	95.63	97.04
F_1 分数	96.66	91.53	94.52

从表 2 可以看出:完整的模型(CRTE)、删除卷积部分(RTE)和删除 Transformer 编码部分(CR)的模型精度之间有一定差别。3 个模型中,CRTE 的准确率、查准率、查全率和 F_1 分数均取得最高值,这说明该模型去掉卷积块或 Transformer 编码模块都将导致模型效果的下降。两个主要模块都对辊压机数据的故障识别起到一定的作用,说明模型构建是合理的。整体模型在辊压机数据集上表现较好,可认为该模型的构建具有实际价值。

3 结 论

本文针对水泥生产设备运行环境较为恶劣,设备容易被环境影响,导致出现非正常停机或故障而影响生产的情况,提出利用卷积残差 Transformer 编码网络对水泥生产线中的主机设备辊压机进行故障诊断。使用多层卷积提取输入数据的局部特征,卷积后增加残差项,以保证模型在训练过程中随网络层数的增加性能可得到提升;将提取出的特征输入 Transformer 编码模块,其中的多头注意力可以聚焦特征中的重点信息,再次增加残差后经过全连接层进行分类,充分挖掘数据的特征信息;在凯斯西储大学公开数据集上验证该模型的可行性,准确率达到 99.75%,然后在辊压机实际运行中产生的振动数据上进行 10 次实验,结合 10 次的结果作为最终结果;同时通过消融实验证明,先用卷积操作提取特征信息,然后使用 Transformer 编码模块关注重点信息的方法能取得较好的效果,最终得到模型对正常和故障状态的查全率分别为 94.72%和 98.32%,说明能有效识别辊压机运行过程中的异常状态,存在一定实用价值。

参考文献(References):

[1] 谢亚钦. 辊压机常见机械故障分析与处理方法[J]. 新世纪水泥导报, 2018, 24(1): 47-48.
XIE Ya-qin. Analysis and treatment of common mechanical faults of roller presses [J]. Cement Guide for New Epoch, 2018, 24(1): 47-48.

[2] 俞建明, 翟小飞, 魏士源, 等. 基于多元状态估计的旋转设备早期故障监测方法[J]. 自动化应用, 2022(8): 42-45.
YU Jian-ming, ZHAI Xiao-fei, WEI Shi-yuan, et al. Early fault monitoring method for rotating equipment based on

- multivariate state estimation[J]. Automation Application, 2022(8): 42-45.
- [3] 普会杰,刘韬,刘畅,等.基于流形学习的旋转设备故障诊断方法[J].中国安全生产科学技术,2023,19(8):209-216.
PU Hui-jie, LIU Tao, Liu Chang, et al. Fault diagnosis method of rotating equipment based on manifold learning[J]. Journal of Safety Science and Technology, 2023, 19(8): 209-216.
- [4] 黄迅迪,庞雄文.基于深度学习的智能设备故障诊断研究综述[J].计算机科学,2023,50(5):93-102.
HUANG Xun-di, PANG Wen-xiong. A review of research on intelligent device fault diagnosis based on deep learning[J]. Computer Science, 2023, 50(5): 93-102.
- [5] 芦奕霏.基于深度学习的轴承故障诊断方法研究[D].南京:南京邮电大学,2022.
LU Yi-fei. Research on bearing fault diagnosis methods based on deep learning[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2022.
- [6] 周翔宇,毛善君,李梅.基于频域降采样和 CNN 的轴承故障诊断方法[J].北京大学学报(自然科学版),2023,59(2):251-260.
ZHOU Xiang-yu, MAO Shan-jun, LI Mei. A bearing fault diagnosis method based on down-sampling in frequency domain and CNN[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2023, 59(2): 251-260.
- [7] 宋晓承,岑跃峰,张宇来,等.基于双通道深度学习的轴承故障诊断研究[J].机电工程,2023,40(7):988-998.
SONG Xiao-cheng, CEN Yue-feng, ZHANG Yu-lai, et al. Research on bearing fault diagnosis based on dual channel deep learning[J]. Mechanical and Electrical Engineering, 2023, 40(7): 988-998.
- [8] 张珂,王竞禹,石怀涛,等.基于 CNN 的变工况滚动轴承故障诊断研究[J].控制工程,2022,29(2):254-262.
ZHANG Ke, WANG Jing-yu, SHI Huai-tao, et al. Research on rolling bearings fault diagnosis under variable working condition based on CNN[J]. Control Engineering of China, 2022, 29(2): 254-262.
- [9] 李秋婷,王秀青,解飞,等.基于注意力机制的滚动轴承故障诊断方法[J].轴承,2023(10):84-92.
LI Qiu-ting, WANG Xiu-qing, XIE Fei, et al. A fault diagnosis method for rolling bearings based on attention mechanism[J]. Bearing, 2023(10): 84-92.
- [10] 韩争杰,牛荣军,马子魁,等.基于注意力机制改进残差神经网络的轴承故障诊断方法[J].振动与冲击,2023,42(16):82-91.
HAN Zheng-jie, NIU Rong-jun, MA Zi-kui, et al. A bearing fault diagnosis methods based on attentional-mechanism-improved residual neural network[J]. Journal of Vibration and Shock, 2023, 42(16): 82-91.
- [11] 卢浩龙,朱彦敏.基于多尺度图 Transformer 的滚动轴承故障诊断[J].国外电子测量技术,2023,42(12):186-194.
LU Hao-long, ZHU Yan-min. Fault diagnosis of rolling bearing based on multi-scale graph Transformer[J]. Foreign Electronic Measurement Technology, 2023, 42(12): 186-194.
- [12] 潘琳鑫,巩永旺,晏生莲.一种改进一维卷积神经网络的轴承故障诊断方法[J].软件导刊,2023,22(4):38-42.
PAN Lin-xin, GONG Yong-wang, YAN Sheng-lian. A bearing fault diagnosis method based on improved one-dimensional convolutional neural network[J]. Software Guide, 2023, 22(4): 38-42.
- [13] HAN S, NIU P, LUO S, et al. A novel deep convolutional neural network combining global feature extraction and detailed feature extraction for bearing compound fault diagnosis [J]. Sensors, 2023, 23(19): 8060.
- [14] 钱白云,吕朝阳,张维宁,等.基于多传感器信息融合与混合感受野残差卷积神经网络的调相机转子故障诊断[J].计算机测量与控制,2023,31(9):29-35.
QIAN Bai-yun, LYU Chao-yang, ZHANG Wei-ning, et al. Fault diagnosis of condenser rotor based on multi-sensor information fusion and mixed receptive field residual convolutional neural network[J]. Computer Measurement and Control, 2023, 31(9): 29-35.
- [15] 汉秋,王敬宇,赵理华.基于人工智能的自然资源要素遥感解译的建设应用[J].中国测绘,2021(7):66-69.
HAN Qiu, WANG Jing-yu, ZHAO Li-hua. Construction and application of remote sensing interpretation of natural resource elements based on artificial intelligence[J]. China Surveying and Mapping, 2021(7): 66-69.
- [16] 蔡昌春,何捷,承敏钢,等.基于改进 VMD-MCKD 和深度残差网络的风机齿轮箱故障诊断[J].山东电力技术,2024,51(2):67-78.
CAI Chang-chun, HE Jie, CHENG Min-gang, et al. Fault diagnosis of fan gearbox based on improved VMD-MCKD and deep residual network[J]. Shandong Electric Power, 2024, 51(2): 67-78.
- [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.
- [18] 李俊卿,胡晓东,秦静茹,等.基于多头注意力机制和卷积模型的超短期风电功率预测[J].电力科学与工程,2022,38(7):34-40.
LI Jun-qing, HU Xiao-dong, QIN Jing-ru, et al. Ultra-short-term wind power prediction based on multi-head attention mechanism and CNN model[J]. Electric Power Science and Engineering, 2022, 38(7): 34-40.
- [19] 林昕,朱小栋.基于 Attention 机制的 LSTM 股价预测模型[J].重庆工商大学学报(自然科学版),2022,39(2):75-82.
LIN Xin, ZHU Xiao-dong. Attention-mechanism-based LSTM model for stock price predicting[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2022, 39(2): 75-82.

责任编辑:李翠薇