

基于自注意力编解码结构的旋转机械故障诊断与预测系统

朱珊珊¹, 郭虎^{2,3}, 余海波^{2,3}, 杨明翰³, 汪建业³

- 安徽工业技术创新研究院六安院, 安徽六安 237100;
- 中国科学技术大学研究生院科学岛分院, 安徽合肥 230026;
- 中国科学院合肥物质科学研究院, 安徽合肥 230031)

摘要: 由于恶劣的运行条件和高负荷要求, 旋转机械故障可能导致高昂的维护成本和不必要的停机时间。有必要开发一个高效、准确的旋转机械故障在线诊断和预测系统, 帮助企业快速识别故障, 预测未来事件, 优化维修计划。构造状态矩阵表示旋转机械产生的振动信号, 即将一个连续时间序列划分为多个窗口, 并将每个窗口转换为一个图像。由特定结构的串联编解码器提取并处理图像特征, 用于分类训练数据集中的振动模式。通过仿真实验验证了基于自注意力编解码结构的旋转机械故障在线诊断和预测系统的可靠性和有效性, 构建的旋转机械状态特征库可以准确诊断和预测旋转机械的故障。研究表明, 该系统可以帮助企业优化维护计划, 减少停机时间和维护成本。

关键词: 故障诊断; 旋转机械; Transformer; 卷积神经网络

DOI: 10.11907/rjdk.231706

开放科学(资源服务)标识码(OSID):



中图分类号: TP399

文献标识码: A

文章编号: 1672-7800(2024)009-0099-06

A Fault Diagnosis and Prediction System for Rotating Machinery Based on Self-Attention Encoding and Decoding Structure

ZHU Shanshan¹, GUO Hu^{2,3}, YU Haibo^{2,3}, YANG Minghan³, WANG Jianye³

- Lu'an Branch, Anhui Institute of Innovation for Industrial Technology, Luan 237100, China;
- Science Island Branch, Graduate School of USTC, Hefei 230026, China;
- Hefei Institutes of Physical Science, Chinese Academy of Science, Hefei 230031, China)

Abstract: Due to harsh operating conditions and high load requirements, rotating machinery faults can lead to high maintenance costs and unnecessary downtime. It is necessary to develop an efficient and accurate rotating machinery fault online diagnosis and prediction system to help enterprises quickly identify faults, predict future events, and optimize maintenance plans. The construction state matrix represents the vibration signal generated by rotating machinery, that is, a continuous time series is divided into several Windows, and each window is converted into an image. Image features are extracted and processed by a series codec of a specific structure to classify vibration patterns in a training data set. The reliability and effectiveness of the online fault diagnosis and prediction system for rotating machinery based on self-attention codec structure are verified by simulation experiments. The state characteristic database of rotating machinery can accurately diagnose and predict the faults of rotating machinery. The system can help businesses optimize maintenance schedules and reduce downtime and maintenance costs.

Key Words: fault diagnosis; rotating machinery; Transformer; convolutional neural network

收稿日期: 2023-10-23

作者简介: 朱珊珊(1991-), 女, 安徽工业技术创新研究院六安院研究实习员, 研究方向为信号处理、智能故障诊断; 郭虎(1998-), 男, 中国科学技术大学研究生院科学岛分院博士研究生, 研究方向为计算机层析技术、图像处理、信号处理、人工智能; 余海波(1997-), 男, 中国科学技术大学研究生院科学岛分院博士研究生, 研究方向为图像处理、信号处理、人工智能; 杨明翰(1990-), 男, 博士, 中国科学院合肥物质科学研究院副研究员, 研究方向为系统控制与仿真技术; 汪建业(1966-), 男, 博士, 中国科学院合肥物质科学研究院研究员、博士生导师, 研究方向为光电子学测量技术、复杂核系统测量与控制技术、数字模拟、智能故障诊断。本文通讯作者: 郭虎。

0 引言

振动信号是一种普遍存在于机械系统中的重要信号，可用于监测和诊断机械故障。随着工业化进程的不断推进，各种旋转机械在生产和生活中得到广泛应用，其中包括发电机组、泵、风力发电机等^[1]。由于旋转机械的部件在长时间运转过程中会逐渐出现疲劳开裂、磨损、断裂等问题，故机械结构的健康状态诊断与预测成为一个极具挑战性的问题。

为了对不同类型的机械故障进行识别和分类，在过去的几十年中，许多研究人员已经提出了各种不同的振动诊断方法。通过振动分析进行故障诊断是维修工程师广泛采用的一种旋转机械状态监测方法，传统的机械结构健康状态检测方法主要基于信号分析^[2]、频域分析等。在传统的振动诊断方法中，基于频域分析的方法，如快速傅里叶变换(FFT)^[3]和小波变换(WT)^[4]等被广泛应用^[5]。这些方法可以将振动信号从时域转换为频域，以提取具有不同特征的频率分量。此外，一些学者通过特征提取方法，比如基于时域特征、频域特征和时频特征^[2]等特征提取方式相结合的方法以改善故障诊断缺陷^[6]，也取得了很好的效果。然而，这些方法在处理多种类型的复杂机械故障时可能会出现一些问题^[7]，比如信号采样率不足以捕捉所有故障特征频率，从而导致重要信息丢失，且频域方法容易受到抽样长度、窗函数和信号重叠等参数影响，这可能导致频谱泄漏和失真。因此，近年来，基于机器学习和深度学习的振动故障诊断已逐渐成为研究热点。机器学习模型如概率神经网络(PNN)^[8]、主成分分析(PCA)^[9]、支持向量机(SVM)^[10-11]、k近邻(KNNs)^[12-13]方法等可以更高效地处理数据；深度学习模型，尤其是卷积神经网络(CNN)已被广泛应用于振动故障诊断。这种方法不需要人工提取特征，而是通过训练神经网络学习涉及振动信号的复杂特征，能够更高效地进行故障诊断^[14-15]。随着问题的多样化，方法也在不断地改进，冷佳等^[16]提出多特征融合CNN网络，刘晓宇等^[17]针对小样本集提出深层多尺度径向基过程神经网络(DLMS-RBFPNN)，Gong等^[18]和Lei^[19]等在自适应算法方面作出了贡献。但由于旋转机械的高维度和复杂性，这些方法普遍面临诸多局限。除卷积神经网络外，Transformer结构的广泛应用也为故障诊断带来了新的变革。因此，本文提出一种基于自注意力的编解码结构(Self-Attention Encoder-Decoder, SAED)对健康状态进行在线诊断与预测，这种方法能够有效地学习和提取状态矩阵的低维和高维特征，从而实现振动信号的准确分类和故障诊断。

综上所述，基于深度学习和特征提取方法的振动故障诊断方法，是当前研究的热点和难点。本文提出这种新的基于SAED的故障诊断方法，利用自注意力编码器，开展了

针对三维坐标系空间振动数据的振动分析。基于状态矩阵的健康状态在线诊断与预测系统将为机器的故障排查和预防提供更加有效的途径，其在旋转机械领域有着广阔的应用前景。

1 相关方法

1.1 数据预处理

对于一个三轴加速度传感器采集到的一组时序上的海量数据，振动信号表示直角坐标系下的加速度。对于 t 个时间点上的数据 $X = \{x_1, x_2, \dots, x_t\}$, $Y = \{y_1, y_2, \dots, y_t\}$, $Z = \{z_1, z_2, \dots, z_t\}$ 删除离群点，再通过 min-max 归一化方法将其归一化到 0 到 1 之间以解决数据分布不规律问题，其归一化表达式为如式(1)所示。

$$X_{norm} = (X_i - X_{min}) / (X_{max} - X_{min}) \quad (1)$$

在进行机器的健康状态预测和诊断时，三轴振动传感器的振动信号通常可以表示为一个标量，该标量表示整个机器的整体振动强度。对时间点 T_i 的矢量信号 (x_i, y_i, z_i) 转化为标量信号的过程为 $a_i = x_i^2 + y_i^2 + z_i^2$ ，每个时间点的数据进行加权求和，比如时间点 T_i 的矢量信号 (x_i, y_i, z_i) 转换成标量 $a_i = x_i^2 + y_i^2 + z_i^2$ ，该标量振动信号 a_i 用来表示该时间点 T_i 上的振动强度，将此前连续 m 个时刻的标量振动信号在时间轴方向上排列即可得到一个振动强度序列 $A_{1 \times m}$ 。 n 个传感器的信号就是一个 $n \times m$ 的振动强度矩阵 $A_{n \times m}$ ，如图 1 所示。将振动强度矩阵 $A_{n \times m}$ 作为输入数据，使用监督学习算法进行建模、预测和诊断。

对 3 个方向上测量的振动数据求平方和的过程可能导致信息损失，因为这个操作会将原始信号降维为一个标量，丢失了 3 个方向振动信号在不同频率和振幅上所表示的信息。虽然这对于某些应用场景而言可能并不是很理想，例如需要对不同频率和振幅振动信号进行更精细分析和测量的场景，但是在很多部件的故障检测中都可以利用更少的内存进行更高效的故障分析。

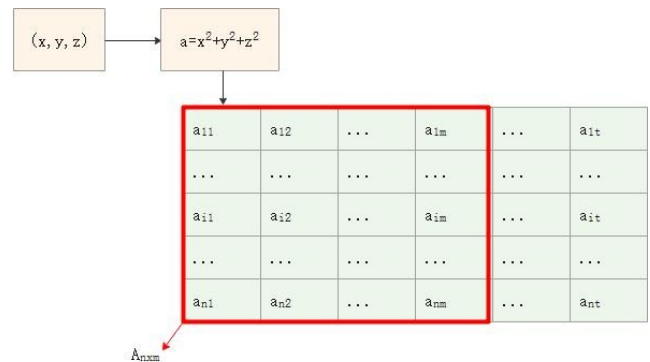


Fig. 1 Data organization form and observation window with the size of $n \times m$

图1 数据组织形式和 $n \times m$ 大小的观测窗

1.2 优化目标

对旋转机械的故障诊断可以表示为对状态矩阵 $A_{n \times m}$ 的分类问题,表示通过 n 个三轴加速传感器从当前时刻 T_m 之前的 m 个时刻的信号预测当前旋转机械在 T_m 时刻的状态。对此,该分类问题可以表示为式(2)。

$$Y_i = f(A_{n \times m}), (i = m, m + 1, \dots, t) \quad (2)$$

其中, f 表示分类函数, Y_i 表示分类结果, $A_{n \times m}$ 表示从 i 时刻开始 m 个时刻信号转化的状态矩阵。当 $A_{n \times m}$ 来自样本空间,该故障诊断系统就可以计算出当前旋转机械的状态 Y_i 是稳态或者故障态。

对式(1)这种张量分类问题,经典的机器学习方法如二值分类, k 近邻和支持向量机等聚类方法只需要更少的计算资源,但实时性和准确率却无法达到要求。基于深度学习的卷积神经网络(CNN)显然是一个合适的方法^[20],但对于CNN的训练和运行需要大量的计算资源,因此用于旋转机械振动故障诊断的硬件系统需要较高的实时计算性能。与CNN相比,串联编码器结构处理序列数据具有更高的灵活性,且与传统的RNN相比,串联编码器使用了更加高级的门控技术,如Transformer中的自注意力机制,可以有效地解决梯度消失和梯度爆炸问题,同时具有更好的并行性,以加速模型训练。




Fig. 2 Data flow and SAED network structure

图2 SAED网络结构与数据流

对于分类问题,输出层的激活函数一般选择SoftMax函数,其表达式如式(3)所示。

$$p_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (3)$$

其中, p_i 表示输出层上第 i 层神经元的输出, z_i 表示输出层上第 i 个神经元的输入, k 表示输出层上神经元的数量。最终函数值反映的就是分类概率,是一个向量,其中最大的分类概率用以表示当前旋转机械的振动状态。

2 实验与结果分析

2.1 物理设备

实验以某旋转机械为例,在不同位置安装2个振动传感器提供实时振动信号,其中振动信号由集散控制系统(DCS)采集。

如图3所示,工控机通过DCS内的专用DPU连接起来,这个专用DPU还会与DCS中的其他DPU进行通信。通过基于TCP/IP的数据传输网络获取振动信号,提取振动

1.3 网络结构

Transformer是一种用于处理序列数据的深度学习模型,在处理长序列数据时具有更好的性能,并且可以并行计算,使得训练速度更快。

Transformer模型基于自注意力机制,它通过对序列中的每个元素赋予不同的权重系数,实现了元素之间的交互和融合。在自注意力机制的基础上,Transformer还使用了多头注意力机制(Multi-head Attention),以进一步扩展模型的表达能力和上下文理解能力。

除注意力机制外,Transformer还包括编码器和解码器。编码器用于学习序列的表示,在故障诊断任务中,它可以将源信号序列编码成一个固定长度的向量。解码器则通常用于生成目标序列,在故障诊断任务中,它可以使用编码器的输出以及上一个时刻的生成结果,逐步生成目标序列。可以通过与CNN的结合完成故障诊断的分类任务。

图2展示了SAED的完整结构,包括数据输入层、串联编码器、串联解码器和 1×1 卷积层实现的输出层。通过串联编码器可以提取状态矩阵中隐含的信息并得到高维特征,最终的 1×1 卷积层是为了将高维特征进行整合,得到特征的高级含义,进而转换成最终分类结果。




Fig. 3 Hardware architecture based on DPU

图3 基于DPU的硬件结构

张量,其中故障分析算法也在DCS中执行,分类结果一并传输到操作台进行分析。

2.2 实验方法

分别对振动传感器上3个方向的数据进行归一化,然后求平方和转换成标量,两个三轴振动传感器接收到的信号就可以表示为二维向量,转换成张量之后通过如图2所示的网络结构得到分类结果。SAED结构包含5个编码器结构、5个解码器结构,以及1个整合高维特征生成分类结果的 1×1 卷积层,其中核心组件为编码器和解码器。这两个核心组件都由多个相同的层堆叠而成,每个层由两个子层组成,分别是多头自注意力机制(Multi-Head Self-Attention)和前馈神经网络,在每个子层中,都有一个残差连接和一个层归一化操作,其具体结构如图4所示。本文在实验中,考虑到不同故障之间存在关联,故保留了传统Transformer算法中的位置编码结构。通过引入位置编码,模型能够保留输入序列的顺序信息,并允许模型在自注意力机制的基础上对序列进行适当建模。

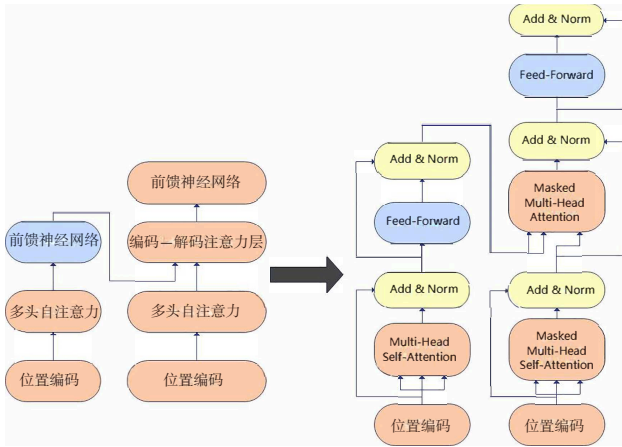


Fig. 4 Encoder-Decoder specific structure implementation
图4 编解码器具体结构实现

在该结构中,自注意力编码是模型中的核心机制之一,主要用于捕捉输入序列中不同信号之间的关联性和重要性,目的是将每个信号与其他信号之间的关联性进行建模,通过对不同信号之间进行关系度量,以便根据这些关系进行编码。为了测量信号之间的关系,对每个单词进行3个矩阵变换:查询、键、值。这些变换包括学习的权重,便可以转换到不同的表示空间以捕捉信号之间的关联性。其中,查询矩阵和键矩阵的点积可以计算出不同信号之间的相关性得分,即可判断出不同信号之间的关联程度。

2.3 数据预处理

在此次实验中,考虑5种振动器状态,包括1种正常状态和4种故障状态:轴承等磨损、联轴器平衡断裂、油液损坏和齿轮故障,所有状态如表1所示。

对于轴承等磨损状态,可以将其描述为轴承摩擦和磨损会导致振动信号的频率和幅度发生变化。例如,在时域中观察到的振动信号可能会变得更加不规则和不稳定,频域上可以看到频率分布的幅值发生变化;轴器不平衡会导致振动


Table 1 Simulated fault condition

表1 模拟故障条件


状态ID	描述
1	正常
2	轴承等磨损
3	联轴器平衡断裂
4	油液损坏
5	齿轮故障

信号呈现出明显的不对称性。这种故障状态下,振动信号的频谱中会出现与转子不平衡相关的频率成分;油液损坏是指当油液质量降低或含有污染物时,振动信号的幅度和频谱都会发生变化。这种故障状态下,振动信号可能呈现出较高的幅值和不寻常的频率成分;齿轮故障是指齿轮的磨损、损坏或错误啮合等问题。在这种情况下,齿轮故障将导致振动信号中出现与齿轮啮合相关的频率成分。此外,振动信号的幅度和频谱也会随着齿轮故障的严重程度而发生变化。

通过旋转机械的振动实验,获得了12 h内的振动数据,分为训练集和验证集两部分。安装退化组件以在不同时间呈现故障。12 h内采集到的振动信号超过25万个,每个振动张量有50个采样周期为0.5 s的时域样本,6个信号组(2个传感器x、y、z方向的振动信号),对三轴振动信号求取平方和之后,每个振动张量的大小为 50×2 ,其中一个传感器信号表现的状态变化如图5所示。



(a) Normalized sum of squares of vibration signal within 0~0.7 h
(a) 0~0.7 h内的归一化振动信号平方和



(b) Normalized sum of squares of vibration signal within 0.7~12 h
(b) 0.7~12 h内的归一化振动信号平方和

Fig. 5 Normalized sum of squares of vibration signal from sensor 1
图5 传感器1的归一化振动信号平方和结果

2.4 实验结果及分析

本文采用的评价指标是精确率、召回率, 以及它们的调和均值 $F1$ 得分 ($F1$ -Score)。其中, 精确率表示模型预测为正类的样本中, 真正为正类的样本比例, 其计算公式为: 精确率 = 真正类数 / (真正类数 + 假正类数); 召回率表示模型能够正确预测为正类的样本比例, 其计算公式为: 召回率 = 真正类数 / (真正类数 + 假负类数); $F1$ 评价指标是精确率和召回率的调和平均值, 能够综合考虑两个指标之间的平衡性, 计算公式为: $F1 = 2 * (\text{精确率} * \text{召回率}) / (\text{精确率} + \text{召回率})$ 。 $F1$ 评价指标的取值范围是 0~1, 数值越接近 1 表示模型性能越好。当精确率和召回率在不同场景中具有不同重要性时, $F1$ 评价指标可以作为一个较为平衡的评价指标。

本文实验环境为: 将振动数据分为训练集和测试集两部分, 其中训练集中的正常信号约 14 万个, 故障信号约 8 万个, 测试集中正常信号约 2 万个, 故障信号约 1 万个。将数据集中的信号经过预处理得到的张量直接输入到 SAED 中。200 轮迭代学习过程得到的训练损失和精确率变化曲线分别如图 6 所示, 可以看到, 在训练过程中, 损失可以迅速收敛到一个很小的值, 且训练精度保持在 99% 左右, 这说明本文提出的网络可以很好地将传感器数据拟合到状态分类的映射上。

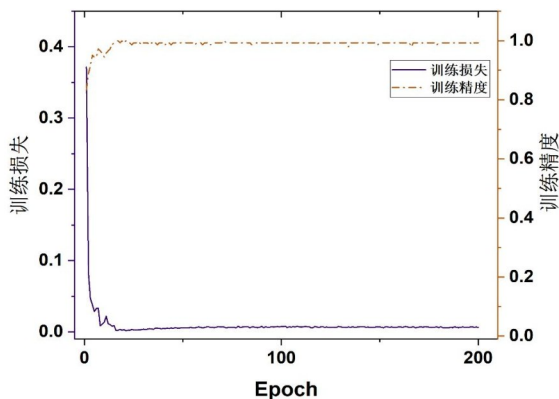


Fig. 6 Train loss and accuracy rate

图 6 训练损失与精确率

为了测试 SAED 的性能, 通过在线测试方式额外测试了 7 万个振动信号, 大约 2 万个故障信号。200 轮训练网络的验证损失和精确率变化曲线如图 7 所示, 由于测试数据与训练数据的采集对象不同, 故验证损失和精度略有下降, 但仍然在一个可接受的范围内, 这一训练和验证过程证明, 该方法的准确率和召回率都在 90% 以上, 测试实验结果如表 2 所示。其中, 类别 2 和类别 4 的结果比较相似是因为轴承磨损和油液损坏都属于轻微影响的故障, 因而与正常状态的诊断结果也较为相似, 但二者的振动数据又分别具有不同的特征, 因此准确率和召回率都偏高。类别 3 和类别 5 的准确率较低是因为这两个故障都会严重引起

机械的正常运行, 在宕机状态下对振动数据具有较强的误导性, 因而误判可能性较高。

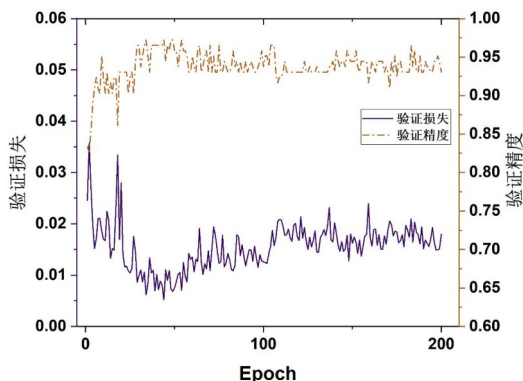


Fig. 7 Validation loss and accuracy rate

图 7 验证损失与精确率

Table 2 Accuracy and recall of the SAED method on the test set

表 2 SAED 方法在测试集上的精确率与召回率

类别	样本数量	精确率	召回率	F1 得分
1	49 384	0.950 16	0.941 92	0.946 02
2	7 328	0.935 79	0.948 69	0.942 20
3	1 526	0.909 81	0.905 64	0.911 00
4	2 253	0.934 24	0.945 85	0.940 01
5	6 835	0.912 75	0.955 08	0.933 44

2.5 对比实验

为了进一步验证本文提出的自注意力编解码结构的精确率, 本文选取了一些传统的机器学习方法, 如 K-近邻 (KNN)^[21]、支持向量机 (SVM)、二分类方法对上述测试数据进行重复实验, 得到实验结果如表 3 所示。其中, 精确率表示预测准确的样本数量除以总的样本数, 而不具体区分每一种类别。可以看到, 机器学习方法的精确率均小于本文提出的 SEAD 方法, 说明本文方法相比于机器学习方法可以通过提取更多的特征以表示故障类型。

Table 3 Comparison of experimental results

表 3 实验结果比较

对比方法	精确率	召回率	F1 得分
KNN	0.902 4	0.924 5	0.913 3
SVM	0.917 1	0.899 5	0.908 2
二分类	0.882 6	0.904 7	0.893 5
SEAD	0.943 3	0.934 9	0.939 1

3 结语

本文研究了基于自注意力的串联编码器在旋转机械故障诊断与分析中的应用, 提出了一种编解码结构以预测旋转机械的振动状态。将 14 万个信号作为训练数据进行训练, 并将 2 万个信号作为测试数据进行测试, 对于本文提到的 1 种正常状态和 4 种故障状态, 训练精度可以很快收敛到 99%, 同时验证精度和 $F1$ 得分最终稳定收敛在 94% 左右, 验证了本文所提出的网络 SAED 的有效性。并

且,该方法通过对每一个三轴传感器数据进行了降维处理,并将多个传感器数据整合成一个二维张量用以训练,节省了66%的内存空间,极大地提高了深度网络的训练效率。

同时,与传统的机器学习方法的对比实验表明,该方法通过自注意力编码结构提取到丰富的高维信号特征模拟多模态的故障状态,其 $F1$ 得分相比于传统机器学习方法可以获得3%的提升。在线测试结果表明,基于自注意力的编解码结构对于旋转机械的故障诊断具有良好的测试精度和响应速度。

参考文献:

- [1] JAYASWALT P, WADHWANI A K. Application of artificial neural networks, fuzzy logic and wavelet transform in fault diagnosis via vibration signal analysis: a review[J]. Australian Journal of Mechanical Engineering, 2009, 7(2):157-172.
- [2] VEDAM H, VENKATASUBRAMANIAN V. A wavelet theory-based adaptive trend analysis system for process monitoring and diagnosis [C]// New Mexico: Proceedings of the 1997 American Control Conference, 1997.
- [3] RAI V K, MOHANTY A R. Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert - Huang transform[J]. Mechanical Systems and Signal Processing, 2007, 21(6):2607-2615.
- [4] PENG Z, CHU F, HE Y. Vibration signal analysis and feature extraction based on reassigned wavelet scalogram[J]. Journal of Sound and Vibration Magazine, 2002, 253(5):1087-1100.
- [5] PENG Z K, CHU F L. Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography[J]. Mechanical Systems & Signal Processing, 2004, 18(2):199-221.
- [6] JALAYER M, KABOLI A, ORSENIGO C, et al. Fault detection and diagnosis with imbalanced and noisy data: a hybrid framework for rotating machinery[J]. Machines, 2022, 10(4):237.
- [7] GONG X. Adaptive feature selection method with FF-FC-MIC for the detection of mutual faults in rotating machinery[J]. Journal of Vibroengineering, 2022, 24(4):16.
- [8] CZECH P, WOJNAR G, BURDZIK R, et al. Application of the discrete wavelet transform and probabilistic neural networks in IC engine fault diagnostics[J]. Journal of Vibroengineering, 2014, 16(4):1619-1639.
- [9] SUN W, CHEN J, LI J. Decision tree and PCA-based fault diagnosis of rotating machinery[J]. Mechanical Systems and Signal Processing, 2007, 21(3):1300-1317.
- [10] CHANG Y, WANG Y, TAO L, et al. Fault diagnosis of a mine hoist using PCA and SVM techniques[J]. Journal of China University of Mining and Technology, 2008, 18(3):327-331.
- [11] FERNÁNDEZ-FRANCOS D, MARTÍNEZ-REGO D, FONTENLA-ROMERO O, et al. Automatic bearing fault diagnosis based on one-class ν -SVM[J]. Computers & Industrial Engineering, 2013, 64(1):357-365.
- [12] SONG T, TANG B P, LI F. Fault diagnosis method for rotating machinery based on manifold learning and K-nearest neighbor classifier[J]. Journal of Vibration and Shock, 2013, 32(5):149-153.
宋涛, 汤宝平, 李锋. 基于流形学习和K-最近邻分类器的旋转机械故障诊断方法[J]. 振动与冲击, 2013, 32(5):149-153.
- [13] WANG Q, LIU Y B, HE X, et al. Fault diagnosis of bearing based on KPCA and KNN method[J]. Advanced Materials Research, 2014, 986:1491-1496.
- [14] XU M, WANG P. Research on fault diagnosis of rotating machinery based on deep LSTM residual network[J]. Machine Tool & Hydraulics, 2023, 51(4):184-190.
徐敏, 王平. 基于深度LSTM残差网络的旋转机械故障诊断研究[J]. 机床与液压, 2023, 51(4):184-190.
- [15] LU N, LI M, ZHANG G, et al. Fault feature extraction method for rotating machinery based on a CEEMDAN-LPP algorithm and synthetic maximum index[J]. Measurement, 2022, 189:110636.
- [16] LENG J, LIU Z, ZHANG X F, et al. Research on fault diagnosis of rotating machinery based on multi-feature fusion CNN network[J]. Software Guide, 2021, 20(9):44-50.
冷佳, 刘镇, 张笑非, 等. 多特征融合CNN网络的旋转机械故障诊断研究[J]. 软件导刊, 2021, 20(9):44-50.
- [17] LIU X Y, WU L, XU S H. A deep layer process neural network and its application in signal classification[J]. Software Guide, 2020, 19(3):60-64.
刘晓宇, 武鲁, 许少华. 一种深层过程神经网络及其在信号分类中的应用[J]. 软件导刊, 2020, 19(3):60-64.
- [18] GONG X, ZHI Z, LI C, et al. Adaptive feature selection method with FF-FC-MIC for the detection of mutual faults in rotating machinery[J]. Journal of Vibroengineering, 2022, 24(4):679-694.
- [19] LEI D, CHEN L, TANG J. Mining of weak fault information adaptively based on DNN inversion estimation for fault diagnosis of rotating machinery[J]. IEEE Access, 2021, 10:6147-6164.
- [20] LIU Z H, CHEN L, WEI H L, et al. A tensor-based domain alignment method for intelligent fault diagnosis of rolling bearing in rotating machinery[J]. Reliability Engineering & System Safety, 2023, 230:108968.
- [21] LU D, NING Q, YANG X. Fault diagnosis of rolling bearing based on knn-naive Bayesian algorithm[J]. Computer Measurement & Control, 2018, 26:21-23.

(责任编辑:孙娟)