

doi:10.3969/j.issn.1673-9833.2025.05.003

基于多模态数据融合的轴承故障诊断方法

吴昊天^{1,2}, 彭泽宇^{1,2}, 刘涛^{1,2}, 姚齐水^{1,2}

(1. 湖南工业大学 机械工程学院, 湖南 株洲 412007;
2. 高性能滚动轴承技术湖南省高校重点实验室, 湖南 株洲 412007)

摘要: 针对传统单一模态信号处理在轴承故障诊断中面临的精度不足和复杂故障模式下诊断能力有限的问题, 提出了一种基于卷积神经网络(CNN)和门控循环单元(GRU)的轴承故障诊断方法。通过融合电流信号和振动信号的时域与频域特征进行故障分类, 采用CNN进行特征提取, 并利用GRU捕捉时序数据的长期依赖关系, 以提高模型的诊断能力。此外, 采用批量归一化(BN)方法优化训练过程, 防止梯度消失或爆炸。实验结果表明: 所提方法在不同故障状态下具有较高的分类精度, 尤其在正常运行和内圈故障状态下, 精度和召回率均接近1, 表明该方法在多模态数据融合的故障诊断任务中具有较强的鲁棒性; 与CNN、ResNet、MS-CNN的对比实验结果, 也证明了本文所提方法在变转速工况的故障诊断中具有更高的准确性。

关键词: 故障诊断; 卷积神经网络; 数据融合; 门控循环单元; 滚动轴承

中图分类号: TH133; TP18 **文献标志码:** A **文章编号:** 1673-9833(2025)05-0016-08

引文格式: 吴昊天, 彭泽宇, 刘涛, 等. 基于多模态数据融合的轴承故障诊断方法[J]. 湖南工业大学学报, 2025, 39(5): 16-23.

A Bearing Fault Diagnosis Method Based on Multi-Modal Data Fusion

WU Haotian^{1,2}, PENG Zeyu^{1,2}, LIU Tao^{1,2}, YAO Qishui^{1,2}

(1. School of Mechanical Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China;
2. High Performance Rolling Bearing Technology, Key Laboratory of Hunan Provincial Universities, Zhuzhou Hunan 412007, China)

Abstract: In view of such flaws as insufficient precision and limited diagnostic ability under complex fault modes found in bearing fault diagnosis of traditional single mode signal processing, a bearing fault diagnosis method, which is based on convolutional neural network (CNN) and gated recurrent unit (GRU), has thus been proposed. With the time-domain and frequency-domain features of current signals and vibration signals integrated for fault classification, CNN is used for feature extraction, and GRU for capturing the long-term dependencies of time-series data, thus improving the diagnostic ability of the model. In addition, an optimization of the training process and prevent gradient vanishing or exploding can be achieved by adopting batch normalization (BN) method. Experimental results show that the proposed method is characterized with a high classification accuracy in different fault states, especially in normal operation and inner ring fault states, with its accuracy and recall rates close to 1, indicating that the proposed method possesses a strong robustness in the fault diagnosis task of multimodal data fusion. The comparative experimental results with CNN, ResNet, and MS-CNN also demonstrate that the proposed method has a higher accuracy in fault diagnosis under

收稿日期: 2025-02-10

基金项目: 国家自然科学基金资助项目(52305465)

作者简介: 吴昊天, 男, 湖南工业大学硕士生, 主要研究方向为运载装备关键件设计理论及应用, E-mail: 1531943602@qq.com

通信作者: 姚齐水, 男, 湖南工业大学教授, 博士, 主要研究方向为机构学与机械动力学, 机械零部件安全服役科学,
E-mail: yaoqishui@126.com

variable speed conditions.

Keywords: fault diagnosis; convolutional neural network; data fusion; gated recurrent unit; rolling bearing

1 研究背景

在现代工业系统中,轴承是机械设备中不可缺少的零件,轴承故障不仅会直接影响设备的运行效率和安全性,还可能引发更为严重的设备损坏,导致生产中中断和高昂的维修成本^[1]。因此,轴承故障诊断已成为工业生产中的一个关键问题^[2]。

现有的轴承故障诊断方法大致可分为机器学习、深度学习和迁移学习方法^[3]。基于机器学习的故障诊断方法通常包括数据采集、特征提取以及故障分类等步骤^[4]。为了获得更好的故障诊断准确率,研究人员在基础的机器学习方法上进行创新。如 Yu X. 等^[5]采用经验模态分解法,并结合 k -means 方法和标准差选择了最敏感的特征。Mao W. T. 等^[6]提出了基于结构特征选择的轴承故障诊断方法,并引入群体识别矩阵进行特征选择,通过支持向量机进行故障诊断。虽然这些方法能够有效地提取轴承的部分特征信息,但由于依赖于人工特征选择和信号预处理,其鲁棒性和适应性较差,尤其在面对复杂的故障模式时,往往难以满足故障诊断的高精度需求^[7]。

随着深度学习技术的不断发展,特别是卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN)等神经网络模型的应用,轴承故障诊断方法逐渐从传统的特征工程向自动特征学习方向转变^[8]。CNN 通过多层卷积、池化操作,能够有效地降低数据维度,提高特征提取的准确性,尤其在面对大规模数据时,能够显著提升模型的分类能力^[9]。Tian Y. L. 等^[10]提出了一种用于实时检测滚子轴承损伤的深度卷积神经网络,使用 softmax 函数进行最终的故障预测。刘涛等^[11]提出基于多尺度注意力机制(convolutional block attention module, CBAM)和 CNN 的涡旋压缩机故障诊断方法,通过调整权重值的方式提取重要的故障特征。然而, CNN 主要用于处理局部信息,对于处理具有时序依赖性的信号数据存在一定的局限性。

RNN 核心的循环结构可以对序列数据进行逐步更新,保留上下文信息,因此其主要用于处理动态数据和时序数据^[12]。S. Hochreiter 等^[13]在 1997 年提出了 RNN 的一种对于训练过程优化的变体——长短期记忆网络(long short-term memory, LSTM)。LSTM 在保留了 RNN 对序列结构数据进行建模以及

时间序列建模优势的同时,优化了 RNN 在训练时已经出现的梯度消失和爆炸现象^[14]。

其后,门控循环单元(gate recurrent unit, GRU)作为一种改进的 LSTM 结构被提出^[15],其通过引入更新门和重置门,能够更有效地控制信息流的传递。在多模态数据的处理上,GRU 能够捕捉信号随时间变化的动态特征,为故障诊断提供更为丰富的时序信息。

由于 CNN 和 RNN 在一定程度上可以互补,因而越来越多的学者将两者结合起来,进行轴承故障诊断研究。Chen X. H. 等^[16]使用两个不同核大小的卷积神经网络自动提取原始信号的信号特征,并使用长短期记忆根据学习特征识别故障类型。王英杰等^[17]使用双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)提取轴承运转过程中的时序特征,同时利用 CNN 提取显著特征进行故障判别与分类。但是,现阶段的研究大部分是只针对单一信号进行了分析,而忽略了其他信号中存在的故障信息。

基于上述背景,本文提出了一种基于 CNN 和 GRU 的多模态数据融合故障诊断方法。首先通过并行双分支通道,同时对振动信号和电流信号进行处理,然后进行特征融合。一方面,本文方法通过 CNN 与 GRU 方法自动提取特征,克服了传统方法人工特征选择的局限性;另一方面,通过多模态数据融合,提高了复杂工况下的故障诊断精确度。

2 基本原理

2.1 CNN 结构

基于 CNN 的特征提取,能通过卷积层和池化层降低输入数据的维度,其基本架构如图 1 所示。




图 1 典型卷积神经网络结构图

Fig. 1 Typical convolutional neural network structure diagram

图 1 所示的 CNN 结构中, 卷积层通过滑动卷积核在输入数据上进行局部特征的提取, 能够捕捉到局部的空间特征:

$$y_j^l = f\left(\sum_i w_{ij}^l x_i^{l-1} + b_j^l\right). \quad (1)$$

式中: b 为偏置矩阵; w 为权值矩阵; y 为卷积特征; x 为输入特征; f 为激活函数; l 为层数; i 为特征个数; j 为输出特征编号。

由于本文输入的数据相对较为复杂, 所以使用 $PReLU(x)$ 激活函数。与传统的 $PReLU(x)$ 激活函数不同, 本文选取的 $PReLU(x)$ 激活函数允许在训练过程中学习负半轴的斜率, 这使得模型在处理负输入时更加灵活。

$$PReLU(x) = \begin{cases} x, & x > 0; \\ \alpha x, & x \leq 0. \end{cases} \quad (2)$$

式中 α 为可学习的参数, 通常为一个很小的正数。

池化层主要进行下采样, 在保证特征尺度不变性的前提下减小数据量, 其运算表示如下:

$$x_j^{l'} = f\left(w_j^{l'-1} \text{down}\left(x_j^{l-1} + b_j^{l'}\right)\right). \quad (3)$$

式中 down 为降采样函数。

全连接层使前后两层神经元全部相连, 有助于特征学习, 可表示如下:

$$y = f(w_i x_i + b_i). \quad (4)$$

2.2 门控循环单元

GRU 是一种改进的循环神经网络结构, 通过引入门控机制来控制信息的流动, 从而更有效地捕捉序列中的长期依赖关系。同时, GRU 相较于 LSTM, 其结构更简单, 只有更新门和重置门, 减少了计算复杂度, 其具体结构如图 2 所示。




图 2 门控循环单元结构图

Fig. 2 Gated recurrent unit structure diagram

更新门用于对前一时刻的状态信息与当前时刻的状态融入程度进行调控, 其值越大, 融入越多。更新门调控的具体过程如下:

$$z_t = \sigma(w_z \cdot [h_{t-1}, x_t]). \quad (5)$$

式中: σ 为 sigmoid 激活函数; h_{t-1} 为时间 $t-1$ 的隐藏状态; z_t 为 t 时刻的更新门向量。

重置门与更新门的功能类似, 主要用于控制前一状态有多少历史信息写入当前候选集 r_t , 具体的控制过程如下:

$$r_t = \sigma(w_r \cdot [h_{t-1}, x_t]). \quad (6)$$

将重置门与上一步隐藏状态进行计算, 得到当前时间步的候选状态 $\tilde{h}_t$:

$$\tilde{h}_t = \tanh(w_h \cdot [r_t \cdot h_{t-1}, x_t]). \quad (7)$$

式中 $\tanh$ 为双曲正切激活函数。

最后, 结合更新门的结果, 确定新的隐藏状态在多大程度上来自旧的隐藏状态和新的候选状态:

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t. \quad (8)$$

2.3 批量归一化

批量归一化 (BN), 主要通过将数据进行归一化处理以使数据在迭代中服从均值为 0、方差为 1 的正态分布, 同时引入学习参数, 使得网络可以加快训练的收敛速度。BN 方法表示如下:

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i; \quad (9)$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2; \quad (10)$$

$$x_{il} = (x_i - \mu_B) / \sqrt{\sigma_B^2 + \epsilon}; \quad (11)$$

$$y_i = \gamma \bar{x}_i + \beta \equiv BN_{\gamma, \beta}(x_i). \quad (12)$$

式中: σ_B^2 和 μ_B 分别为每批次数据的方差和均值; x_{il} 为每批次数据经过标准化处理后的数据; ϵ 为常数项; γ 和 β 为可学习参数; m 为当前批次中的样本数量; B 为批次。

2.4 网络结构

课题组针对多模态数据融合进行网络构建, 将电流与振动信号同步输入神经网络, 进行特征提取融合, 具体步骤如图 3 所示。




图 3 网络结构图

Fig. 3 Network structure diagram

首先, 构建两个通道, 对振动信号和电流信号同

步处理,经过两个卷积层和归一化层的处理后,提取其中特征信息。加入随机丢弃层防止网络过拟合。

其次,对每个通道的输出进行并行处理,分别使用GRU以及全局池化层进行处理。GRU能够有效捕捉输入数据中的时间依赖性,同时学习信号随时间变化的动态特征。全局池化层将卷积层的输出特征图压缩为固定大小的特征向量,提取全局特征,通过计算每个特征通道的平均值,减少了特征的维度,同时保留了重要信息。

将每个分支并行处理的数据进行合并,再将两个分支合并后的数据再次合并,构成包含两个分支全部特征信息的综合信号,再输入最后的全连接层网络中进行分类操作,也即故障诊断的过程。

3 信号特征处理

3.1 特征提取

3.1.1 时域特征提取

时域特征提取主要计算一些统计指标,包括有量纲指标以及无量纲指标,是对振动信号较为直接的特征提取方式。设振动信号的序列为 x_i ,常用的时域特征计算公式如下:

1) 均值 (mean) μ_{mean} ,

$$\mu_{\text{mean}} = \frac{1}{N} \sum_{i=1}^N x_i; \quad (13)$$

式中 N 为样本总数。

2) 均方根值 (root mean square, RMS) μ_{rms} ,

$$\mu_{\text{rms}} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}; \quad (14)$$

3) 标准差 (standard deviation) σ_{std} ,

$$\sigma_{\text{std}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu_{\text{mean}})^2}; \quad (15)$$

4) 偏度 (skewness) d_{skew} ,

$$d_{\text{skew}} = \frac{1}{N} \sum_{i=1}^N (x_i - \mu_{\text{mean}})^3 / \sigma_{\text{std}}^3; \quad (16)$$

5) 峰度 (kurtosis) d_{kurt} ,

$$d_{\text{kurt}} = \frac{1}{N} \sum_{i=1}^N (x_i - \mu_{\text{mean}})^4 / \sigma_{\text{std}}^4 - 3; \quad (17)$$

6) 峰值 (peak) p ,

$$p = \max(|x_i|); \quad (18)$$

7) 峰值因子 (crest factor) C ,

$$C = p / \mu_{\text{rms}}. \quad (19)$$

以上的7个指标中,偏度、峰度、峰值因子为无量纲指标,而绝对均值、均方根、标准差、峰值为有量纲指标。

3.1.2 频域特征提取

仅通过对信号的时域特征进行提取,往往难以充分反映信号中的复杂状态特性,尤其是在有周期性、冲击性或多频率成分的情况下。

频域特征指标,是描述信号频域分布的统计量,其能够有效地表征信号的频率成分以及其能量的分布特性,具体包括:

1) 频率均值 (frequency mean) f_m ,

$$f_m = \sum_{j=1}^M f_j \cdot P(f_j) / \sum_{j=1}^M P(f_j); \quad (20)$$

式中: M 为不同频率值的总数; P 为频率 f_j 的概率。

2) 频率标准差 (frequency standard deviation) f_s ,

$$f_s = \sqrt{\left[\sum_{j=1}^M (f_j - f_m)^2 \cdot P(f_j) \right] / \sum_{j=1}^M P(f_j)}; \quad (21)$$

3) 小波系数标准差 (wavelet features) σ_{wf} ,

$$\sigma_{\text{wf}} = [\sigma(c_1), \sigma(c_2), \dots, \sigma(c_L)]; \quad (22)$$

式中: $\sigma(c_k)$ 为第 k 层小波系数的标准差,且

$$\sigma(c_k) = \sqrt{\frac{1}{N_k} \sum_{i=1}^{N_k} (c_k(i) - \mu_k)^2}; \quad (23)$$

4) 包络谱均值 (envelope mean) μ_{em} ,

$$\mu_{\text{em}} = \frac{1}{N} \sum_{i=1}^N |x_a(i)|; \quad (24)$$

式中: $x_a(i)$ 为解析信号的幅值(包络)。

5) 包络谱标准差 (envelope standard deviation) σ_{es} ,

$$\sigma_{\text{es}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (|x_a(i)| - \mu_{\text{em}})^2}.$$

3.2 特征值分布分析

针对振动信号的4种运行工况,对其概率分布密度进行分析,以探讨每个特征在故障分类中的区分能力,所得结果见图4,其中class 0~3分别代表正常运行、内圈故障、外圈故障、滚子故障,横坐标为特征取值,纵坐标为概率密度,其线下面积之和为1。

对图4所示结果进行分析,可以看出在时域特征中,均方根和标准差显示出良好的故障识别能力,特别是在正常状态与故障状态的区分上。

在频域特征方面,频率均值和频率标准差在不同故障类别间展现出不同的分布模式,尤其是在内圈故障中的分布特征与其他类别的有明显区别。包络特征的范围为0~3.5,显示出对故障状态的敏感性良好。同时,小波特征也在不同尺度上提供了互补的故障信息,尤其是在较低尺度上表现出更好的类别区分能力。




图4 特征概率分布图

Fig. 4 Distribution of feature probability

通过分析可以得出,特征信号能够在一定程度上表征轴承的运行情况,所以将特征信号作为输入,输入CNN网络,可以进一步学习提取深层特征,增加模型的诊断准确率。

4 实验与分析

本节将通过具体数据集进行实验,同时与常用模型进行对比实验,以验证本文方法性能。

4.1 数据集描述

实验数据集由韩国科学技术院(KAIST)的轴承测试台^[18]收集。如图5所示,测试台主要由1个制动器、2个轴承、1个质量轮、1个变速箱、1个扭矩计和1个电机组成。使用4个加速度计(PCB352C34)在2个轴承座A和B的x方向和y方向上测量振动数据。使用3个CT电流传感器(Hioki CT6700)测量电流数据。振动数据由西门子SCADAS Mobile

5PM50 采集, 采样频率为 25.6 kHz; 电流数据由 NI9775 采集, 采样频率为 100 kHz。该数据集以恒定速度收集了 600 s, 在不同速度条件 ($680 \text{ r}\cdot\text{min}^{-1}$ 和 $2\,460 \text{ r}\cdot\text{min}^{-1}$) 下收集了 2 100 s。数据集中包含 4 种工况 (正常运行、内圈故障、外圈故障和滚子故障) 的电流、振动和转速信号, 本文主要使用电流与振动信号作为输入信号, 部分数据如图 6、7 所示。






图5 KAIST 轴承测试台


Fig. 5 KAIST bearing test stand




a) normal condition-8 192 points



b) inner condition-8 192 points




c) outer condition-8 192 points




d) ball condition-8 192 points

图6 振动信号图


Fig. 6 Vibration signal diagram




a) normal condition-8 192 points



b) inner condition-8 192 points



c) outer condition-8 192 points



d) ball condition-8 192 points

图7 电流信号图

Fig. 7 Current signal diagram

4.2 参数设置

在 CNN-GRU 模型中, 将卷积核的大小均设置为 3×3 , 步长均设置为 1×1 。卷积层的卷积核个数分别为 64 和 128。GRU 层的单元数为 128。全连接层的输出分别为 256, 128, 4。将 Dropout 方法随机丢弃的概率设置为 0.3 (在卷积层后) 和 0.4 (在合并后的特征向量后)。

本实验基于 Tensorflow 2.16.1 框架和 Python 编程语言构建网络模型。笔者采用的 GPU 为 NVIDIA GeForce GTX1050 Ti, CPU 为 Intel(R)Core(TM) i7-8750H。

4.3 实验结果

对故障分类结果进行统计, 可以得到如图 8 所示的混淆矩阵以及如表 1 所示的统计结果。




图 8 故障诊断混淆矩阵

Fig. 8 Confusion matrix for fault diagnosis

表 1 故障诊断评价指标与结果

Table 1 Fault diagnosis evaluation indicators

类别	精确率	召回率	F_1 -score
正常运行	0.93	0.99	0.96
内圈故障	0.98	1.00	0.99
外圈故障	0.97	0.89	0.93
滚子故障	0.93	0.92	0.92

从表 1 中可以看出, 模型对于正常状态和内圈故障的检测效果十分高, 召回率为 0.99 和 1, 也就意味着几乎没有漏检。相对而言, 对于外圈、滚子的故障分类较差, 但其综合得分也都在 0.92 以上, 这说明模型在进行多模态数据融合故障检测时, 可以取得不错的效果。

如果对分类结果进行调整, 只考虑故障情况与正常运行情况的话, 可以得到外圈故障情况下与滚子故障情况下的召回率均可以达到 0.96, 这也就意味着所建立的模型在判断故障情况方面可以达到综合 0.97 的故障诊断率, 只是在故障分类准确度方面还有进一步提高的空间。

4.4 对比实验

为了更好地验证本文所提方法在复杂工况下

的故障诊断准确率, 选取几种较为常用的方法, 如: CNN、ResNet、MS-CNN 进行对比实验, 所得结果如图 9 所示。




图 9 对比实验混淆矩阵

Fig. 9 Confusion matrix of comparison experiments

将本文方法与图 9 所示结果进行对比, 可以发现, 虽然 3 种诊断方法在正常运行与内圈故障的区分中得到了很好的结果, 但在外圈与滚子故障中的表现不太好, 而本文方法在所有情况中均得到了较好的故障诊断精度。这充分说明本文方法在变转速工况的故障诊断中具有更高的准确性。

5 结语

本文针对传统单一模态信号处理在轴承故障诊断中面临的精度不足和复杂故障模式下诊断能力有限的问题, 提出了一种基于 CNN-GRU 的多模态数据融合故障诊断方法。

首先, 通过对电流信号与振动信号进行特征提取作为输入数据, 通过构建的并行 CNN 网络对两种模态的输入进行处理。然后, 经过 GRU 与全连接层的分支结构, 捕捉时间依赖性的同时降低维度并保存重要特征。其次, 将两种信号处理后的特征进行融合, 形成更进一步的诊断特征, 以此提高复杂工况下的故障诊断准确率。试验结果表明, 本文方法在实验数据集上取得了良好的诊断结果。

与传统方法进行对比发现, 相较于 CNN、ResNet 以及 MS-CNN 方法, 本文方法在诊断精确率方面取得了明显优势。

参考文献:

- [1] JU Y M, TIAN X, LIU H J, et al. Fault Detection of Networked Dynamical Systems: A Survey of Trends and Techniques[J]. International Journal of Systems Science, 2021, 52(16): 3390–3409.
- [2] CHEN X H, YANG R, XUE Y H, et al. Deep Transfer Learning for Bearing Fault Diagnosis: A Systematic Review Since 2016[J]. IEEE Transactions on Instrumentation Measurement, 2023, 72: 3244237.
- [3] LEI Y G, YANG B, JIANG X W, et al. Applications of Machine Learning to Machine Fault Diagnosis: A Review and Roadmap[J]. Mechanical Systems and Signal Processing, 2020, 138: 106587.
- [4] LI W, NIU Y G, CAO Z R. Event-Triggered Sliding Mode Control for Multi-Agent Systems Subject to Channel Fading[J]. International Journal of Systems Science, 2022, 53(6): 1233–1244.
- [5] YU X, DONG F, DING E J, et al. Rolling Bearing Fault Diagnosis Using Modified LFDA and EMD with Sensitive Feature Selection[J]. IEEE Access, 2018, 6: 3715–3730.
- [6] MAO W T, WANG L Y, FENG N Q. A New Fault Diagnosis Method of Bearings Based on Structural Feature Selection[J]. Electronics, 2019, 8(12): 1406.
- [7] 伍章俊, 许仁礼, 方刚, 等. 一种面向旋转机械多传感器故障诊断的模态融合深度聚类方法[J]. 电子与信息学报, 2025, 47(1): 244–259.
- WU Zhangjun, XU Renli, FANG Gang, et al. A Modal Fusion Deep Clustering Method for Multi-Sensor Fault Diagnosis of Rotating Machinery[J]. Journal of Electronics & Information Technology, 2025, 47(1): 244–259.
- [8] 沈涛, 李舜酩. 针对滚动轴承故障的批标准化 CNN-LSTM 诊断方法[J]. 计算机集成制造系统, 2022, 28(12): 3944–3953.
- SHEN Tao, LI Shunming. CNN-LSTM Method with Batch Normalization for Rolling Bearing Fault Diagnosis[J]. Computer Integrated Manufacturing Systems, 2022, 28(12): 3944–3953.
- [9] 陈永展, 曲建岭, 王小飞, 等. 时序记忆增强的 CNN-LSTM 滚动轴承故障诊断方法[J]. 噪声与振动控制, 2025, 45(1): 105–111.
- CHEN Yongzhan, QU Jianling, WANG Xiaofei, et al. Rolling Bearing Fault Diagnosis Based on CNN-LSTM with Time Sequential Memory Enhancement[J]. Noise and Vibration Control, 2025, 45(1): 105–111.
- [10] TIAN Y L, LIU X Y. A Deep Adaptive Learning Method for Rolling Bearing Fault Diagnosis Using Immunity[J]. Tsinghua Science and Technology, 2019, 24(6): 750–762.
- [11] 刘涛, 麻德权. 基于 CBAM-CNN 的涡旋压缩机故障诊断[J]. 振动·测试与诊断, 2024, 44(5): 900–906, 1036.
- LIU Tao, MA Dequan. Fault Diagnosis of Scroll Compressor Based on Improved CBAM-CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(5): 900–906, 1036.
- [12] LECUN Y, BENGIO Y, HINTON G. Deep Learning[J]. Nature, 2015, 521: 436–444.
- [13] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8): 1735–1780.
- [14] GRAVES A, JAITLEY N, MOHAMED A R. Hybrid Speech Recognition with Deep Bidirectional LSTM[C]//2013 IEEE Workshop on Automatic Speech Recognition and Understanding. Olomouc, Czech Republic: IEEE, 2013: 273–278.
- [15] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(增刊2): 1–6, 26.
- YANG Li, WU Yuqian, WANG Junli, et al. Research on Recurrent Neural Network[J]. Journal of Computer Applications, 2018, 38(S2): 1–6, 26.
- [16] CHEN X H, ZHANG B K, GAO D. Bearing Fault Diagnosis Base on Multi-Scale CNN and LSTM Model[J]. Journal of Intelligent Manufacturing, 2021, 32(4): 971–987.
- [17] 王英杰, 朱景建, 龚智强, 等. 基于 DAE-BiLSTM-CNN 的滚动轴承故障诊断方法[J]. 机械设计, 2024, 41(11): 123–129.
- WANG Yingjie, ZHU Jingjian, GONG Zhiqiang, et al. Method of Fault Diagnosis for Rolling Bearings Based on DAE-BiLSTM-CNN[J]. Journal of Machine Design, 2024, 41(11): 123–129.
- [18] JUNG W, KIM S H, YUN S H, et al. Vibration, Acoustic, Temperature, and Motor Current Dataset of Rotating Machine Under Varying Operating Conditions for Fault Diagnosis[J]. Data in Brief, 2023, 48: 109049.

(责任编辑: 廖友媛)