

基于多通道并行 LSTM - CNN 的 旋转机械故障诊断

周旭涛¹, 杨泽昀², 吴文开³

(1. 中铁工程机械研究设计院有限公司, 湖北 武汉 430066;

2. 西安电子科技大学杭州研究院, 浙江 杭州 311231;

3. 中国船舶及海洋工程设计研究院, 上海 200011)

摘要: 针对旋转机械故障诊断信息特征提取不完整而造成的故障误判问题, 提出一种以多通道信号作为输入、长短期记忆网络和卷积神经网络并行的旋转机械故障诊断模型。该模型以实际监测的多通道振动信号作为输入, 分别捕获振动信号中的时间序列特征和局部空间特征, 从而完成旋转机械故障诊断。采用凯斯西储大学轴承中心实验数据进行验证, 实验结果表明, 所提出的故障诊断模型训练收敛速度快、收敛精度高, 且故障诊断准确率达 99.99% 以上。

关键词: 长短期记忆网络; 卷积神经网络; 旋转机械; 滚动轴承; 故障诊断

中图分类号: TH133.3; TH17

文章编号: 1000-0682(2025)02-0092-07

文献标识码: A

DOI: 10.19950/j.cnki.CN61-1121/TH.2025.02.017

Fault diagnosis of rotating machinery based on multi-channel parallel LSTM - CNN

ZHUO Xutao¹, YANG Zeyun², WU Wenkai³

(1. China Railway Engineering Machinery Research & Design Institute Co., Ltd., Hubei Wuhan 430066, China;

2. Hangzhou Institute of Technology, Xidian University, Zhejiang Hangzhou 311231, China;

3. Marine Design & Research Institute of China, Shanghai 200011, China)

Abstract: Aiming at the problem of fault misjudgment caused by incomplete features extraction of rotating machinery fault diagnosis information, a rotating machinery fault diagnosis model based on multi-channel signal as input, Long Short-Term Memory (LSTM) network and Convolutional Neural Network (CNN) is proposed. The model takes the multi-channel vibration signal as the input, and captures the time series characteristics and local spatial characteristics of the vibration signal, so as to complete the fault diagnosis of rotating machinery. The experimental data from the bearing center of Case Western Reserve University are used to verify the proposed fault diagnosis model. The experimental results show that the proposed fault diagnosis model has fast convergence speed and high convergence accuracy, and the accuracy of fault diagnosis is more than 99.99%.

Keywords: Long Short-Term Memory; convolutional neural network; rotating machinery; rolling bearing; fault diagnosis

0 引言

大型工程机械是基础建设、资源开发、交通运输

等领域的重要工程装备, 其中旋转类机械是大型工程机械的重要组成部分, 该类设备通常以滚动轴承、齿轮等作为机械运转的核心部件。据相关统计表明, 约 30% 的旋转类机械故障由滚动轴承故障引起^[1], 并且旋转类机械通常处于高负荷连续作业工况, 一旦发生故障可能会导致重大工程事故, 甚至会造成严重的人员伤亡, 因此对旋转机械开展故障诊断研究具有重要意义。

收稿日期: 2024-07-23

第一作者: 周旭涛(1988—), 男, 汉族, 山东荣成人, 硕士, 工程师, 研究方向为工程机械智能监测及安全评估技术。

E-mail: zhouxutao@163.com

近年来,机械故障诊断技术得到大力发展,机械故障诊断由过去的人工专家诊断模式逐渐向智能诊断模式转变^[2],其中以基于机器学习的故障诊断方法最为流行,这类方法的主要思想为通过提取机械设备运行时振动信号中能反映机械运行状态的特征,采用特征分类器将运行状态分类为正常状态或者不同的故障状态,从而实现机械故障诊断。He 等^[3]构建基于一维卷积神经网络的故障诊断模型,实现轴承故障诊断。Lei 等^[4]提出基于长短期记忆网络的故障诊断模型,对风电机组轴承故障进行诊断。此外,部分学者们^[5-7]为充分提取振动信号中的故障信息,构建基于不同机器学习方法组合的故障诊断模型以实现机械故障诊断。虽然这些方法在机械故障诊断方面已取得良好的效果,但仍然存在片面地利用振动信号的时间或空间维度特征,导致故障诊断信息特征时空不完备的问题,同时在过往的研究中,对旋转类机械故障进行故障诊断时,主要通过单通道输入信号的特征进行分析^[8],缺乏不同通道信号数据的交互联动,进一步加剧故障特征信息提取不完备的问题,导致故障诊断的不准确,甚至发生故障误判。

针对旋转类机械故障诊断信息特征提取不完备而造成的故障误判问题,通过在旋转类机械不同位置布置多个传感器以提取多通道振动信号的时空特征信息,该文提出了一种以多通道振动加速度信号作为输入、长短期记忆网络和卷积神经网络并行的旋转机械故障诊断模型,对该模型的基本原理及模型结构进行了说明,并通过凯斯西储大学轴承中心 4 种电机负荷工况下 10 种故障类型的实验数据验证了提出的故障诊断模型的有效性,从而为工程机械运营、维护提供技术支撑。

1 神经网络模型

1.1 长短期记忆网络 (LSTM)

长短期记忆网络 (Long Short - Term Memory, LSTM) 作为一种用于时间序列预测及特征提取的算法,是对循环神经网络 (Recurrent Neural Network, RNN) 的改进。RNN 在模型参数优化的梯度反向传播环节中容易出现梯度消失或梯度爆炸的问题^[5],导致长距离的信息丢失,进而导致预测及特征提取精度降低,而 LSTM 通过引入门机制,设置输入门、记忆单元、遗忘门和输出门,实现历史信息的更新和保留,增强了对长时间序列数据的记忆处理能力,解决了 RNN 梯度消失及梯度爆炸的问题。由于 LSTM

能够学习数据中的长期依赖关系,可用于提取时间序列数据的特征^[4],而设备运行时振动信号为具有反映设备状态特征的长时间序列数据,因此可将 LSTM 用于提取振动信号中的时间序列特征,以对设备进行故障诊断。LSTM 单元结构如图 1 所示。

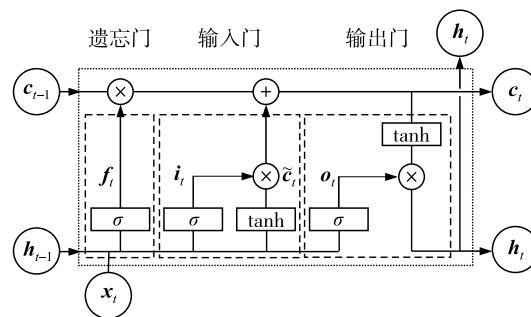


图 1 长短期记忆网络单元结构图

LSTM 单元结构包括三部分:(1)输入门,控制输入的信息是否被保留到单元状态;(2)遗忘门,决定上一个单元状态有多少保留在当前时刻;(3)输出门,控制单元状态有多少输出。输入门和输出门均由一个 Sigmoid 函数和一个 Tanh 函数组成,其中 Sigmoid 函数的输出在 $[0, 1]$ 之间,表示需要保留/输出多少信息;Tanh 函数的输出在 $[-1, 1]$ 之间,表示输入/输出的信息。遗忘门由一个 Sigmoid 函数和前一时刻的记忆状态 h_{t-1} 组成,其中 Sigmoid 函数的输出在 $[0, 1]$ 之间,表示需要保留多少前一时刻的记忆状态,具体公式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \otimes \tanh(c_t) \quad (6)$$

式中: f_t 和 i_t 分别为遗忘门和输入门的状态向量; $\sigma(\cdot)$ 为 Sigmoid 函数; h_t 为 t 时刻的输出; \tilde{c}_t 为候选元素状态; $\tanh(\cdot)$ 为 Tanh 激活函数; c_t 为 t 时刻的单元状态向量; \otimes 为元素相乘; W_f , W_i , W_c , W_o 分别为遗忘门、输入门、单元状态和输出门的权重; b_f , b_i , b_c 和 b_o 分别为遗忘门、输入门、单元状态和输出门的偏置项。

1.2 卷积神经网络 (CNN)

卷积神经网络 (Convolutional Neural Network, CNN) 由输入层、卷积层、池化层、全连接层以及输出层组成,提取输入数据中局部空间特征,并对特征进行分类以完成故障诊断,其框架如图 2 所示。




图2 卷积神经网络框架图

(1) 输入层在故障诊断模型中为输入待诊断数据,在该文中指采集的振动信号。

(2) 卷积层用于对输入层的待诊断振动信号进行卷积运算,以实现局部空间特征提取,对于第 t 层第 j 个输出节点的卷积运算结果 x_j^t 的计算公式为:

$$x_j^t = f\left(\sum_{i=1}^k w_{ij} * x_{ki+j}^{t-1} + \beta_j^t\right) \quad (7)$$

式中: $f(\cdot)$ 为 ReLU 激活函数; w_{ij} 为 i 号卷积核; k 为卷积核个数; β_j^t 为第 t 层第 j 个输出节点的偏置项; $*$ 为卷积运算。

(3) 池化层用于降低提取特征的维度,从而缩小故障诊断模型的大小以提高计算速度,并保留振动信号中的重要特征。常见的池化层为最大池化和平均池化,其中最大池化通过选择局部区域中的最大值作为输出值,从而保留最显著的特征而得到广泛应用^[9]。对于第 t 层第 i 个特征中第 j 个神经元经最大池化操作的输出结果 $p_j^{(i)}$ 的计算公式为:

$$p_j^{(i)} = \max_r [a_j^{(i)}], (j-1)W+1 \leq r \leq jW \quad (8)$$

式中: W 为池化区域宽度; $a_j^{(i)}$ 为第 t 层第 i 个特征中第 j 个神经元激活值。

(4) 全连接层用于将池化的特征数据连接成特征集,其所有神经元节点都与上一层的输出相连接,全连接层的输出 h' 的表达式为:

$$h' = f(w' h^{t-1} + \rho') \quad (9)$$

式中: $f(\cdot)$ 为激活函数,应用于故障诊断时,通常为 Softmax 激活函数; w' 为权重; h^{t-1} 为上一层的输出; ρ' 为偏置项。

(5) 输出层在故障诊断模型中通常采用 Softmax 分类器函数将全连接层的输出特征集映射为范围在 $(0,1)$ 的实数(即故障分类的概率),从而完成故障诊断。

2 多通道并行 LSTM - CNN 故障诊断模型

2.1 故障诊断模型结构

提出的多通道并行 LSTM - CNN 旋转机械故障诊断模型如图 3 所示。该模型以多通道振动信号数据作为输入,分别采用 LSTM 和 CNN 并行提取振动信号中的时间序列特征和局部空间特征,通过全连接层与 Softmax 激活函数对故障进行分类,从而实现旋转机械的故障类型的异常诊断与分类。其中,长短期记忆网络由多个 LSTM 单元组成;卷积神经网络由多个卷积层组成,每个卷积层包含卷积核、ReLU 激活函数以及最大池化层。




图3 多通道并行 LSTM - CNN 故障诊断模型结构示意图

单独采用 LSTM 或 CNN 作为故障诊断模型时,提取的振动信号特征不全面,缺少时空特征信息的联动,不足以充分反映机械设备的真实运行状态,该文采用 LSTM 与 CNN 结合的方式进行异常诊断,其中 LSTM 善于捕捉振动信号中的时间序列特征,

CNN 善于捕捉振动信号中的局部空间特征,二者结合克服了各自单独作为故障诊断模型的不足,并行提取多通道振动信号本身及通道之间的时间序列特征和局部空间特征,能够更准确地对旋转机械进行故障诊断。

2.2 故障诊断模型训练

多通道并行 LSTM - CNN 故障诊断模型基于 Python 编程语言和 Pytorch 深度学习框架开发,采用交叉熵损失函数评估故障诊断模型在训练集、验证集及测试集上的性能,并使用 Adam 优化器对模型的参数进行优化,以最小化交叉熵损失函数。同时,在训练过程中为了减少过拟合现象、提高模型的泛化能力,在全连接层后连接 Dropout 层随机丢弃部分神经元输出以防止模型过拟合。

由于故障诊断模型需要大量数据进行训练,然而故障状态下的设备运行数据较为稀缺。因此对输入加速度信号进行滑动窗口采样以生成多个样本,并赋予对应的故障标签,从而使故障诊断模型具备充足的训练数据,以有效进行故障诊断。

3 实验数据故障诊断验证与分析

将提出的多通道并行 LSTM - CNN 故障诊断模型应用于凯斯西储大学滚动轴承数据中心的轴承实验数据集,以验证提出的模型在实际应用中的有效性。

3.1 滚动轴承故障实验数据介绍

滚动轴承故障实验系统如图 4 所示。实验对象为图 4 中驱动端的轴承,该轴承型号为 SKF6205 深沟球轴承,采用电火花加工驱动端滚动轴承以模拟不同的故障类型。实验同时在驱动端和风扇安装振动加速度传感器,数据采集采样频率为 12 kHz。实验共分为 10 组故障类型,分别为 1 组正常状态、3 组不同故障直径的滚动体故障、3 组不同故障直径的内圈故障以及 3 组不同故障直径的外圈故障,如表 1 所示。实验共采集了 4 种不同电机负载工况 (0HP、1HP、2HP 和 3HP) 下的数据,采用多通道并行 LSTM - CNN 故障诊断模型对不同电机负载工况下的 10 种故障类型进行诊断,以验证该故障诊断模型的有效性。




图 4 凯斯西储大学轴承实验

表 1 滚动轴承实验故障类型设置

序号	故障类型	代号	故障直径 (英寸)
1	正常状态	Normal	—
2	滚动体故障	BA007	0.007
3		BA014	0.014
4		BA021	0.021
5	内圈故障	IR007	0.007
6		IR014	0.014
7		IR021	0.021
8	外圈故障	OR007	0.007
9		OR014	0.014
10		OR021	0.021

3.2 实测振动数据预处理及可视化

将不同的电机负荷工况中采集到的驱动端和风扇端的振动信号按照 1024 个采集点的窗口长度进行滑动以生成多个样本,同时,为了便于神经网络的训练,对每段振动信号 $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$,按照式 (10) 进行极差 (Min - Max) 归一化处理,将原始数据缩放到 $[0, 1]$ 之间。以电机负荷 0HP 工况为例,取极差归一化处理完成后的 10 种故障类型的驱动端和风扇端的振动信号各一组,将其可视化如图 5 所示。

$$\mathbf{x}' = \frac{\mathbf{x} - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中: \mathbf{x}' 为极差归一化处理后的振动信号; x_{\min} 和 x_{\max} 分别为原始振动信号 \mathbf{x} 的最小值和最大值。

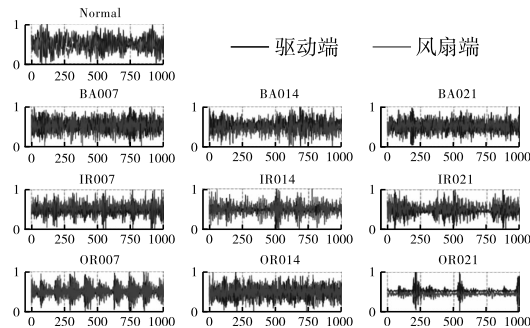


图 5 极差归一化振动信号

3.3 多通道并行 LSTM - CNN 故障诊断模型参数

提出的多通道并行 LSTM - CNN 旋转机械故障诊断模型由具备 2 层 LSTM 单元的长短期记忆网络和 5 层卷积层的卷积神经网络组成,关键参数分别如表 2 和表 3 所示。

表 2 长短期记忆网络参数

层数	层	单元个数
1	LSTM	32
2	LSTM	64

表 3 卷积神经网络参数

层数	层	内核大小	内核个数	步长
1	Conv1d	64	16	16
	MaxPool1d	2	—	2
2	Conv1d	3	32	1
	MaxPool1d	2	—	2
3	Conv1d	3	64	1
	MaxPool1d	2	—	2
4	Conv1d	3	64	1
	MaxPool1d	2	—	2
5	Conv1d	3	64	1
	MaxPool1d	2	—	2

3.4 故障诊断结果与分析

为了验证提出的多通道并行 LSTM - CNN 故障诊断模型的有效性,采用上述不同电机负荷工况的实验数据分别按照 6:2:2 的比例划分为测试集、验证集和测试集,通过训练集训练该故障诊断模型,并通过验证集验证该故障诊断模型的训练情况,最后采用测试集测试该故障诊断模型的有效性。故障诊断模型训练、验证及测试的计算机硬件环境均保持一致,运行计算机 CPU 为 12th Gen Intel(R) Core(TM) i5 - 12400,显卡为 NVIDIA GeForce GTX 1660 Super,内存为 32 GB。

3.4.1 损失函数曲线和诊断精度曲线

在故障诊断模型训练过程中,分别记录训练集、验证集和测试集测试训练模型的损失函数曲线和诊断精度曲线,其中,损失函数曲线反映故障诊断训练模型的收敛速度和收敛精度,诊断精度曲线反映故障诊断模型的诊断准确率,即诊断正确样本占总样本的比例。以电机负载 OHP 工况为例,将 LSTM、CNN 分别作为故障诊断模型与提出多通道并行 LSTM - CNN 故障诊断模型训练集、验证集和测试集的损失函数曲线和诊断精度曲线可视化如图 6 所示。





图 6 训练集、验证集和测试集的损失函数曲线和诊断精度曲线

由图 6 可见,采用 LSTM 作为故障诊断模型,200 轮训练结束后,其训练损失为 0.022 3,验证损失为 0.024 5,测试损失为 0.024 6,对应的训练精度为 98.02%,验证精度为 92.03%,测试精度为 91.46%,这表明仅采用 LSTM 提取振动信号中的时间序列特征进行故障诊断,虽然可以达到较高的精度,但其精度有限,并且迭代过程中,收敛速度较慢;采用 CNN 作为故障诊断模型,200 轮训练结束后,其训练损失为 0.024 3,验证损失为 0.024 8,测试损失为 0.024 7,相应的训练精度为 91.02%,验证精度为 90.13%,测试精度为 90.17%,采用 CNN 提取振动信号中的局部空间特征,精度较 LSTM 偏低且训练过程中仍存在大量波动;而多通道并行 LSTM - CNN 故障诊断模型在 200 轮训练后训练损失为 0.022 9,验证损失和测试损失均为 0.023 1,训练、验证和测试精度均达到 100%,且在迭代过程中收敛速度快且平稳,最终体现出极高的精度,这是由于 LSTM - CNN 结合了两者的提取时间序列特征和局部空间特征的能力,能够充分挖掘振动信号中反映出的故障特征,因此能获得较好的故障诊断模型。

3.4.2 故障诊断结果混淆矩阵

混淆矩阵多用于对故障诊断模型诊断结果的准确率及误判率进行分析^[10-12],其横坐标各标签对应

的每一列数据代表其他类别故障被诊断为该类故障的数量和百分比,纵坐标各标签对应的每一行数据代表该类故障被诊断为其他类故障的数量和百分比,则混淆矩阵中的对角线元素代表各标签对应的故障类型被正确诊断的数量和百分比。以电机负载工况 OHP 为例,将 LSTM、CNN 和多通道并行 LSTM - CNN 故障诊断模型对测试集中 10 种故障类型的诊断结果混淆矩阵可视化如图 7 所示。




图 7 测试集诊断结果混淆矩阵

通过图 7 对角线元素可见, LSTM 可以诊断出 10 种状态,但在每一种状态种存在不同程度的误判,表明仅采用时间序列特征不足以支撑故障诊断模型有效运行; CNN 对大部分状态诊断精度较高,但其将 OR021 误判为 OR007,表明仅采用局部空间特征,亦不足以支撑故障诊断模型的有效运行;而多通道并行 LSTM - CNN 故障诊断模型对试验中的 10 种滚动轴承状态诊断准确率均达到 100%,诊断结果准确,不存在误判。这表明多通道并行 LSTM - CNN 模型能够根据驱动端和风扇端的振动信号准确诊断出 10 种不同的故障状态。

3.5 不同故障诊断模型诊断精度对比

将 4 种电机负荷工况下的数据样本按照 6:2:2 的比例分割成训练集、验证集和测试集,每种电机负荷工况种采用相同的训练集训练获得 LSTM、CNN 和多通道并行 LSTM - CNN 模型,并采用测试集对比三种故障诊断模型的诊断精度,统计对比数据如表 4 所示。

表 4 测试集不同故障诊断模型的诊断结果对比

工况	诊断模型	测试样本总数	诊断正确总数	诊断精度 / %
OHP	LSTM	2085	1907	91.46
	CNN	2085	1880	90.17
	LSTM - CNN	2085	2085	100.00
1HP	LSTM	2459	2218	90.20
	CNN	2459	2275	92.52
	LSTM - CNN	2459	2458	99.99
2HP	LSTM	2459	2250	91.50
	CNN	2459	2234	90.85
	LSTM - CNN	2459	2459	100.00
3HP	LSTM	2464	2267	92.00
	CNN	2464	2304	93.51
	LSTM - CNN	2464	2464	100.00

通过表 4 可以看出,在不同电机负载工况中,多通道并行 LSTM - CNN 故障诊断模型,仅在电机负荷 1HP 工况中诊断精度为 99.99%,其他工况中均为 100%,表明其能够准确诊断出不同电机负荷工况下的 10 种不同的故障状态,且相比 LSTM 和 CNN 模型,四种电机负荷工况中,多通道并行 LSTM - CNN 故障诊断模型在诊断精度方面均提升 8% ~ 10%,表明其具有较好的诊断效果。

3.6 不同通道振动信号故障诊断结果对比

进一步,在其他设置不变的情况下将多通道并行 LSTM - CNN 故障诊断模型分别对单通道驱动端数据(DE)、单通道风扇端数据(FE)以及双通道驱

动端和风扇端数据(DE + FE)进行故障诊断的结果进行对比。统计测试集故障诊断数据如表 5 所示。

表 5 不同通道信号故障诊断结果对比

工况	通道信号	测试样本 总数	诊断正确 总数	诊断精度 /%
0HP	DE	2085	2047	98.18
	FE	2085	2036	97.65
	DE + FE	2085	2085	100.00
1HP	DE	2459	2413	98.13
	FE	2459	2390	97.19
	DE + FE	2459	2458	99.99
2HP	DE	2459	2423	98.54
	FE	2459	2393	97.32
	DE + FE	2459	2459	100.00
3HP	DE	2464	2422	98.30
	FE	2464	2391	97.04
	DE + FE	2464	2464	100.00

通过表 5 对比可见,每种电机负荷工况下,多通道并行 LSTM - CNN 故障诊断模型能够以单通道驱动端或风扇端振动信号作为输入并进行故障诊断,且诊断精度达 97% 以上,但存在少量误判;将单通道输入变为双通道输入时,各电机负载工况下的诊断精度提高 2% ~ 3%,且采用双通道输入时,仅在电机负荷 1HP 工况中诊断精度为 99.99%,其他工况均为 100%,故障诊断结果精准。采用多通道输入时,多通道并行 LSTM - CNN 故障诊断模型可提取的不同输入本身以及不同输入之间的特征更加丰富,因而可充分挖掘振动信号中隐含的机械设备的特征,从而准确识别故障。

4 结论

提出了一种多通道并行 LSTM - CNN 旋转机械故障诊断模型,对该模型的基本原理及网络结构进行了说明,并通过 4 种电机负荷下 10 种故障类型的实验数据验证了提出的多通道并行 LSTM - CNN 故障诊断模型的有效性,得到的主要结论如下:

(1)对比 LSTM 和 CNN 模型损失函数曲线、诊断精度曲线以及诊断结果混淆矩阵,提出的多通道并行 LSTM - CNN 故障诊断模型训练过程具有收敛速度快、收敛精度高,且诊断精度达到 100%,能够准确诊断出 10 种故障类型;

(2)对比不同电机负荷工况下三种模型的诊断

结果可见,提出的多通道并行 LSTM - CNN 故障诊断模型诊断精度均可达 99.99% 以上,比 LSTM 和 CNN 模型高 8% ~ 10%;

(3)对比不同通道振动信号下多通道并行 LSTM - CNN 故障诊断模型的诊断结果可见,在单通道输入下,提出的模型诊断精度达 97% 以上,双通道输入下,诊断精度达 99.99% 以上。

参考文献:

- [1] 胡梦婷,罗晨. 基于 MCNN - LSTM 和交叉熵损失函数的轴承故障诊断[J]. 制造技术与机床, 2024(9): 1 - 9.
- [2] 王婧,许志伟,刘文静,等. 滚动轴承健康智能监测和故障诊断机制研究综述[J]. 计算机科学与探索, 2024, 18(4): 878 - 898.
- [3] HE J, LI X, CHEN Y, et al. Deep transfer learning method based on 1D - CNN for bearing fault diagnosis[J]. Shock and Vibration, 2021(1): 1 - 16.
- [4] LEI J, LIU C, JIANG D. Fault diagnosis of wind turbine based on Long Short - Term memory networks[J]. Renewable Energy, 2019(133): 422 - 432.
- [5] 李聪,丁强,刘亚祥,等. 结合 LSTM 与 1DCNN 的冷水机组故障诊断方法研究[J]. 建筑科学, 2024, 40(6): 146 - 154 + 208.
- [6] 徐行,李军星,贾现召,等. 基于 1DCNN - BiLSTM 的端到端滚动轴承故障诊断方法[J]. 机床与液压, 2024, 52(11): 211 - 218.
- [7] 景斯桐,吴东升. 基于 LSTM - CNN 的双路径滚动轴承故障诊断[J]. 沈阳理工大学学报, 2024, 43(1): 44 - 49.
- [8] 付雅婷,温世明,杨辉,等. 基于多通道输入和 1DCNN - LSTM 的道岔转辙机故障诊断[J]. 铁道学报, 2023, 45(11): 98 - 106.
- [9] 宋春生,梁亚茹,鲁妮芳,等. 基于 SAVMD 与 CNN 结合的轴承故障诊断方法[J]. 机械强度, 2024, 46(3): 509 - 517.
- [10] 贾朱植,刘凯,刘佳鑫,等. 基于 DACNN 的电机滚动轴承故障诊断方法[J]. 国外电子测量技术, 2024, 43(6): 179 - 190.
- [11] 张鑫宇,付强,黄倩,等. 基于 CWT - CNN 的离心泵轴承故障识别方法[J]. 机床与液压, 2024, 52(12): 202 - 207.
- [12] 曹景胜,于洋,王琦,等. 基于优化 VMD - CNN - BiLSTM 的电机轴承智能故障诊断研究[J]. 现代电子技术, 2024, 47(12): 115 - 121.