

[自控·检测]

DOI:10.3969/j.issn.1005-2895.2023.04.009

基于 CEEMDAN 和 CNN-TSA-GRU 的 滚动轴承故障识别方法研究

陈博, 魏豪, 权伟

(西安工程大学 工程训练中心, 陕西 西安 710048)

摘要:为避免复杂噪声对滚动轴承智能诊断模型的准确率干扰,提出一种基于完全集合经验模态分解 CEEMDAN 和深度时间自注意力卷积网络 CNN-TSA 的滚动轴承故障识别模型。该模型首先采用 CEEMDAN 将信号分解为若干固有模态函数(intrinsic mode function, IMF)分量,利用光谱放大因子 SAF 指标自适应筛选最优高信噪比分量;其次采用改进时间自注意力机制对数据分配权重并采用卷积神经网络 CNN 提取空间特征,弱化冗余特征信息,保留目标特征;最后利用门控循环单元 GRU 提取样本数据时间特征,使得网络得到更充分的学习,提高模型鲁棒性。经试验数据验证:所提出的深度学习智能故障识别模型故障识别准确率达到 98.87%;对比一维 CNN 和 CNN-LSTM 模型,识别准确率分别提高 9.15% 和 8.86%,验证了该模型的有效性和优越性。

关键词:故障识别;滚动轴承;CEEMDAN;深度学习;CNN-TSA

中图分类号:TH133.33 文献标志码:A 文章编号:1005-2895(2023)04-0068-07

Research on Rolling Bearing Fault Identification Method Based on CEEMDAN and CNN-TSA-GRU

CHEN Bo, WEI Hao, QUAN Wei

(Engineering Training Centre, Xi'an University of Engineering, Xi'an 710048, China)

Abstract: In order to avoid the interference of complex noise on the accuracy of intelligent diagnosis model of rolling bearing, a rolling bearing fault recognition model based on complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) and convolutional neural network-time self-attention (CNN-TSA) was proposed. Firstly, CEEMDAN was used to decompose the signal into several intrinsic mode function (IMF) components, and spectral amplification factor (SAF) was used to self-adaptively select the optimal high signal-to-noise ratio components. Secondly, an improved temporal self-attention mechanism was used to assign weight to the data and CNN was used to extract spatial features, weakening redundant feature information and retaining target features. Finally, gated recurrent unit (GRU) was used to extract the time features of sample data, so that the network can be more fully learned and the robustness of the model can be improved. The results show that the proposed deep learning intelligent fault recognition model can achieve rolling bearing fault recognition with an accuracy of 98.87%. Comparing the 1D CNN and CNN-LSTM models, the recognition accuracy can be improved by 9.15% and 8.86%, respectively, which verifies the effectiveness and superiority of the model.

Keywords: fault identification; rolling bearing; CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise); deep learning; CNN-TSA (Convolutional Neural Network-Time Self-Attention)

收稿日期:2022-12-23;修回日期:2023-04-25

基金项目:陕西省教育科学“十四五”规划 2021 年度课题(SGH21Y0100)。

第一作者简介:陈博(1984),男,陕西咸阳人,硕士,工程师,主要研究方向为故障诊断、数控加工技术。E-mail:394778444@qq.com

滚动轴承在复杂机械系统中被广泛使用,其安全平稳运行对整个机械系统的运行状态起着至关重要的作用。但滚动轴承的运行工况一般比较复杂^[1],其运行环境中存在着众多的噪声干扰,这就造成滚动轴承的故障难以被及时发现和识别,从而导致重大安全事故的发生^[2-3]。因此,进行噪声环境下的滚动轴承故障识别研究是非常必要的。

对滚动轴承故障特征提取主要是将信号中由轴承故障引起的冲击成分和其余干扰成分有效地分离开来。通用型信号分解方法有:经验模态分解(empirical mode decomposition, EMD)^[4-5]、集合经验模态分解(ensemble empirical mode decomposition, EEMD)^[6-7]、互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)^[8-9]、局域均值分解(local mean decomposition, LMD)^[10]、变分模态分解(variational mode decomposition, VMD)^[11-13]等。上述方法虽然在故障诊断中有一定的效果,但在自适应和鲁棒性方面还有待提升。如 EMD、EEMD 和 CEEMD 都存在模态混叠影响和重构误差问题, LMD 极易受到白噪声干扰, VMD 存在模态选取和二次罚因子预设等问题。

COLOMINAS 等^[14]提出了完全集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)算法,采用添加辅助噪声来解决分解算法中存在的模态混叠问题, CEEMDAN 算法很大程度上降低了计算资源的成本并且实现信号的零重构误差^[15-16]。近年来,为了进一步提高滚动轴承故障诊断精度和效率,人工智能中机器学习理论尤其是深度学习理论被用于滚动轴承智能诊断,成为研究热点。深度学习旨在通过搭建多层次的神经网络结构,逐层遍历提取数据中的深度特征,从而实现数据区分或数据预测,但深层的网络结构意味着传递过程中会产生大量的计算参数,导致模型僵化、泛化能力差。针对该问题, Kiranyaz 等^[17]提出了自适应一维卷积神经网络方法,该方法被广泛应用于故障诊断与检测领域。一维卷积神经网络方法相比于其他深度学习方法的优点在于不过度依赖于大量的轴承故障数据,并且可以直接采用原始振动检测数据进行特征提取^[18]。轴承信号中并不是所有特征都富含轴承故障信息,一

些对轴承故障信息贡献不大的特征权重占比过大,将会降低模型的识别精度。

为了有效提高故障特征的识别精度,课题组提出的基于 CEEMDAN 和 CNN-TSA-GRU 的深度学习故障识别模型首先依据 CEEMDAN 方法对复杂信号成分自适应分解,并采用光谱放大因子(spectral amplification factor, SAF)指标从中筛选最优分量;其次将最优分量作为模型入参,充分提取数据样本的空间和时间特征;最后,经试验数据验证及对比该模型的故障识别效率。

1 算法原理

1.1 完全集合经验分解 CEEMDAN 算法

完全集合经验模态分解 CEEMDAN 算法基于 EMD 算法自适应调整噪声系数,产生信噪比不同的高斯噪声,并引入待分解信号,在避免模态混叠的同时几乎无重构性误差。

假设原始信号为 $x(t)$, 自适应添加高斯白噪声并执行 EMD 分解直至参与分量不能继续分解为止,此时可得 CEEMDAN 的所有 K 个固有模态函数(intrinsic mode function, IMF)分量,则原始信号的分解可表示为剩余残差 $r(t)$ 与各 IMF 分量 $\bar{x}_k(t)$ 的叠加:

$$x(t) = \sum_{k=1}^K \bar{x}_k(t) + r(t). \quad (1)$$

1.2 光谱放大因子 SAF 指标

将信号的傅立叶变换幅度谱和信号在同一频率区间内的幅度谱的比值定义为光谱放大因子,该指标用来表示信号主频率的能量比重^[19]。SAF 指标可以不受噪声强度变化的干扰,有效筛选 CEEMDAN 分解的最优分量序列,具体定义如下:

$$\delta_{\text{SAF}} = \frac{\sum_{n=f_i-\delta}^{f_i+\delta} P_k(n)}{\sum_{n=f_i-\delta}^{f_i+\delta} P_0(n)}. \quad (2)$$

式中: δ_{SAF} 为光谱放大因子; $P_0(n)$ 是信号的傅立叶变换幅度谱; $P_k(n)$ 是第 k 个子序列分量的傅立叶变换幅度谱; f_i 为理论故障特征频率; 2δ 为以 f_i 为中心的频宽,其保证实际故障频率在以理论故障频率 f_i 为中心的频带内。

1.3 卷积神经网络 CNN

一维卷积神经网络(convolutional neural

networks, CNN) 通过多个滤波器对故障数据进行卷积与池化运算,从而提取有效的轴承故障特征。典型一维卷积神经网络由输入层、卷积层、池化层、全连接层和输出层构成,其中卷积层和池化层提取输入数据的特征,而全连接层主要负责分类,其结构如图 1 所示。

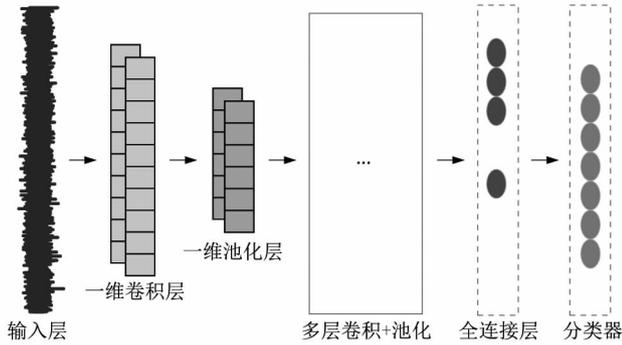


图 1 一维卷积神经网络结构

Figure 1 Network structure of 1D CNN

1.4 时间自注意力机制 TSA

网络入参的多个特征样本中,每个样本对分类结果的贡献度不同,甚至存在一些冗余特征,结合振动信号具有的隐含时间特性,课题组提出改进的时间自注意力机制,在传统自注意力机制计算查询参数 q 、键参数 k 和数值参数 v 之前增加长短记忆网络 (long short-term memory, LSTM) 层给输入数据附带隐藏时间标签,注意力层对输入数据相关性检测增加时间维度,提升权重系数分配精度。

$$\alpha_i = H(L, F(h_i, q)) = L \cdot \frac{\exp(F(h_i, q))}{\sum_{i=1}^{N_p} \exp(F(h_i, q))}; \quad (3)$$

$$F(h_i, q) = qh_i^T; \quad (4)$$

$$V = \sum_{i=1}^{N_p} \alpha_i h_i. \quad (5)$$

式中: H 为 Softmax 分类器; N_p 为输入序列长度, t 为时间标签,且 $t=1, 2, \dots, N_p$; h_i 为卷积网络的输出特征向量; q 为查询向量; F 为评分函数; L 为长短时记忆网络; V 为时间自注意力层的输出特征向量,即分配权重系数后的特征样本数据。

时间自注意力机制如图 2 所示。

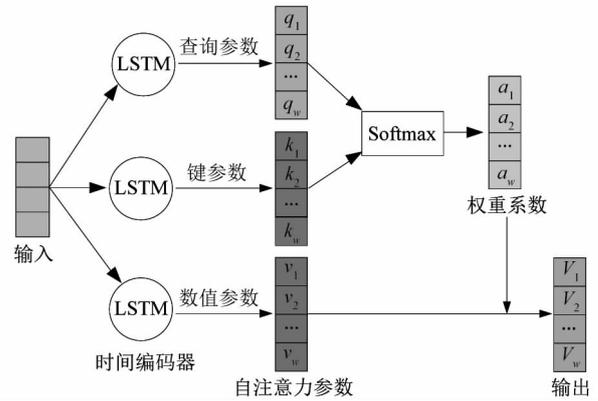


图 2 时间自注意力机制

Figure 2 Temporal self-attention mechanism

2 故障信号预处理

2.1 CEEMDAN 分解重构

由于信号中的噪声成分对网络模型的参数训练会造成较大影响,因此采用凯斯西储大学 (CWRU) 滚动轴承数据中心的滚动轴承试验数据进行降噪预处理研究,针对该信号进行 CEEMDAN 分解,得到 8 个 IMF 分量结果如图 3 所示,CEEMDAN 将噪声和有用信号进行了分离,有用信号主要集中在 IMF1 上,如表 1 所示。依据 SAF 指标选取数值大于 10 (IMF1, IMF2, IMF3 和 IMF4) 作为有效分量。将所筛选的 4 个有效分量相加分解重构得到如图 4 所示结果。从图 4(a) 中可以看出,信号中的噪声信号得到有效剔除,冲击脉冲变得明显,异音特征得到了有效的增强。图 4(b) 中内圈故障特征频率也能明显找出。

表 1 不同 IMF 分量 SAF 指标结果

Table 1 SAF index results of different IMF components

δ_{SAF}							
IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
23.20	15.60	12.50	14.30	8.60	6.20	5.30	6.23

2.2 数据标准化处理

进行数据归一化,利用离差标准化方法,使结果值映射到 [0,1] 之间。函数如下:

$$x^* = \frac{x - \min(x)}{\max(x) - \min(x)}. \quad (6)$$

式中: x 为振动测试信号幅值; x^* 为原始信号幅值标准化处理的归一化数值,作为网络模型入参。

数据标准化处理可以防止网络模型梯度爆炸,保

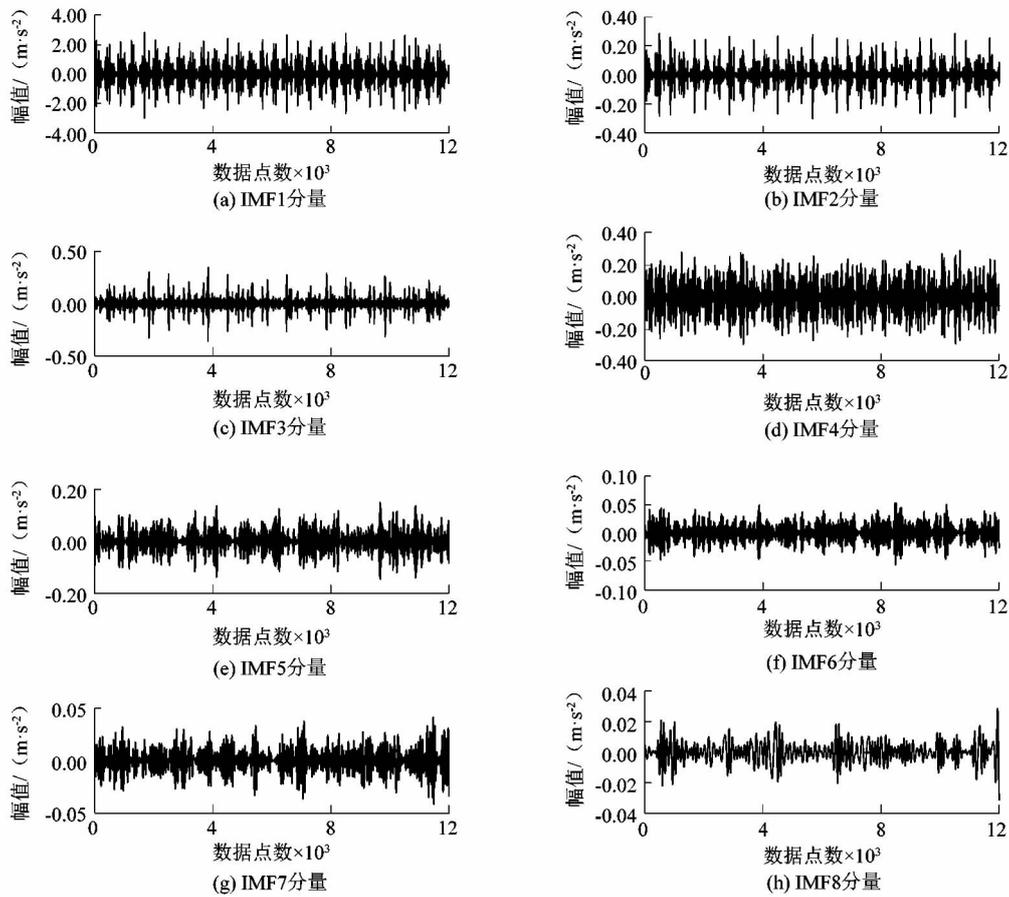


图 3 CEEMDAN 分解的 IMF 分量

Figure 3 IMF component of CEEMDAN decomposition

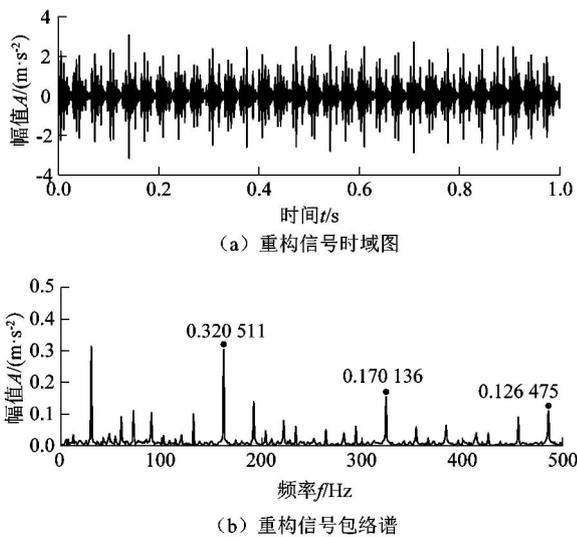


图 4 CEEMDAN 分解重构后的信号

Figure 4 Signal after CEEMDAN decomposition and reconstruction

证结果的可靠性。

3 算法流程

滚动轴承故障识别流程图如图 5 所示,主要由 2 部分内容构成:

1) 数据预处理。采用 CEEMDAN 处理振动监测信号,得到信号分解后的多阶本征模态函数 IMF,结合 SAF 指标筛选最优 IMF 分量,将其纳入数据集。

2) 网络模型训练。构建 CNN-TSA-GRU 深度学习网路模型,将步骤 1)中预处理数据进行打乱划分为训练集和测试集,训练集用于训练网络模型,测试集验证模型准确率。

4 试验分析

4.1 数据准备

为验证该方法的有效性,课题组采用凯斯西储大学(CWRU)滚动轴承数据中心的滚动轴承试验数据进

行验证,CWRU 数据集是世界公认的滚动轴承诊断标准数据集。

和滚珠故障,其中每种故障均有 0.18 mm 损伤直径。实验的采样频率为 48 kHz,每个样本含有 12 000 个数据点。正常数据和 3 种故障数据各采集 1 000 组,总共 4 000 组数据。4 000 组数据拆分成训练集和测试集如表 2 所示。

表 2 凯斯西储大学轴承数据集参数

Table 2 Parameters of CWRU bearing data set

轴承状态	样本总数	训练集样本数	测试集样本数	标签
正常	1 000	800	200	1
内圈故障	1 000	800	200	2
外圈故障	1 000	800	200	3
滚珠故障	1 000	800	200	4

4.2 网络模型参数设置

为了证明该方法的有效性,将该方法应用到凯斯西储大学实验数据上进行分析。首先利用 CEEMDAN 方法对实验数据进行处理,并筛选出最优 IMF 分量进行重构,有效去除了信号中的噪声干扰,增强了各类信号中的特征;然后将数据进行滑动窗处理构造数据集,并将数据集打乱顺序,随机选取 80% 的数据用作训练集,剩余的 20% 用作测试集;通过 CNN-TSA-GRU 故障识别模型进行训练,该模型首先经过时间自注意力层对数据特征自适应分配权重;然后采用 CNN 提取数据样本空间特征;采用 GRU 层提取数据样本时间特征;最后,由 Softmax 分类器输出分类结果,具体的网络层结构参数如表 3 所示。

表 3 网络模型结构与参数

Table 3 Network model structure and parameters

序号	名称	核尺寸	步长	输出尺寸
1	卷积层 1	128 × 1	64 × 1	4 873 × 8
2	池化层 1	16 × 1	2 × 1	2 436 × 8
3	卷积层 2	64 × 1	8 × 1	2 373 × 16
4	池化层 2	16 × 1	2 × 1	1 186 × 16
5	卷积层 3	64 × 1	8 × 1	1 123 × 32
6	池化层 3	8 × 1	2 × 1	561 × 32
7	卷积层 4	32 × 1	3 × 1	530 × 64
8	池化层 4	8 × 1	2 × 1	256 × 64
9	卷积层 5	16 × 1	3 × 1	250 × 128
10	池化层 5	2 × 1	2 × 1	125 × 128
11	TSA 层			125 × 128
12	BiGRU 层			125 × 128
13	全连接层			64 × 1
14	输出层			4 × 1

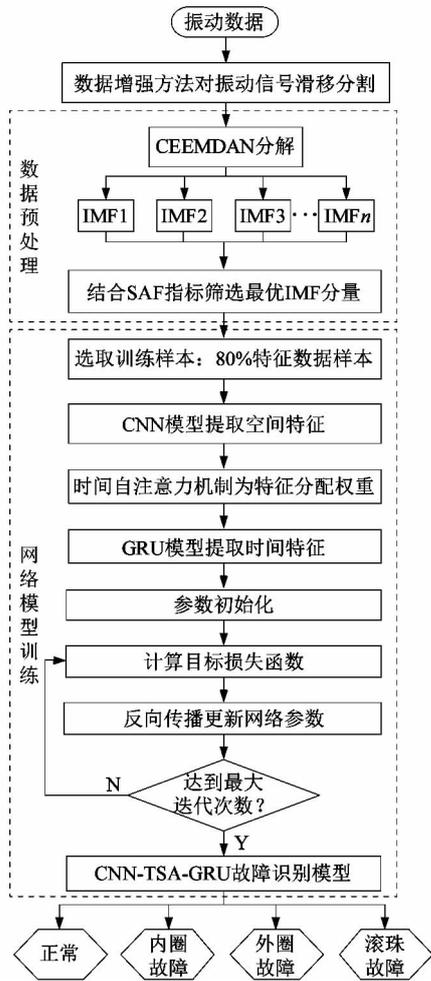
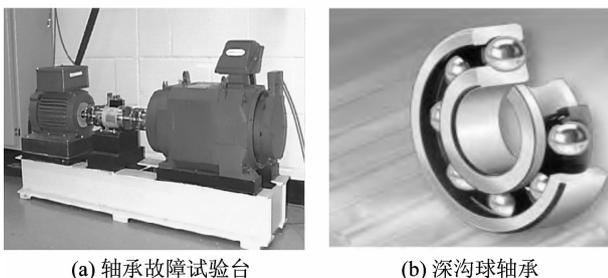


图 5 轴承故障识别流程图

Figure 5 Bearing fault identification flow chart

试验台设置如图 6 所示。其包含 1.5 kW 的电动机、扭矩传感器和示功器。试验研究 4 种滚动轴承的健康状况,分别是正常、轴承内圈故障、轴承外圈故障



(a) 轴承故障试验台

(b) 深沟球轴承

图 6 试验台及测试轴承

Figure 6 Test bed and test bearing

4.3 结果及分析

为了验证该方法诊断性能的优势,分别绘制训练过程和测试过程的准确率曲线,如图 7 所示。

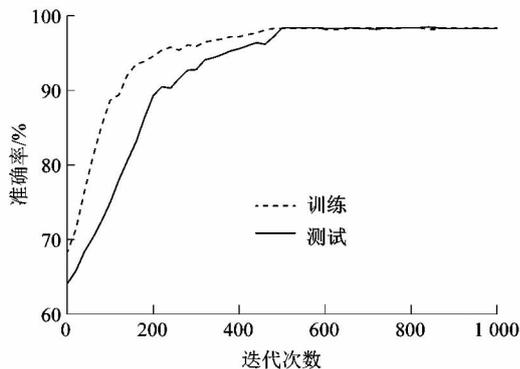


图 7 准确率随迭代次数的变化结果

Figure 7 Variation of accuracy with number of iterations

从图 7 可看出模型在不断的迭代训练过程中,准确率逐渐上升,在迭代次数 500 左右基本收敛。图 8 表明模型在不断迭代过程中损失值逐渐减小。可以看出该方法在轴承故障识别方面具有更好的性能。

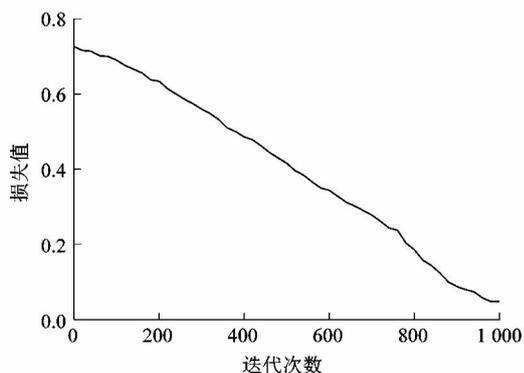


图 8 网络模型损失值随迭代次数的变化情况

Figure 8 Variation of loss value with number of iterations

4.4 对比方法的结果分析

为了进一步验证该网络模型的有效性,设置了 2 个对照组:一维 CNN 和 CNN-LSTM 模型。采用与上文一样的数据和实验设置进行仿真。

利用多分类混淆矩阵对 3 种不同模型的特征聚类情况进行可视化处理,实验结果如图 9 ~ 11 所示。图中纵坐标每行表示该种故障被错判为其他故障的个

数,横坐标每列表示 10 种样本中被判为此类故障的个数。可以看出,其中一维卷积神经网络模型分类准确率为 80.8%,CNN-LSTM 模型准确率为 90.1%,课题组所提模型准确率达到 98.9%,在保证较高的学习效率的同时也取得了较好的诊断结果,证明了该模型具有更好的诊断特性。

真实标签	1	173 21.6%	57 7.1%	22 2.8%	0 0.0%	68.7% 31.3%
	2	4 0.5%	103 12.9%	5 0.6%	0 0.0%	92.0% 8.0%
	3	23 2.9%	40 5.0%	170 21.2%	0 0.0%	73.0% 27.0%
	4	0 0.0%	0 0.0%	3 0.4%	200 25.0%	98.5% 1.5%
		86.5% 13.5%	51.5% 48.5%	85.0% 15.0%	100.0% 0.0%	80.8% 19.2%
	1	2	3	4	预测标签	

图 9 1D CNN 模型识别结果

Figure 9 Results of 1D CNN model recognition

真实标签	1	135 16.9%	1 0.1%	3 0.4%	0 0.0%	97.1% 2.9%
	2	4 0.5%	194 24.2%	5 0.6%	0 0.0%	95.6% 4.4%
	3	61 7.6%	5 0.6%	192 24.0%	0 0.0%	74.4% 25.6%
	4	0 0.0%	0 0.0%	0 0.0%	200 25.0%	100% 0.0%
		67.5% 32.5%	97.0% 3.0%	96.0% 4.0%	100.0% 0.0%	90.1% 9.9%
	1	2	3	4	预测标签	

图 10 CNN-LSTM 模型识别结果

Figure 10 Results of CNN-LSTM model recognition

5 结论

为消除噪声对智能故障诊断模型的干扰,课题组提出了一种基于 CEEMDAN 和 CNN-TSA-GRU 的滚动轴承故障识别模型。经过试验数据和对比方法验证,得出如下结论:

真实标签	1	197 24.6%	0 0.0%	0 0.0%	0 0.0%	100.0% 0.0%
	2	0 0.0%	194 24.2%	0 0.0%	0 0.0%	100.0% 0.0%
	3	3 0.4%	6 0.8%	200 25.0%	0 0.0%	95.7% 4.3%
	4	0 0.0%	0 0.0%	0 0.0%	200 25.0%	100.0% 0.0%
		98.5% 1.5%	97.0% 3.0%	100.0% 0.0%	100.0% 0.0%	98.9% 1.1%
	1	2	3	4	预测标签	

图 11 改进模型识别结果

Figure 11 Recognition results of improved model

1) 该模型采用 CEEMDAN 对故障信号进行分解,能有效拆分信号中的复杂成分,并结合 SAF 指标筛选有效信号分量进行重构,成功提取出故障信号中冲击成分,实现信号降噪和特征强化,解决了非高斯噪声干扰问题。

2) 该模型在传统的 CNN 网络基础上添加了改进时间自注意力机制(TSA)对数据分配权重,弱化冗余特征信息、保留目标特征,并利用门控循环单元(GRU)提取样本数据时间特征,使得网络得到更充分的学习,提高了整个模型的鲁棒性。

3) 采用西储大学轴承数据集开展故障识别研究,试验结果表明所提出故障识别模型相比一维卷积神经网络模型和 CNN-LSTM 模型准确率分别高 18.1% 和 8.8%。证明了该模型具有更高的诊断精度。

参考文献:

[1] REHMAN N, MANDIC D P. Multivariate empirical mode decomposition [J]. Proceedings of the Royal Society A, 2010, 466 (2117):1291 - 1302.

[2] 阳建宏,黎敏,丁福焰.滚动轴承诊断现场实用技术[M].北京:机械工业出版社,2015:12 - 25.

[3] TANG T, BO L, LIU X F, et al. Variable predictive modelclass discrimination using novel predictive models and adaptive feature selection for bearing fault identification [J]. Journal of Sound and Vibration, 2018, 425:137 - 148.

[4] 陈龙,张纯龙.基于 EMD 包络谱特征与 PCA-PNN 的滚动轴承故障诊断[J].煤矿机械,2022,43(10):173 - 176.

[5] 谢振龙,岳彩旭,刘献礼,等.基于 EMD-SVM 的钛合金铣削过程刀具磨损监测[J].振动测试与诊断,2022,42(5):988 - 996.

[6] 刘志慧,徐兴平,牛怀磊,等.基于 EEMD 的立管涡激振动响应最优降噪光滑模型参数识别研究[J].振动与冲击,2022,41(12):254 - 260.

[7] 朱渔,李丹,李晓明,等.基于 EEMD 和 BLSTM 算法的齿轮泵行星轮典型故障诊断[J].机械设计与研究,2022,38(4):198 - 201.

[8] 刘荣伟,何伟挺,汪琳琳,等.基于 CEEMD-LSTM 的离心泵偏工况诊断方法研究[J].振动与冲击,2022,41(19):114 - 121.

[9] 杨波,黄倩,付强,等.基于 CEEMD 和优化 KNN 的离心泵故障诊断方法[J].机电工程,2022,39(11):1502 - 1509.

[10] 高素杰,巫世晶,周建华,等.基于 LMD 排列熵和 BP 神经网络的行星齿轮箱故障诊断方法[J].机械传动,2022,46(10):8.

[11] 胡爱军,白泽瑞,赵军.参数优化 VMD 结合 1.5 维谱的滚动轴承复合故障特征分离方法[J].振动与冲击,2020,39(11):9.

[12] 卢文刚,张燕霞.基于 VMD 和随机森林的离心泵滚动轴承故障诊断[J].机电工程技术,2022,51(3):78 - 82.

[13] 黄晓诚,贺青川,陈文华.基于 VMD 与 MLP 的电机轴承故障检测方法[J].机电工程,2022,39(7):911 - 918.

[14] COLOMINAS M A, SCHOTTHAUER G, TORRES M E. Improved complete ensemble EMD: a suitable tool for biomedical signal processing [J]. Biomedical Signal Processing & Control, 2014, 14:19 - 29.

[15] 刘洋,王林军,李立军,等.基于 SVD-CEEMDAN 和 KLD 的轴承故障分析[J].机床与液压,2022,50(17):195 - 199.

[16] 罗惠中,刘德嘉,甘育娇,等.一种基于 CEEMDAN-改进小波阈值的 OTDR 信号去噪算法[J].光电子·激光,2022,33(3):241 - 247.

[17] KIRANYAZ S, INCE T, HAMILA R, et al. Convolutional neural networks for patient-specific ECG classification [C]//2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Milan:IEEE, 2015: 2608 - 2611.

[18] 丁晓雯,丁强,顾君垚,等.基于 1DCNN-DS 的冷水机组故障诊断[J].低温与超导,2022,50(7):69 - 76.

[19] SMITH W A, RANDALL R B. Rolling element bearing diagnostics using the Case Western Reserve University data: a benchmark study [J]. Mechanical Systems and Signal Processing, 2015, 64:100 - 131.