

基于混沌信息增强的风力机轴承智能故障诊断

苏欢欢, 李春, 闻麒, 岳敏楠

(上海理工大学 能源与动力工程学院, 上海 200093)

摘要: 针对复杂工况下风力机机械部件存在振动损伤识别困难、故障信号特征依赖人为经验提取等问题, 采用完全自适应噪声集合经验模态分解 (CEEMDAN) 方法处理原始信号, 通过皮尔逊相关系数筛选特征信号, 基于混沌理论运用相空间重构方法获取更为纯净的信号, 将重构信号输入卷积神经网络 (CNN) 实现故障特征提取。实验结果表明: 重构之后的信号可有效去除干扰信号, 且在不同的信噪比下, 该诊断模型识别不同类型轴承故障的准确率为 99.74%, 在西安交通大学数据集和渥太华大学数据集两种不同数据集下故障识别率高达 99.31% 和 98.10%, 说明该模型具有良好的泛化性和鲁棒性, 可为风力机机械部件的健康监测与管理提供参考。

关键词: 风力机; 混沌理论; 卷积神经网络; 相空间重构; 故障诊断

中图分类号: TK83

文献标识码: A

DOI: 10.16146/j.cnki.rndlgc.2024.12.021

[引用本文格式] 苏欢欢, 李春, 闻麒, 等. 基于混沌信息增强的风力机轴承智能故障诊断[J]. 热能动力工程, 2024, 39(12): 184-194. SU Huanhuan, LI Chun, WEN Qi, et al. Intelligent fault diagnosis of wind turbine bearings based on chaotic information enhancement[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(12): 184-194.

Intelligent Fault Diagnosis of Wind Turbine Bearings based on Chaotic Information Enhancement

SU Huanhuan, LI Chun, WEN Qi, YUE Minnan

(School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai, China, Post Code: 200093)

Abstract: Aiming at the problems that it is difficult to identify the vibration damage of wind turbine mechanical components under complex working conditions, and the fault signal characteristics depend on human experience extraction, the complete adaptive noise ensemble empirical mode decomposition (CEEMDAN) method was used to process the original signal. The Pearson correlation coefficient was used to screen the characteristic signal. Based on the chaos theory, the phase space reconstruction method was used to obtain a more pure signal. The reconstructed signal was input into the convolutional neural network (CNN) to realize fault feature extraction. The experimental results show that the reconstructed signal can effectively remove the interference signal, and under different signal-to-noise ratios, the diagnostic model has an accuracy rate of 99.74% in identifying different types of bearing faults, with fault recognition rates as high as 99.31% and 98.10% under two different datasets in Xi'an Jiaotong University and University of Ottawa, respectively, indicating that it has good generalization and robustness, which can provide reference for health monitoring and management of wind turbine mechanical components.

Key words: wind turbine, chaos theory, convolutional neural network (CNN), phase space reconstruction, fault diagnosis

收稿日期: 2023-12-11; 修订日期: 2024-02-03

基金项目: 国家自然科学基金资助项目 (51976131, 52006148, 52106262)

Fund-supported Project: National Natural Science Foundation of China (51976131, 52006148, 52106262)

作者简介: 苏欢欢 (1997-), 男, 上海理工大学硕士研究生。

通信作者: 岳敏楠 (1982-), 女, 上海理工大学副教授。

引 言

风电作为清洁能源,在国家实现双碳战略目标中发挥着不可替代的作用^[1-2]。海上风力机在役环境复杂,受风浪流等多种载荷作用,旋转机械易发生损伤,且必须经历停机维护才能重启运行,运行维护困难,加剧了风力机关键组件的损伤^[3]。对风力机关键组件进行准确的检测、诊断和预测并及时采取维护措施,可有效减少计划外停机事件,降低风电场成本,提高经济效益^[4-5]。因此,有效监测齿轮箱、轴承等机械部件振动信号并检测其健康状况,实现早期故障评估和趋势预测是当前行业研究的热点^[6-7]。在机械部件性能退化初期,振动信号因受变载荷和环境噪音等因素影响导致振动信号的非线性及非平稳性特征明显^[8],致使通过传统方式提取故障特征困难^[9-10]。

为解决振动信号受变转速、变载荷、强噪声影响的问题,众多学者提出许多信号预处理方法。Sun 等人^[11]提出基于经验模态分解和改进的切比雪夫距离的新型轴承故障诊断方法,建立了准确的故障识别模型,但该模型参数过分依赖人为调整和验证,且泛化性能较弱。周浪等人^[12]提出基于分段累积近似与自适应噪声辅助集成经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)的滚动轴承故障诊断模型,有效提取故障信息,实现对轴承故障的诊断。在处理信号时单一的模态分解可能会导致信号的细节损失,特别是包含故障特征的低频包络信号。雷春丽等人^[13]构建样本熵与变分模态分解(Variational Mode Decomposition, VMD)结合的故障诊断模型,通过提取振动信号的趋势项,实现对轴承的故障诊断,但该模型受噪声影响较大。综上,原始信号经预处理后,存在降噪不完全、特征提取不充分等问题,致使模型故障识别能力下降。

随着智能化的不断发展,基于深度学习的故障诊断方法成为近年研究的热点。Ince 等人^[14]基于卷积神经网络(Convolutional Neural Network, CNN)利用轴承振动信号实现电机轴承故障检测,克服传统方法对专家经验和领域知识的依赖。Wen 等

人^[15]利用 CNN 在图像处理方面的优势将振动信号转换为二维图像,建立的新模型具有更高的诊断精度。郭俊锋等人^[16]建立混合域注意力机制与 Chost 卷积神经网络相结合的诊断模型,将振动信号转化为具有时间相关性的二维特征图,有效提高故障识别的准确率,但该模型训练时间过长,且易发生特征丢失。Li 等人^[17]提出了一种基于小波包变换和卷积神经网络的两步故障诊断方法,但模型训练需要大量的数据,若数据集不充分或标签不准确,将造成特征提取不充分的情况,影响诊断结果。

为弥补现有诊断模型的不足,本文提出在训练中引入高斯白噪声模拟实际环境噪声,提高模型抗噪性,增强复杂环境下诊断性能的稳定性,模型利用相空间重构故障信号抑制高频噪声,还原系统动力学非线性结构,有效增强模型的抗噪性和特征提取能力。模型通过皮尔逊相关系数筛选 CEEMDAN 分解的固有模态函数(IMF)分量,并基于混沌理论运用相空间重构(Phase Space Reconstruction, PSR)方法重构信号后输入 CNN 模型实现故障分类。针对不同故障信号,CEEMDAN-PSR-CNN 模型仍可有效提取故障信息,实现准确的故障识别,从而提供了一种实现故障诊断的新途径。

1 理论基础

1.1 自适应噪声完备集合经验模态分解

CEEMDAN 是优化经验模态分解(Empirical Mode Decomposition, EMD)和互补集合经验模态分解(Complementary Ensemble Empirical Mode Decomposition, CEEMD)方法的一种改进算法。CEEMDAN 算法实现过程如下:

(1) 在原始信号 $f(x)$ 中加入若干成对高斯白噪声 $\beta\theta_i(x)$ 形成新的噪声序列 $Y_i(x)$:

$$Y_i(x) = f(x) + \beta\theta_i(x) \tag{1}$$

式中: β —噪声标准差; $\theta_i(x)$ —第 i 次添加的白噪声, $i=1,2,\dots,n$, n 为添加白噪声的次数。

(2) 使用 EMD 分解 $Y_i(x)$, 得到首个模态分量 $IMF_1(x)$ 和余量信号 $M_1(t)$:

$$IMF_1(x) = \frac{1}{n} \sum_{i=1}^n IMF_1^i(x) \tag{2}$$

$$M_1(t) = f(x) - IMF_1(x) \tag{3}$$

(3) 在余量信号 $M_1(t)$ 中添加自适应高斯白噪声,生成新的噪声序列 $M_2(t) + \beta_1 Z(\theta_i(x))$,再得到第 2 个模态分量 $IMF_2(x)$ 和余量信号 $M_2(t)$:

$$IMF_2(x) = \frac{1}{n} \sum_{i=1}^n Z_i(M_1(t) + \beta_1 Z(\theta_i(x))) \quad (4)$$

$$M_2(t) = f(x) - IMF_2(x) \quad (5)$$

式中: $Z_l(\cdot)$ —EMD 分解后产生的第 l 个分量。

(4) 重复步骤 (3) 得到第 $l + 1$ 个模态分量 $IMF_{l+1}(x)$ 和余量信号 $M_l(t)$:

$$IMF_{l+1}(x) = \frac{1}{n} \sum_{i=1}^n (Z_l(M_k(t) + \beta_k Z_k(\theta_i(x)))) \quad (6)$$

$$M_l(t) = M_{l-1}(t) - IMF_l(x) \quad (7)$$

(5) 当余量信号为单调函数时,停止迭代,算法终止,此时的信号为:

$$f(x) = \sum_{i=1}^n IMF_i(x) + Z(x) \quad (8)$$

(6) 皮尔逊 (Pearson) 相关系数反映了两个变量线性相关性的强弱,通过计算 IMF 分量与原信号的皮尔逊相关系数,进而选取最优的分量。计算公式为:

$$P = \frac{\sum_{i=1}^n (\bar{x} - \mu_X)(\bar{y} - \mu_Y)}{\sqrt{\sum_{i=1}^n (\bar{x} - \mu_X)^2} \sqrt{\sum_{i=1}^n (\bar{y} - \mu_Y)^2}} \quad (9)$$

式中: P —Pearson 相关系数; X, Y —输入信号向量; $\bar{x}$ —向量 X 的平均值; $\bar{y}$ —向量 Y 的平均值; μ_X, μ_Y — X 和 Y 的样本均值。

1.2 分形与混沌

分形理论在被提出之后迅速发展,在当代非线性科学研究中具有极为重要的地位。局部与整体以某种方式相似的形叫做分形,其特征是系统部分与整体间具有自相似性及无标度性^[18-20]。

混沌运动是指在确定性非线性系统中,受系统对初始条件高度依赖所驱动的有限相空间内的随机性运动现象^[21]。混沌运动对初始条件的细微变化具有高度敏感性,因此当振动信号发生微小变化时,混沌吸引子将呈现显著变化。虽然混沌运动表现出近乎随机的特性,但其实存在复杂而有序的几何分形结构及内在规律性^[22]。

1.2.1 相空间重构

相空间重构是处理振动信号的常用技术^[23]。信号中包含系统状态变量的变化轨迹,多以时间序列的形式呈现。一些系统信息隐藏在序列中不能直接观测,但可以通过相空间重构来提取。相空间重构是由 Packard 等人^[24]提出的分析非线性时间序列的方法,以有限的数字重构奇异吸引子来分析系统动力学行为。相空间重构是分析时间序列混沌特性的重要手段,将信号分解为原始信号和噪声信号,然后利用信号处理技术去除噪声信号,最后通过信号重构技术将原始信号重构出来。在选取轴承振动特征信号时,将一维时间序列 $\{u_i | i = 1, 2, \dots, n\}$ 嵌入 a 维空间得到相点 F :

$$F = \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_n \end{bmatrix} = \begin{bmatrix} u_1 & u_{1+\tau} & u_{1+2\tau} & \cdots & u_{1+(a-1)\tau} \\ u_2 & u_{2+\tau} & u_{2+2\tau} & \cdots & u_{2+(a-1)\tau} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ u_n & u_{n+\tau} & u_{n+2\tau} & \cdots & u_{n+(a-1)\tau} \end{bmatrix} \quad (10)$$

式中: τ —延迟时间; a —嵌入维数。

嵌入维数 a 与延迟时间 τ 的选取对动力学系统的重构具有显著影响^[25]。 τ 过小会使重构相空间失去独立性,导致信息冗余,并且使混沌吸引子展开不充分,不能显现系统动力学特性; τ 过大会破坏原信号间的内在联系,造成信息丢失,增加不必要的运算,并放大时间序列中的噪声,不能突出动力学特性。通常采用虚假邻点法、Cao 法及 G-P 算法确定最佳嵌入维数 a ^[26],采用互信息法和自相关法计算得到延迟时间 τ ^[27-28]。本文采用 G-P 算法和互信息法计算嵌入维数和延迟时间:

$$C(r) = \frac{2}{D(D-1)} \sum_{i=1}^n H(r - \|X_i - X_j\|) \quad (11)$$

$$I(\eta) = \sum_{i=1}^N P(x_i + x_{\eta+i}) \log_2 \left[\frac{P(x_i, x_{i+\eta})}{P(x_i)P(x_{i+\eta})} \right] \quad (12)$$

式中: r —以 X_i 或 X_j 为中心球体的半径; H —阶跃函数, $\|\cdot\|$ 是范数; X_i, X_j —经过相空间重构后得到的高维向量; $C(r)$ —两个向量在一定距离的概率; n —数据集个数; $P(x_i), P(x_{i+\eta})$ —在时间序列 $x_i, x_{i+\eta}$ 出现的概率; $P(x_i, x_{i+\eta})$ —同时出现在 x_i 和 x_{i+1} 中的概率。

1.2.2 Lyapunov 指数

混沌融合利用混沌现象的随机性和非线性特性将多个混沌信号或非线性系统进行融合,从而获得更加复杂的信号或系统,使得混沌系统的运动轨迹具有十分复杂的结构^[29]。Lyapunov 指数 λ 可反映非线性响应信号的动态特征,且不受数据本身波动的影响^[30]。Lyapunov 指数值越大,说明系统的敏感性越强,系统更易产生混沌现象。基于 Wolf 法计算 Lyapunov 指数 λ :

$$\lambda = (t_M - t_0)^{-1} \sum_{s=0}^k \ln(E'_s/E_s)$$

(13)

式中: E_s —原点与重构点的距离, $s = 1, 2, \cdots, k$; N'_s —下一时刻两点的距离; k —迭代总次数; t_0 —初始时间; t_M —经过迭代后的时间。

Lyapunov 指数可能为正,也可能为负。 $\lambda > 0$, 系统处于混沌状态且具有非线性特征; $\lambda < 0$, 系统将做周期运动; $\lambda = 0$, 系统趋于静止。

2 深度学习理论

2.1 卷积神经网络

在 Lecun^[31] 提出的 LeNet 网络模型中,卷积神经网络(CNN)体现出强大的特征提取能力,能够模

仿生物视觉皮层感知机制,因其强大的学习能力而被广泛应用于各领域。CNN 是一种前馈神经网络,具有局部感受野、参数共享和池化 3 个显著的特征。局部感受野和权重共享使 CNN 能够以较少的参数处理大规模数据,有利于处理高频振动信号。基于 CNN 的故障诊断方法的一般步骤可概括为:数据预处理、结构模型构建及模型训练。图 1 为简单的卷积神经网络模型。




图 1 卷积神经网络结构图

Fig.1 Structure diagram of convolutional neural network

本文采用的 CNN 流程如图 2 所示。由图 2 可知,CNN 模型由数据标准化层(BN)、全连接层、Dropout 层(DR)、卷积层和池化层组成,最后经 Softmax 分类器输出其准确率。




图 2 卷积神经网络流程图

Fig.2 Flow chart of convolutional neural network

2.2 故障诊断流程

旋转机械振动耦合与复杂的服役环境导致振动信号具有不稳定及非线性等特征,仅通过 CNN 模型难以提取故障特征。本文基于混沌理论对故障特征信号进行相空间重构,联合 CNN 建立故障诊断方

法,实现轴承故障诊断。诊断过程如图 3 所示。由图 3 可知,该模型通过对原始信号进行分解、筛选和重构的预处理,将处理过的数据输入 CNN 模型进行训练以达到识别故障的目的,为表明该模型能有效提取特征,基于分形理论分析其混沌特性。




图 3 故障诊断流程图
Fig. 3 Flow chart of fault diagnosis

3 实验信号分析

3.1 实验数据

风力机作为大型旋转机械设备,其机械部件传动系统的故障特征与其他旋转机械设备存在共性,故风力机传动系统滚动轴承的故障诊断和其他旋转机械设备的故障诊断属于同一研究领域,研究方法基本一致^[32]。风力机中有多种不同类型的轴承,本文以主传动系统轴承为对象进行研究,主传动轴承包括主轴承、齿轮箱轴承,且传动轴承以滚动轴承为主。因此,可采用美国凯斯西储大学(CWRU)轴承数据中心^[33]提供的高速滚动轴承实验数据验证所提方法的有效性及准确性。轴承实验平台装置如图 4 所示,图中@ 3、@ 6 和@ 12 分别表示故障发生在外圈 3 点钟、6 点钟和 12 点钟方向。由图 4 可知,实验平台主要由负载电机(2 235 W)、传感器和功率计 3 部分构成。将采样频率设置为 12 kHz,在滚动轴承内圈、外圈和滚珠上分别布置损伤直径 $d_1 = 0.177\ 8\ \text{mm}$ 和 $d_2 = 0.533\ 4\ \text{mm}$ 的故障缺陷。通过加速度传感器采集不同工况下的振动信号,滚动轴承参数如表 1 所示。




图 4 轴承实验平台装置图
Fig. 4 Bearing experimental platform device diagram


表 1 实验滚动轴承参数(mm)
Tab. 1 Experimental rolling bearing parameters(mm)

参 数	数 值
内圈直径	25.00
外圈直径	52.00
滚珠直径	7.94
节圆直径	39.04

3.2 特征信号

3.2.1 信号对比

筛选后重构信号与原信号对比如图 5 所示。由图 5 可知,经过筛选重构的信号与原信号振幅不同且主要特征与原信号具有高度一致性,剔除了无关分量并保留了信号原有的故障特征。






图 5 筛选后的特征信号与原信号对比

Fig. 5 Comparison of filtered characteristic signal and original signal

3.2.2 计算嵌入延迟时间和嵌入维数

相空间重构的关键在于选取嵌入空间维数和延

迟时间,故选择恰当的嵌入维数使吸引子完全打开极为重要。原信号的嵌入维数和延迟时间如表 2 所示。由表 2 可知,与原信号相比,重构信号延迟时间增大,系统动力学信息丢失情况减少,且嵌入维数减小,还原系统真实结构。

表 2 重构延迟时间与嵌入维数计算

Tab.2 Reconstructed delay time and embedding dimension calculation

位 置	延迟时间/s		嵌入维数	
	原信号	重构信号	原信号	重构信号
正常状态	3	15	5	3
内圈 $d_1=0.1778\text{ mm}$	7	5	7	3
滚珠 $d_1=0.1778\text{ mm}$	7	9	7	3
外圈 $d_1=0.1778\text{ mm}, @3$	10	15	7	4
外圈 $d_1=0.1778\text{ mm}, @6$	13	14	6	6
外圈 $d_1=0.1778\text{ mm}, @12$	5	9	6	3
内圈 $d_2=0.5334\text{ mm}$	13	16	7	4
滚珠 $d_2=0.5334\text{ mm}$	11	17	6	3
外圈 $d_2=0.5334\text{ mm}, @3$	2	6	6	3
外圈 $d_2=0.5334\text{ mm}, @6$	4	6	6	3
外圈 $d_2=0.5334\text{ mm}, @12$	3	8	7	4

Lyapunov 指数 λ 为特征值, λ 越大,故障特征越丰富。为更好地分析不同状态的轴承振动信号,基于混沌理论,计算 11 种状态信号的 Lyapunov 指数,结果如表 3 所示。

表 3 原信号与重构信号的 Lyapunov 指数

Tab.3 Lyapunov exponents of original signal and reconstructed signal

位 置	原信号	重构信号
正常状态	0.107 0	0.345
内圈 $d_1=0.1778\text{ mm}$	0.216 0	0.376
滚珠 $d_1=0.1778\text{ mm}$	0.018 2	0.269
外圈 $d_1=0.1778\text{ mm}, @3$	0.062 9	0.413
外圈 $d_1=0.1778\text{ mm}, @6$	0.026 6	0.457
外圈 $d_1=0.1778\text{ mm}, @12$	0.428 2	0.716
内圈 $d_2=0.5334\text{ mm}$	0.019 7	0.503
滚珠 $d_2=0.5334\text{ mm}$	0.013 8	0.208
外圈 $d_2=0.5334\text{ mm}, @3$	0.040 3	0.715
外圈 $d_2=0.5334\text{ mm}, @6$	0.074 4	0.642
外圈 $d_2=0.5334\text{ mm}, @12$	0.057 3	0.634

由表 3 可知,11 组数据的 Lyapunov 指数均为正,表明系统都具有混沌特征,而重构信号的 Lyapunov 指数均大于原信号,表明混沌特征更为明

显,信号特征更为显著。

3.3 模型诊断结果分析

将重构的信号输入卷积网络模型进行训练,进一步挖掘故障信息,实现故障识别。基于上述数据集进行诊断,结果取多次实验平均值,原信号、CEEMDAN 的分解信号及筛选后重构信号的故障分类准确率和损失曲线如图 6 所示。




图 6 不同信号故障分类准确率和损失曲线
Fig. 6 Different signal fault classification accuracy rate and loss curves

由图 6 可知,将滚动轴承故障信号作为输入时,由于原振动信号具非线性、非平稳性及强耦合的特点,仅 CNN 模型无法提取有效的特征信息,而 CEEMDAN-PSR-CNN 模型经 200 次迭代训练,在 150 次迭代之后损失值趋于平缓,且损失值为 0.001,此时故障识别故障准确率已达 99.74%,此时模型已收敛。由此可见,此模型可从重构信号中提取故障特征实现降噪,有效剔除无关分量,消除冗余影响,且模型收敛过程更为迅速,故障识别准确率更高。

3.4 抗噪性能分析

因风力机叶轮旋转对机舱内振动产生的激振,

使得轴承在运行经过缺陷位置时产生周期性脉冲振动,且振动频率处于低频段,但由于风力机运行工况复杂,导致特征易被噪声淹没。为研究 CEEMDAN-PSR-CNN 诊断模型的鲁棒性,将信噪比为 -6, -4, -2, 0, 2, 4 和 6 的高斯白噪声添加到重构信号中,模拟轴承实际工作环境。不同信噪比下不同算法准确率对比结果如表 7 所示。




图 7 不同信噪比下准确率对比
Fig. 7 Comparison of accuracy rates at different signal-to-noise ratios

由图 7 可知,添加噪声之后,信号特征易被淹没,相比 VMD,EMD 和 CEEMDAN,经 CEEMDAN-PSR 方法处理后的信号降噪效果较好,更易获取纯净故障信息,CNN 更容易提取故障信息。故 CEEMDAN-PSR-CNN 诊断方法具有较好的鲁棒性,能够使信号在噪声存在的情况下保持较好的性能,其稳定性和可靠性在不同信噪比下都具有良好的表现。

3.5 混沌特征分析

为定量说明 CEEMDAN-PSR 降噪效果与特征提取能力,求取重组信号吸引子轨迹,使故障信息可视化。11 种不同状态原信号与重构信号的吸引子轨迹如图 8 和图 9 所示。由图 8 和图 9 可知,所有相图均呈“云团状”,具有一定体积且不闭合的结构,运动轨迹不具有周期性。不同轴承状态的相形各不相同,吸引子轨迹形态各异,表现出的响应不完全呈周期性,也不完全呈随机性。但重构之后的相图轨迹平滑,整体重构相图的吸引子具有自相似性,表明振动信号受到噪声影响较小,但因混沌相图对初始值变化敏感,与原始信号相比,重构后相图较吸引子轨迹发生不同变化,有外延或收缩、有缠绕或摆脱的走向、有体积增大或缩小等不同变化。




图 8 原信号混沌相图

Fig. 8 Chaotic phase diagrams of original signal




图 9 重构信号混沌相图

Fig. 9 Chaotic phase diagrams of reconstructed signal

3.6 模型泛化性验证

为更好地验证模型在复杂工况下的泛化性,采用西安交通大学数据集^[34]和渥太华大学数据集^[35]进行验证。文献[35]数据集选用 ER16K 深沟球轴承作为研究对象,且采用 200 kHz 的采样频率对振动信号进行采集。该数据集涵盖正常状态、内圈故障、外圈故障、滚动体故障以及内外圈与滚动体的复合故障。变转速具体包括递增、递减、递增后递减和递减后递增。采用 CEEMDAN-PSR-CNN 模型验证,结果如图 10 所示。由图 10 可知,文献[34-35]经该模型处理后由 Softmax 分类器输出,其准确率达到 99.31% 和 98.10%,由此说明 CEEMDAN-PSR-CNN 模型具有良好的泛化性。

3.7 模型可视化

为了更好地理解模型运作过程,对 CNN 模型进行可视化处理,采用 t-SNE 对 CNN 模型各卷积层数据降维可视化故障特征,结果如图 11 所示。




图 10 数据集准确率与损失

Fig. 10 Accuracy rate and loss of datasets

由图 11 可知,随卷积层数不断增加,不同故障特征被挖掘,不同轴承状态分离。在全连接层中,11 种轴承状态发生明显分离,不存在模态混叠现象。




图 11 各卷积层可视化结果

Fig. 11 Visualization results of each convolutional layer

4 结 论

针对传统故障诊断方法需要依赖人为经验,同时在强噪声或变载荷的情况下难以有效提取故障特征的问题,采用 CEEMDAN 算法对振动信号进行分解筛选,基于混沌融合理论将筛选后的特征分量重构降噪预处理,建立故障诊断模型,通过结果分析得出以下结论:

- (1) 重构之后的信号可有效去除噪声和干扰,故障特征信号更加平滑和干净。这对于信号处理和分析非常有益,特别是在噪声环境下。
- (2) Lyapunov 指数可以很好地反映出原始信号的混沌特性, CNN 可提取更为纯净的非线性特征信号。
- (3) 在信噪比 6 dB 下, CEEMDAN-PSR-CNN 模型的准确率为 97.89%, 说明该算法具有鲁棒性。

(4) 与传统算法相比,CEEMDAN-PSR-CNN 算法在不同的数据集中故障识别准确率为 99.31% 和 98.10%,表明该模型具有良好的泛化性。

参考文献:

[1] LIU W Y,GAO Q W,YE G,et al. A novel wind turbine bearing fault diagnosis method based on integral extension LMD[J]. Measurement,2015,74:70 – 77.

[2] 习近平. 关于《中共中央关于制定国民经济和社会发展第十四个五年规划和二〇三五年远景目标的建议》的说明[R]. 新华社,2020 – 11 – 03.

XI Jinping. Explanation on the " proposal of the central committee of the Communist Party of China on formulating the fourteenth five-year plan for national economic and social development and the vision goals for the year 2035" [R]. The Xinhua News Agency, 2020 – 11 – 03.

[3] SHENG S,O'CONNOR R. Reliability of wind turbines[J]. Wind Energy Engineering,2017,15:299 – 327.

[4] QIAO W,LU D. A survey on wind turbine condition monitoring and fault diagnosis—Part II: Signals and signal processing methods [J]. IEEE Transactions on Industrial Electronics,2015,62(10): 6546 – 6557.

[5] HU Z X,WANG Y,GE M F,et al. Data-driven fault diagnosis method based on compressed sensing and improved multiscale network [J]. IEEE Transactions on Industrial Electronics, 2019, 67(4):3216 – 3225.

[6] 黄刚劲,范玉刚,黄国勇. CEEMD 与 FastICA 的故障特征提取方法[J]. 机械强度,2018,40(5):1024 – 1029.

HUANG Gangjin,FAN Yugang,HUANG Guoyong. Method of fault feature extraction based on CEEMD and FastICA[J]. Journal of Mechanical Strength,2018,40(5):1024 – 1029.

[7] 闫晓丽. 学形态学与混沌理论的滚动轴承故障诊断研究[D]. 北京:华北电力大学,2021.

YAN Xiaoli. Research on rolling bearing fault diagnosis based on mathematical morphology and chaos theory[D]. Beijing: Northern Electric Power University,2021.

[8] 孙 康,金江涛,李 春,等. 基于优化变分模态分解与混沌分形融合的滚动轴承故障识别 [J]. 动力工程学报,2022, 42(10):951 – 959,985.

SUN Kang,JIN Jiangtao,LI Chun,et al. Fault identification of rolling bearings based on optimized variational mode decomposition and chaotic fractal[J]. Journal of Chinese Society of Power Engineering,2022,42(10): 951 – 959,985.

[9] XIANG S Y. Research of fault diagnosis of rolling bearing based on wavelet packet and FSVM[J]. Journal of Physics: Conference Series,2018,1087(4):042061.

[10] DRAGOMIRETSKIY K,ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing,2014,62(3):

531 – 544.

[11] SUN Y,LI S,WANG X. Bearing fault diagnosis based on EMD and improved Chebyshev distance in SDP image [J]. Measurement,2021,176:109100.

[12] 周 浪,王礼桂,胡 雷,等. 基于分段累计近似与自适应噪声辅助集成经验模态分解的滚动轴承故障诊断方法 [J]. 轴承,2023,519(2):26 – 30.

ZHOU Lang,WANG Ligui,HU Lei,et al. Fault diagnosis method for rolling bearings based on PAA and CEEMDAN [J]. Bearing, 2023,519(2):26 – 30.

[13] 雷春丽,曹鹏瑶,崔 攀,等. 样本熵和 VMD 结合的轴承早期故障预测方法[J]. 机械设计与制造,2022,6:300 – 304.

LEI Chunli,CAO Pengyao,CUI Pan,et al. An early failure prediction method based on sample entropy and variational modal decomposition [J]. Machinery Design and Manufacture, 2022, 6: 300 – 304.

[14] INCE T,KIRANYAZ S,EREN L,et al. Real-time motor fault detection by 1D convolutional neural networks[J]. IEEE Transactions on Industrial Electronics,2016,63(11):7067 – 7075.

[15] WEN L,LI X,GAO L,et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics,2017,65(7):5990 – 5998.

[16] 郭俊锋,谭宝宏,王智明. 基于 MDAM-GhostCNN 的滚动轴承故障诊断方法[J/OL]. 北京航空航天大学学报:1 – 15[2023 – 11 – 09]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0224>.

GUO Junfeng,TAN Baohong,WANG Zhiming. Rolling bearing fault diagnosis method based on MDAM-GhostCNN[J/OL]. Journal of Beijing University of Aeronautics and Astronautics:1 – 15 [2023 – 11 – 09]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0224>.

[17] LI G,DENG C,WU J,et al. Rolling bearing fault diagnosis based on wavelet packet transform and convolutional neural network [J]. Applied Sciences,2020,10(3):770.

[18] MAJUMDAR A,BHUSHAN B. Fractal model of elastic-plastic contact between rough surfaces [J]. Journal of Tribology, 1991, 113(1):1 – 11.

[19] ROLPH S. Fractal geometry:Mathematical foundations and applications[J]. Mathematical Gazette,1990,74(469):288 – 317.

[20] MANDELBROT B B. How long is the coast of Britain? Statistical self-similarity and fractional dimension [J]. Science, 1967, 156(3775): 636 – 638.

[21] 徐 炜. 混沌背景中的弱信号检测和提取[D]. 上海:上海交通大学,2007.

XU Wei. Weak signal detection and extraction from chaos background signal[D]. Shanghai:Shanghai Jiao Tong University,2007.

[22] 孙 康,金江涛,李 春,等. 基于优化变分模态分解与混沌分形融合的滚动轴承故障识别 [J]. 动力工程学报,2022, 42(10):951 – 959,985.

SUN Kang,JIN Jiangtao,LI Chun,et al. Fault identification of

rolling bearings based on optimized variational mode decomposition and chaotic fractal[J]. Journal of Chinese Society of Power Engineering,2022,42(10):951-959,985.

[23] 张立国,刘婉,张淑清,等.基于相空间重构改进算法的混沌奇异谱分析及应用[J].计量学报,2021,42(10):1299-1306. ZHANG Liguo,LIU Wan,ZHANG Shuqing,et al. Chaotic singular spectrum analysis based on improved phase space reconstruction algorithm and its application[J]. Acta Metrologica Sinica, 2021,42(10):1299-1306.

[24] PACKARD N H,CRUTCHFIELD J P,SHAW R S. Geometry from a time series[J]. Physical Review Letters,2008,45:712.

[25] 蒋宇. 齿轮箱混沌特性与故障诊断研究[D]. 徐州:中国矿业大学,2021. JIANG Yu. Study on chaos characteristics and fault diagnostics of gearbox system[D]. Xuzhou: China University of Mining and Technology,2021.

[26] 宋锐. 基于混沌激励的结构损伤识别[D]. 南京:东南大学,2015. SONG Rui. Structural damage identification based on chaos incentive[D]. Nanjing:Southeast University,2015.

[27] ABARBANEL H D I,BROWN R,SIDOROWICH J J,et al. The analysis of observed chaotic data in physical systems[J]. Reviews of Modern Physics,1993,65(4):1331-1392.

[28] 张菁,樊养余,李慧敏,等.相空间重构中延迟时间选取的新算法[J].计算物理,2011,28(3):469-474. ZHANG Jing,FAN Yangyu,LI Huimin,et al. An improved algorithm for choosing delay time in phase space reconstruction[J]. Chinese Journal of Computational Physics, 2011, 28 (3): 469-474.

[29] 禹思敏.混沌系统与混沌电路:原理、设计及其在通信中的一个用[M].西安:西安电子科技大学出版社,2011. YU Simin. Chaotic system and chaotic circuit: Principle, design and application in communication[M]. Xi'an:Xi'an University of Electronic Science and Technology Press,2011.

[30] ABABANEL H D I,BROWN R,SIDOROWICH J J,et al. The analysis of observed chaotic data in physical systems[J]. Reviews of Modern Physics,1993,65(4):1331.

[31] LECUN Y,BOSER B,DENKER J S,et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation,1989,1(4):541-551.


[32] 郑洋. 风力发电系统的故障诊断方法研究[D]. 无锡:江南大学,2019. ZHENG Yang. Research on fault diagnosis method of the wind turbine system[D]. Wuxi:Jiangnan University,2019.

[33] Case Western Reserve University bearings data set. [EB/OL]. Available: <http://csegroups.case.edu/bearingdatacenter/pages/download-data-file>.

[34] WANG B,LEI Y,LI N,et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. IEEE Transactions on Reliability,2020,69(1):401-412.

[35] HUANG H,BADDOUR N. Bearing vibration data collected under time-varying rotational speed conditions[J]. Data in Brief,2018, 21:1745-1749.

(刘颖编辑)



捷克政府选择罗尔斯·罗伊斯公司 SMR 用于小型反应堆项目

2024 年 9 月,捷克政府和国家能源集团(ČEZ 集团)双方就发展小型模块化反应堆(SMR)达成协议,出资认购罗尔斯·罗伊斯公司20%的股份,并计划在 2030 年初启动第一座反应堆,以支持该国未来的能源安全。罗尔斯·罗伊斯公司 SMR 是基于小型压水反应堆的470 MWe 装机容量设计,可提供至少 60 年的持续基本负荷发电,该公司从 7 家潜在的 SMR 技术供应商中脱颖而出。

ČEZ 集团计划在南波西米亚 Temelín 核电站附近建造第一座小型反应堆。ČEZ 集团还探索在其他地点建造第二座和第三座小型反应堆,其中包括 Dětmarovice 和 Tušimice 核电站的厂址,目前正在对这些厂址进行勘探和监测,以评估它们是否适合核源部署。

(孙嘉忆摘译自 <https://www.powerengineeringint.com>)