

改进 CEEMDAN 算法与 CNN 融合的深度学习系泊故障研究

贾文哲, 闻 麒, 李 春, 岳敏楠

(上海理工大学 能源与动力工程学院, 上海 200093)

摘 要: 针对海上漂浮式风力机在长期的海洋环境作用下, 受到风、浪、流等复杂载荷的影响, 发生腐蚀、蠕变和失效等故障问题, 基于深度学习理论, 提出了一种改进的完全集合经验模态分解 (Improved Complete Ensemble EMD, ICEEMDAN) 结合卷积神经网络 (Convolutional Neural Network, CNN) 的故障诊断方法, 用于对海上漂浮式风力机的系泊系统进行故障识别。该方法基于平台艏摇响应信号状态, 计算系泊蠕变与失效阶段, 并分析不同位置系泊对漂浮式风力机稳定性的影响, 诊断出系泊是否产生蠕变以及系泊蠕变位置。研究结果表明: 改进后的方法能够较好地识别系泊蠕变到失效过程, 挖掘了纵荡、横荡、横摇及艏摇等因素对风力机稳定性的影响, 其在不同信噪比下均可有效地诊断出系泊状况与不同位置的蠕变, 且准确率最高可达 99.83%。

关 键 词: 漂浮式风力机; 改进 CEEMDAN 算法; CNN; 故障诊断

中图分类号: TH133

文献标识码: A

DOI: 10.16146/j.cnki.rndlgc.2023.11.017

[引用本文格式] 贾文哲, 闻 麒, 李 春, 等. 改进 CEEMDAN 算法与 CNN 融合的深度学习系泊故障研究[J]. 热能动力工程, 2023, 38(11): 141-150. JIA Wen-zhe, WEN Qi, LI Chun, et al. Improved CEEMDAN algorithm fused with CNN for deep learning of mooring faults[J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(11): 141-150.

Improved CEEMDAN Algorithm fused with CNN for Deep Learning of Mooring Faults

JIA Wen-zhe, WEN Qi, LI Chun, YUE Min-nan

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

Abstract: In the long-term presence of the ocean environment, floating offshore wind turbines (FOWT) are subjected to complex loads such as wind, waves, and currents, which may result in fault problems such as corrosion, creep and failure. To address this issue, this study proposes an improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) combined with convolutional neural network (CNN) method based on deep learning theory for fault diagnosis of the mooring system of offshore floating wind turbines. The method calculates the creep and failure stages of the mooring system based on the platform's yaw response signal status, analyzes the impact of mooring at different positions on the stability of floating wind turbines, and diagnoses whether creep occurs in the mooring system and its location. The research results show that the improved method can effectively identify the creep to fail-

收稿日期: 2022-12-31; 修订日期: 2023-03-07

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

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

作者简介: 贾文哲 (1987-), 男, 上海理工大学博士研究生。

通讯作者: 李 春 (1963-), 男, 上海理工大学教授。

ure process of the mooring system, explore the impact of surge, sway, roll and yaw factors on the stability of wind turbines, and can accurately diagnose the mooring condition and creep at different positions under different signal-to-noise ratios (SNR), with a highest accuracy rate of 99.83%.

Key words: FOWT, ICEEMDAN algorithm, CNN, fault diagnosis

引 言

推进清洁、低碳可再生能源转型是减少环境污染、缓解能源供需矛盾的可行途径^[1]。风能因储量丰富、开采便利、分布广泛,成为理想替代能源。海上风能无长距离能源损耗,发展迅速。随水深增大,漂浮式风力机适用于更广海域范围且施工安装更灵活,前景广阔^[2]。

漂浮式风力机以系泊与海底相连,以提供定位和回复力,避免漂移和倾倒^[3]。在复杂的海洋环境下,系泊受到的拉力更大,受力方向更多变,容易出现故障^[4],同时也导致平台动态响应增大,影响风力机发电量和相邻风力机的安全运行^[5]。系泊伸长率会影响其在海水中的耐腐蚀性能,加速系泊腐蚀,提高失效概率并缩短其使用寿命^[6]。漂浮式风力机遭受极端环境后,系泊容易产生蠕变,进一步削弱抗腐蚀与承载能力,加剧与海底的磨损,长时间作用下更易失效^[7]。因此,及时发现系泊问题,确保其在风力机生命周期中的安全性至关重要。

近年来,深度学习技术被广泛应用于学术研究与工业中的复杂信号处理。其中,卷积神经网络(Convolutional Neural Network, CNN)通过对大量数据进行逐步分类识别,将数据的局部特征与全局特征提取出来^[8-9],鲁棒性强,尤其擅长处理时间信号。文献[10]构建了相空间-CNN故障诊断模型,对不同工作状态下齿轮箱的振动信号进行分析发现,不同状态下轴承振动信号具有明显混沌特性。文献[11]采用卷积神经网络和振动信号融合对风力机叶轮的裂缝进行故障诊断,经过统计不同裂纹的数据样本库,实现高精度故障诊断效果。文献[12]通过CNN对不同叶轮的图片进行分析,准确地辨识出叶片的结冰状况。文献[13]基于卷积神经

网络对风力机叶片频谱信息进行识别,提取故障特征,精确地检测出叶片的气动与质量不平衡。

集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)在原数据中增添高斯白噪声,并进行经验模态分解(Empirical Mode Decomposition, EMD)通过多次分解来消除异常干扰,减少经验模态分解算法的模式混叠。CEEMDAN添加了本征模态函数(Intrinsic Mode Function, IMF)分量,解决白噪声从高频到低频的传递问题,避免了异阶分量的计算。但是得到的本征模态分量中又存留了部分白噪声,导致后续信号的处理出现问题。因此,文献[14]提出了ICEEMDAN,较好地解决残留噪声和伪模态的问题。

关于风力机故障诊断的研究较多,但多关注于风力机叶片、轴承齿轮箱的情况,鲜有关于海上漂浮式风力机的研究。风电发展“由陆向海”已成学界共识,对适用于更广阔海域的漂浮式风力机研究必不可少^[15]。

本文计算了不同位置系泊失效后,漂浮式风力机Barge平台动态响应,并且基于改进的CEEMDAN与CNN融合的深度学习方法对平台动态响应的数据进行诊断,确定系泊是否发生蠕变以及系泊蠕变的具体位置,为系泊故障诊断提供技术支持。Barge平台是由英国ITI能源有限公司资助开发的,因此也称为ITI Barge平台。

1 研究对象

1.1 漂浮式风力机模型

研究对象为美国可再生能源实验室(NREL)提供的5 MW风力机样本和ITI Barge平台。图1是漂浮式风力机示意图^[16]。表1和表2分别为风力机和平台的主要参数表。




图 1 ITI Barge 平台漂浮式风力机示意图
Fig. 1 Schematic diagram of FOWT on ITI Barge platform

表 1 NREL 5 MW 风力机

参 数	数值
功率/MW	5
叶片数	3
风轮直径/m	126
额定转速/ $r \cdot \min^{-1}$	12.1
切入风速/ $m \cdot s^{-1}$	3
额定风速/ $m \cdot s^{-1}$	11.4
切出风速/ $m \cdot s^{-1}$	25
轮毂直径/m	3
塔架高度/m	90
风轮质量/ $10^5 kg$	1.1
塔架质量/ $10^5 kg$	3.5
机舱质量/ $10^5 kg$	2.4

表 2 ITI Barge 平台

参 数	数值
长 × 宽/m	40 × 40
吃水深度/m	4
质心/m	-0.282
排水量/ m^3	6×10^3
质量/kg	5.452×10^6
导缆孔数量	4
系泊数量	8
横摇惯量/ $10^8 kg \cdot m^2$	7.269
纵摇惯量/ $10^8 kg \cdot m^2$	7.269
艏摇惯量/ $10^9 kg \cdot m^2$	1.454

1.2 浮式风力机系泊系统

Barge 平台是一个长方体,通过底部 4 个角的导

缆孔连接到海底锚点,每个角有两根系泊,系泊之间的夹角为 45°。平台系泊参数如表 3 所示^[17]。因为系泊上下对称,文中只分析上半部分的 4 根系泊。系泊选用材料为合成纤维绳,仅考虑其刚度、阻尼、最大承受拉力线密度等参数。系统示意图如图 2 所示。

表 3 系泊参数
Tab. 3 Mooring parameters

参 数	数值
单位长度质量/ $kg \cdot m^{-1}$	129.5
等效截面积/ m^2	0.006 36
最大张力/N	7.5×10^6
轴向刚度/ $N \cdot m^{-1}$	7.5×10^8
系泊长度/m	473.3




图 2 系泊示意图
Fig. 2 Mooring diagram

2 环境载荷与参数

在海洋环境中,漂浮式风力机的主要载荷包括:叶轮受到的风载荷,平台受到的波浪载荷和流载荷^[18]。

2.1 风载荷

风载荷主要作用于上部叶轮和塔架,用叶素动量理论计算叶轮受到推力与扭矩,由公式(1)的两式分别表示:

$$\begin{cases} dQ=0.5\rho c\frac{(\Omega\cdot r(1+b))^2}{\cos^2\theta}(C_1\sin\theta-C_d\cos\theta)dr \\ dN=0.5\rho c\frac{U_\infty^2(1-a)^2}{\sin^2\theta}(C_1\cos\theta-C_d\sin\theta)dr \end{cases} \quad (1)$$

式中: c —距轮毂中心 r 处风力机叶片弦长; m ; ρ —空气密度, kg/m^3 ; Ω —风轮转速, r/s ; b —切向诱导因子; a —轴向诱导因子; U_∞ —来流速度, m/s ; θ —来流攻角; C_l —升力系数; C_d —阻力系数。

2.2 波浪载荷

采用辐射绕射理论来计算平台的波浪载荷,因为 Barge 平台体型较大,需考虑平台的海水绕射效应。作用在平台上波浪力与力矩分别表示为:

$$F_W = \iint_{S_B} -p \vec{n} dS_B \tag{2}$$

$$M_W = \iint_{S_B} -p(\vec{r} \times \vec{n}) dS_B \tag{3}$$

式中: F_W —波浪力; N ; S_B —湿表面面积, m^2 ; M_W —波浪力矩, $\text{N} \cdot \text{m}$; $\vec{r}$ —结构物表面到基点矢量; $\vec{n}$ —结构物表面法线方向。

2.3 流载荷

海流是在太阳辐射、海水热胀冷缩及降水等作用下,导致不同区域的海水存在密度差,从而形成的大规模海水定向流动现象,是海水主要运动形式^[19]。额定海况下,海流速度较缓,对海上结构的作用主要表现在拖曳力,可表示为:

$$F_c = \frac{1}{2} \rho_s C_d A U_o^2 \tag{4}$$

式中: U_o —流速, m/s ; A —平台的等效面积, m^2 ; ρ_s —海水密度, kg/m^3 。

2.4 环境参数

图 3 为湍流风速谱与波高时间序列图。在图 3(a)中,参照 IEC 61400-3,采用 Fast 中的 Turb-Sim 模块^[20],风谱选择 Kaimal,风速取 $11.4 \text{ m}/\text{s}$,生成湍流风场。选 P-M 波谱计算浪载荷,波浪峰值取 6 m ,跨零周期取 10.1 s 。图 3(b)是波高时历曲线。海流为均匀流,流速 $0.8 \text{ m}/\text{s}$ 。

3 改进 CEEMDAN 融合 CNN 诊断方法

3.1 改进 CEEMDAN 算法

CEEMDAN 算法可以有效地减少模态混叠,但无法完全消除冗余和伪分量。而多数文献多采用皮尔森系数、峭度和灰色关联度等方法提取最优本征模态函数分量,忽视了故障信息可能存在着部分本征模态函数分量,导致有用信息无法完全提取。采

用分形维数和主成分分析 (Principal Component Analysis, PCA) 相结合的方法改进了 CEEMDAN。主成分分析通过数据降维来实现对有效故障信息的提取,利用交叉分析法计算最佳分量组,分形维数越大表明信号越混乱,反之,则表明信号越稳定。改进 CEEMDAN 算法流程图如图 4 所示。




图 3 湍流风速谱与波高时间序列
Fig. 3 Turbulent wind speed spectrum and time series of wave height




图 4 改进 CEEMDAN 算法流程图
Fig. 4 Flow chart of improved CEEMDAN algorithm

3.2 仿真信号分析

利用合成仿真信号 $x(t)$ 验证 ICCEMDAN 的分解精度,其中分量 $x_1(t)$ 为单一调频信号, $x_2(t)$ 为两段不同频率的两个正弦信号之和, $x_3(t)$ 为分段信号。具体表达式为:

$$\begin{cases} x_1(t) = 0.6\sin(10\pi t + 20\pi) \\ x_2(t) = 0.7\sin(1\,000\pi t) + \sin(1\,800\pi t) \\ x_3(t) = \begin{cases} 0.6\cos(400\pi t), t \in [0.1, 0.2] \\ 0.5\cos(400\pi t), t \in [0.3, 0.4] \\ 0.4\cos(400\pi t), t \in [0.5, 0.6] \\ 0.3\cos(400\pi t), t \in [0.7, 0.8] \end{cases} \\ x(t) = x_1(t) + x_2(t) + x_3(t) \end{cases} \quad (5)$$

设采样频率为 1 000 Hz,采样时长为 1 s,采用 ICCEMDAN 对 $x(t)$ 进行分解,时域波形如图 5 所示。




图 5 时域图
Fig. 5 Time domain diagrams

为体现 ICCEMDAN 分解效果,采用变分模态分解 (Variational Mode Decomposition, VMD) 算法对数据进行分解,借鉴集合经验模态分解 (Ensemble Empirical Mode Decomposition, EEMD) 算法递归特性^[21]确定 VMD 模态分解数 K , c 是合成信号的采样频率,取值与采样频率相同,即 $K = 3, c = 1\,000$ 。两种方法分解所得 IMF 与原信号的相关系数如表 4 所示。

由图 5 及表 4 可知,经 ICCEMDAN 分解所得 IMF 与合成信号相关系数高达 99% 以上,可有效分解风力机平台振动信号。

表 4 仿真信号与各 IMF 相关系数

Tab. 4 Correlation coefficients between simulation signal and IMF

仿真信号	分解方法	IMF1/%	IMF2/%	IMF3/%
$x(t)$	ICCEMDAN	99.87	99.78	99.63
$x(t)$	VMD	95.12	91.32	90.46

3.3 卷积神经网络

CNN 通过自动学习训练卷积核来提取特征数据,免去人为过程,自学能力强^[22],在故障诊断领域普遍应用。CNN 主要包含 3 层:卷积层,主要用来提取数据特征;池化层,主要用来进行下采样,但不会损坏识别结果;全连接层,主要用来进行特征分类。

在获取输入数据后,卷积层通过多个不同尺度卷积核与输入矩阵做卷积运算获取前面层的特征,再一步步偏置,基于激活函数得到特征矢量,其公式为:

$$X_j^l = f\left(\sum_{i \in M_j} X_i^{l-1} \times \omega_{ij}^l + b_j^l\right) \quad (6)$$

式中: X_j^l —第 l 层第 j 个元素; M_j —第 j 个卷积区域; ω_{ij}^l —对应卷积核的权重矩阵; b_j^l —偏置项; $f(\cdot)$ —激活函数。

池化也称下采样,是为了解决卷积层特征提取后数据量庞大,提高 CNN 效率的一种方式。可减少卷积层间神经元数量、提高计算效率及避免过拟合,其运算表达式为:

$$X_j^l = f(\beta_l \cdot \text{down}(X_j^{l-1}) + b_j^l) \quad (7)$$

式中: β_l —权值矩阵; $\text{down}(\cdot)$ —降采样函数。

池化包括均值池化与最大值池化,其中后者最常用,可表示为:

$$X^l = \max_{(i-1)l+1 \leq i \leq il} X^{l-1}(t) \quad (8)$$

式中: l —池化区域长度。

Dropout 正则化技术一般置于全连接层之前,可防止过拟合,其过程可表示为:

$$y = f(\beta_2 x) \cdot m, m_i \sim \text{Bernoulli}(p) \quad (9)$$

式中: x —输入量; β_2 —权值矩阵; y —输出。

针对所分析的系泊蠕变动态响应,设计的 CNN 模型框架模型参数如表 5 所示。

表 5 模型参数
Tab.5 Parameters of model

网络层	卷积核数量@ 卷积核大小	池化 区域	步长	网络层输出 (卷积核数量@ 输入信号的长度)
输入层	-	-	-	1@ 2048 × 1
卷积层 C1	16@ 11 × 1	-	[4 1]	16@ 510 × 1
池化层 S1	-	[2 1]	[2 1]	16@ 255 × 1
卷积层 C2	32@ 5 × 1	-	[2 1]	32@ 126 × 1
池化层 S2	-	[2 1]	[2 1]	32@ 63 × 1
卷积层 C3	32@ 3 × 1	-	[1 1]	32@ 61 × 1
池化层 S3	-	[2 1]	[2 1]	32@ 30 × 1
卷积层 C4	64@ 2 × 1	-	[1 1]	64@ 29 × 1
池化层 S4	-	[2 1]	[2 1]	64@ 14 × 1
卷积层 C5	128@ 2 × 1	-	[1 1]	128@ 13 × 1
池化层 S5	-	[2 1]	[2 1]	128@ 6 × 1
Dropout 层	-	-	-	128@ 6 × 1
全连接层	-	-	-	9@ 1 × 1

3.4 改进 CEEMDAN 融合 CNN 诊断流程

针对单一 CEEMDAN 和 CNN 算法存在的不足，本文提出改进 CEEMDAN 结合 CNN 的故障诊断方法，诊断流程如图 6 所示。




图 6 故障诊断流程图
Fig. 6 Flow chart of fault diagnosis


4 结果与分析

4.1 系泊失效过程中平台的动态响应

海洋环境中，在风浪同向入射时，迎风侧系泊承受的载荷最大，系泊张力最大，平台响应会导致迎风侧系泊拉力显著波动，因此更容易发生系泊损伤和失效。

计算中设置风浪方向一致，沿着风轮平面的法线方向入射，平台的 8 根系泊沿中线对称，故仅对平台一侧的系泊进行分析。对系泊正常状态、系泊发生蠕变及系泊失效 3 个阶段的平台动态响应曲线以及各阶段最大幅值进行对比。如图 7 所示。

图 7 中，0 ~ 3 000 s 为系泊正常运行时平台的动态响应，3 000 ~ 6 000 s 为发生蠕变后平台的动态响应，6 000 ~ 9 000 s 为失效后平台的动态响应。图中的柱状图表示 3 个阶段平台各自由度的最大响应幅值，其值在左轴显示，且单位与右轴相同。经对比可知，与正常状态相比系泊在蠕变及失效阶段，平台的动态响应幅值均会不同程度增大。






图 7 系泊在正常、蠕变及失效阶段平台六自由度响应
Fig. 7 Platform responses in six free degrees in normal, creep and failure stages of mooring

受系泊状态变化影响最大的自由度为横荡、纵荡、艏摇及横摇,而纵摇与垂荡方向受到影响后变化较小。横荡与纵荡响应幅值变化最大是因为系泊状态改变后,系泊张力变小,导致平台纵向与横向受力不均。横摇与艏摇增大是由于系泊状态变化后各位置系泊的拉力不同,对平台扭矩产生了变化。

对于平台的横荡、纵荡、横摇及艏摇 4 个自由度,系泊产生蠕变后平台的响应幅值变化不是很明显,但在失效后平台响应幅值急剧增大,对比不同系

泊失效后的平台响应幅值,迎风侧系泊(1,2 号系泊)失效对平台影响最大,背风侧系泊(3,4 号系泊)引起的变化相对较小。

4.2 基于卷积神经网络(CNN)的系泊故障诊断

文献[23]研究表明,纵荡与纵摇均会导致风轮推力的增大。增大 1° 的纵摇响应幅度,风轮受到推力变化幅度波动将达 10% 以上,这将使得漂浮式风力机叶片摆振大幅增加,叶片弯矩急剧上升。此外,因风轮受力增大,塔架及剩余系泊安全将直接受到影响。因此,需要提前判断系泊是否处于蠕变阶段,以采取有效措施预防系泊失效。

系泊状态产生变化后,平台艏摇比其他方向更敏感,故以平台艏摇响应数据作为特征数据进行分析。系泊正常状态对应的系泊蠕变后平台艏摇数据样本标签为 0,系泊 1,2,3,4 对应的样本标签分别为 1,2,3,4。其对应的时域响应如图 8 所示。




图 8 不同系泊蠕变阶段平台艏摇响应
Fig. 8 Platform yaw responses in different creep stages of mooring

为增加不同系泊受损后平台艏摇的样本数量,从而增加准确率。对各组数据进行重采样,重采样方式如图 9 所示。




图 9 数据重采样

Fig. 9 Data augment with overlap

依据改进的 CEEMDAN 筛选最优重构分量,使用 CNN 验证并与集合经验模态分解法(改进 EE-MD-CNN)及经验模态分解法(改进 EMD-CNN)进行对比。将平台艏摇响应的数据集按 8:1:1 比例训练、测试及验证,并利用重采样法提高样本数量和识别精度。在无噪声环境下,训练集的准确率和损失如图 10 所示。由图 10 可知,在准确率和损失方面,改进的 CEEMDAN 结合 CNN 法均优于其他算法,具有良好的可行性与鲁棒性。




图 10 训练集准确率和损失

Fig. 10 Accuracy and loss of training set

为进一步检验其良好的实用性和泛化性,需尽量减轻混杂噪声,还原实际运行环境,图 11 为各方法不同信噪比下识别准确率。由图 11 可知,改进的 CEEMDAN 结合 CNN 法有较好的泛化性,不同信噪

比下都能很好的还原实际环境,且与准确率呈正相关趋势,间接给出了噪声对故障诊断精度的影响。改进后的算法比原始算法具有更高识别度,筛选最佳重构分量的分类精度也更高,其准确率最高可达 99.83%,在信噪比最低时(-6 dB) 仍达到 87.13% 识别度,比其他算法高 0.53% ~ 10.43% 。




图 11 各方法不同信噪比下识别准确率

Fig. 11 Recognition accuracy of each method under different SNRs

改进的 CEEMDAN 结合 CNN 算法可较好地摒除伪分量与冗余信号,实现降噪处理,提高有效故障体征提取的准确性,增强了故障诊断识别和分类精度。

采用 t 分布随机邻域嵌入法(t -Distributed Stochastic Neighbor Embedding, t -SNE) 将高维度数据可视化。首先数据点之间的高维非线性信号转化为表示相似性的条件概率,然后嵌入到最小化低维数据和高维数据联合概率之间。降维后各层的可视化结果如图 12 所示。由图可知,随着卷积层增加,模型对特征数据的捕捉逐渐加深,图中数据点间流行分布越来越明显,不同故障类型数据点间重叠部分逐渐消失,间距加大,更加容易辨识。在卷积层 3 与 4 中,系泊正常状态下平台响应的特征数据已明显分离;在卷积层 5 中,系泊 3,4 发生蠕变的平台响应数据与其他 3 种系泊状态的数据已经大体分离,在全连接层中,5 种状态已全部分离,说明通过改进 CEEMDAN 与 CNN 结合的深度学习方法可有效从不同系泊状态下平台响应的二维时域数据中提取纯净的非线性信息。




图 12 模型中各层降维可视化结果

Fig. 12 Visualization results of dimensionality reduction in each layer of model

5 结 论

海上漂浮式风力机系泊在风、浪、流载荷长期作用下会产生腐蚀、蠕变甚至失效,在计算了不同位置系泊蠕变与失效阶段平台动态响应后,提出了改进 CEEMDAN 与 CNN 结合的深度学习方法。并基于此方法对平台响应数值进行特征提取和诊断,对系泊状态进行特征识别,得出系泊是否产生蠕变以及蠕变位置,对预防系泊失效有重大的意义,并得出如下结论:

(1) 系泊从蠕变阶段到失效,平台的六自由度响应幅值显著增大。艏摇、横摇、横荡、纵荡受影响最明显,纵荡与垂摇方向变化较小。且迎风侧系泊失效对平台影响最显著,背风侧影响最小。

(2) 改进的 CEEMDAN 结合 CNN 法有明显的优越性,且表现出良好的抗噪性能,在不同信噪比下最高可达 99.83%,具有较好的泛化性能。

(3) 不同位置系泊发生蠕变后,CNN 在诊断平台响应特征数据时损失率低、准确率高,且收敛速度快,诊断效果好。

(4) 经 t 分布随机邻域嵌入法可视化后,可较好地展现所提方法对不同系泊蠕变后信号识别与分类效果。

参考文献:

[1] ZHANG J,ZHANG J W,CAI L,et al. Energy performance of wind power in China: a comparison among inland, coastal and offshore wind farms [J]. Journal of Cleaner Production, 2017, 143 (1) : 836 – 842.

[2] 单鹏昊. 深海浮式平台及其系泊缆索的时域耦合分析 [D]. 哈尔滨: 哈尔滨工程大学, 2013.

SHAN Peng-hao. Time-domain coupling analysis of deepwater floating platform and the mooring lines [D]. Harbin: Harbin Engineering University, 2013.

[3] 王东华,叶舟,张楠,等. 海上漂浮式风力机 Spar 平台系泊型式及动态响应研究 [J]. 热能动力工程, 2017, 32 (2) : 106 – 112, 141.

WANG Dong-hua, YE Zhou, ZHANG Nan, et al. Research on mooring pattern and dynamic response of floating wind turbine Spar platform and mooring type [J]. Journal of Engineering for Thermal Energy and Power, 2017, 32 (2) : 106 – 112, 141.

[4] CHENG Z, MADSEN H A, CHAI W, et al. A comparison of extreme structural responses and fatigue damage of semi-submersible type floating horizontal and vertical axis wind turbines [J]. Renewable Energy, 2017, 108: 207 – 219.

[5] GU J Y, CHEN Y, GENG P T, et al. Study on the dynamic response and tension characteristics of a TLP with one tendon broken [J]. Journal of Ship Mechanics, 2015, 19 (12) : 1488 – 1497.

[6] BAE Y H, KIM M H, KIM H C. Performance changes of a floating offshore wind turbine with broken mooring line [J]. Renewable Energy, 2017, 101: 364 – 375.

[7] ZHANG X L, HOOGELAND M. Influence of deformation on corrosion of mooring chain steel in seawater [J]. Materials and Corrosion, 2019, 70 (6) : 1 – 15.

[8] 丁承君,冯玉伯,王曼娜. 基于变分模态分解与深度卷积神经网络的滚动轴承故障诊断 [J]. 振动与冲击, 2021, 40 (2) : 287 – 296.

DING Cheng-jun, FENG Yu-bo, WANG Man-na. Rolling bearing fault diagnosis using variational mode decomposition and deep convolutional neural network [J]. Journal of Vibration and Shock, 2021, 40 (2) : 287 – 296.

[9] 任浩,屈剑锋,柴毅,等. 深度学习在故障诊断领域中的研究现状与挑战 [J]. 控制与决策, 2017, 32 (8) : 1345 – 1358.

REN Hao, QU Jian-feng, CHAI Yi, et al. Deep learning for fault diagnosis: the state of the art and challenge [J]. Control and Decision, 2017, 32 (8) : 1345 – 1358.

[10] 许子非,岳敏楠,李春. 基于卷积神经网络风力机轴承混沌空间故障分析与诊断 [J]. 热能动力工程, 2020, 35 (6) : 243 –

250,256.

XU Zi-fei, YUE Min-nan, LI Chun. Fault diagnosis and analysis of wind turbine bearing chaotic phase based on convolutional neural network[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(6): 243 – 250, 256.

[11] 郭迎福, 全伟铭, 王文韞, 等. 基于三维振动信息融合的卷积神经网络风力机叶片裂纹诊断方法[J]. 光学学报, 2020, 40(22): 134 – 142.

GUO Ying-fu, QUAN Wei-ming, WANG Wen-yun, et al. Crack diagnosis method of wind turbine blade based on convolution neural network with 3D vibration information fusion[J]. Acta Optica Sinica, 2020, 40(22): 134 – 142.

[12] KREUTZ M, ALLA A A, EISENSTADT A, et al. Ice detection on rotor blades of wind turbines using RGB images and convolutional neural networks[J]. Procedia CIRP, 2020, 93: 1292 – 1297.

[13] CAO Z, XU J, XIAO W, et al. A novel method for detection of wind turbine blade imbalance based on multi-variable spectrum imaging and convolutional neural network[C]// 2019 Chinese Control Conference, Guangzhou, China, 2019.

[14] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]//Proceedings of 2011 IEEE International Conference on Acoustics, Speech and Signal Processing, Prague, Czech Republic, 2011.

[15] HEMMATI A, OTERKUS E, BARLTROP N, et al. Fragility reduction of offshore wind turbines using tuned liquid column dampers[J]. Soil Dynamics and Earthquake Engineering, 2019, 125: 105705.

[16] JONKMAN J, MATHA D. Quantitative comparison of the responses of three floating platforms[J]. Australian Historical Studies, 2010, 32(3): 351 – 355.

[17] JONKMAN J, MATHA D. Dynamics of offshore floating wind turbines-analysis of three concepts[J]. Wind Energy, 2011, 14(4): 557 – 569.

[18] YE K, JI J C. Current, wave, wind and interaction induced dynamic response of a 5 MW Spar-type offshore direct-drive wind turbine[J]. Engineering Structures, 2019, 178: 395 – 409.

[19] 河海大学《水利大辞典》修订委员会. 水利大辞典[M]. 上海: 上海辞书出版社, 2015.

Revision Committee of Water Conservancy Dictionary of Hohai University. Water conservancy dictionary[M]. Shanghai: Shanghai Lexicographical Publishing House, 2015.

[20] JONKMAN B J, BUHL M L. TurbSim user's guide[R]. Colorado; National Renewable Energy Laboratory, 2005.

[21] 刘 洋, 曹云东, 侯春光. 基于经验模态分解及维格纳威尔分布的电缆双端故障定位算法[J]. 中国电机工程学报, 2015, 35(16): 4086 – 4093.

LIU Yang, CAO Yun-dong, HOU Chun-guang. The cable two-terminal fault location algorithm based on EMD and WVD [J]. Proceedings of the CSEE, 2015, 35(16): 4086 – 4093.


[22] 李彦冬, 郝宗波, 雷 航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508 – 2515.

LI Yan-dong, HAO Zong-bo, LEI Hang. Survey of convolutional neural network [J]. Journal of Computer Applications, 2016, 36(9): 2508 – 2515.

[23] 京 泰. 10 MW 浮式风机气动性能的 CFD 流固耦合模拟研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.

JING Tai. CFD simulation with fluid-structure interaction for aerodynamic performace of a 10 MW floating off-shore wind turbine [D]. Harbin: Harbin Institute of Technology, 2019.

(姜雪梅 编辑)



中国订购通用电气公司的氢气燃气轮机用于 1.7 GW 绿色燃气电厂

中国国家开发投资有限公司(国投)冀能燃气发电有限公司已向 GE Vernova 订购了两台氢气燃气轮机, 用于新建联合循环发电厂。这座 1.7 GW 的发电厂将位于中国浙江省舟山群岛, 为中国最大的群岛供电, 该群岛由 1 390 个岛屿组成。

GE Vernova 表示, 从煤炭转换为天然气可以当量减少多达 60% 的碳排放量。这些燃气轮机可增强浙江省的供电能力和电网调峰能力, 以增加电网灵活性。首台机组计划于 2025 年底开始运行, 预计未来将燃烧掺氢比高达 10% 的天然气混合燃料。目前, 该公司已在中国大陆获得了由 10 台 GE H 级燃气轮机提供动力的 5 个项目, 预计全面运行后电厂装机容量将超过 8 GW。作为最早进入中国的国际燃气轮机制造商和服务供应商之一, GE Vernova 旗下燃气发电业务植根中国市场 40 余年。

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