

DOI: 10.19650/j.cnki.cjsi.J2614962

基于 SADeformer 的风电机组叶根载荷虚拟感知*

江国乾¹, 赵天健¹, 王钧尧¹, 岳 健², 丁雪娟²

(1. 燕山大学电气工程学院 秦皇岛 066004; 2. 北京金风慧能技术有限公司 北京 100176)

摘 要:叶根载荷的精准测量对风电机组叶片疲劳寿命评估和健康管理具有重要工程价值。当前叶根载荷直接测量存在硬件成本高、长期运行可靠性不足、难以规模化部署的难题,而风电机组标配的数据采集与监视控制系统(SCADA)为叶根载荷的低成本间接测量提供了可行路径。为此,针对 SCADA 多源传感数据强耦合、非平稳特性带来的载荷测量精度不足问题,提出一种基于 SCADA 数据的叶根载荷虚拟感知方法,利用对称感知的时空可变形 Transformer 模型(SADeformer)实现高精度载荷反演。该模型在特征提取环节采用变量维度可变形注意力块(V-DAB)与时间维度可变形注意力块(T-DAB)的协同架构,分别捕获变量间的非线性依赖关系和时间序列中的长短期关联,再经由多层感知机预测器输出三叶片挥舞、摆振方向的载荷感知结果。同时,结合风电机组叶片的物理对称性先验知识,设计新型对称性损失函数,对叶片挥舞和摆振载荷的空间一致性进行建模。实验结果表明,基于 SCADA 数据的所提测量方法,在秒级载荷数据反演中表现最优,决定系数(R^2)达 0.952,平均绝对百分比误差(MAPE)低至 0.8%,综合性能优于主流时序模型;引入对称性物理约束后,三叶片载荷测量误差显著下降,验证了方法的有效性。

关键词: 风电机组; 叶根载荷; 注意力机制; 虚拟感知; 对称性损失

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 460.99

Virtual sensing of wind turbine blade root loads based on SADeformer

Jiang Guoqian¹, Zhao Tianjian¹, Wang Junyao¹, Yue Jian², Ding Xuejuan²

(1. School of Electrical Engineering, Yanshan University, Qinhuangdao 066004, China; 2. Beijing Goldwind Smart Energy Technology Co., Ltd., Beijing 100176, China)

Abstract: Accurate measurement of blade root loads is of critical engineering value for fatigue life assessment and health management of wind turbine blades. Current direct measurement methods suffer from high hardware cost, insufficient long-term operational reliability and difficulty in large-scale deployment. In contrast, the standard supervisory control and data acquisition (SCADA) system equipped on wind turbines provides a feasible low-cost alternative for indirect blade root load measurement. To address the insufficient measurement accuracy caused by strong coupling and non-stationary characteristics of multi-source SCADA sensing data, this paper proposes a SCADA-data-based virtual sensing method for blade root loads, which employs a symmetry-aware spatiotemporal deformable Transformer (SADeformer) for high-precision load inversion. In the feature extraction stage, the model adopts a collaborative architecture of variable-dimension deformable attention block (V-DAB) and time-dimension deformable attention block (T-DAB) to respectively capture nonlinear inter-variable dependencies and both long short-term temporal correlations, respectively. The model then outputs flapwise and edgewise load sensing results of three blades via a multi-layer perceptron predictor. Moreover, by integrating the prior physical knowledge of wind turbine blade symmetry, a new symmetry loss function is designed to model the spatial consistency of blade flapwise and edgewise loads. Experimental results demonstrate that the proposed method achieves state-of-the-art performance in second-level load data inversion, with a coefficient of determination (R^2) of up to 0.952 and a mean absolute percentage error (MAPE) as low as 0.8%, outperforming mainstream time series models in comprehensive performance. The introduction of symmetry physical constraint significantly reduces three-blade load measurement errors, verifying the effectiveness of the proposed method.

Keywords: wind turbine; blade root load; attention mechanism; virtual sensing; symmetry loss

收稿日期: 2026-02-22 Received Date: 2026-02-22

* 基金项目: 国家自然科学基金(62273299)、京津冀自然科学基金合作专项(25JJJC0009)项目资助

0 引言

随着全球能源结构向低碳化加速转型,风电机组作为风能转化的关键装备,其运行可靠性直接决定风电场的经济效益与安全水平^[1-2]。叶片是风电机组捕获风能的关键部件,长期承受湍流风载荷、重力及惯性力的耦合作用,叶根部位因应力集中极易发生疲劳损伤。据统计,叶片故障导致的损失约占风电场总故障损失的 23%^[3],而叶根载荷的精准测量,是评估叶片疲劳损伤、制定健康管理策略的重要依据^[4-5]。

当前叶根载荷的主流测量方案为叶片预埋应变片直接测量,该方案虽能获取直接载荷数据,但存在显著的工程痛点:1)应变片长期在野外高温、高湿、强腐蚀环境下运行,易老化失效,维护与更换成本极高;2)传感器预埋需改造叶片本体结构,存在安全风险,无法在存量机组大量部署;3)高频载荷测量系统的采样、传输、存储成本高,难以实现全场覆盖。因此,研发低成本、高可靠性、可规模化部署的叶根载荷间接测量方法,对风电机组实时状态监测、故障预警及运维决策具有重要的工程价值^[6]。

风电机组标配的数据采集与监视控制系统(supervisory control and data acquisition, SCADA)是集数据采集、传输、分析、控制于一体的工业级测控仪表系统,可实时采集风速、风向、桨距角、机舱加速度等多种运行参量,为载荷间接测量提供了丰富的多源传感数据支撑,且基于 SCADA 数据的虚拟感知技术已广泛应用于风电机组关键参数的间接监测^[7-8],为解决叶根载荷直接测量难题提供了可行路径。

叶根载荷虚拟感知本质上是一类基于多源传感数据的强非平稳、高维度时序建模问题。风电机组运行过程中,叶根挥舞及摆振方向载荷受风速、风向、转速、桨距角等多运行参量的动态耦合影响,高频时序数据中既包含湍流风引发的高频波动,又叠加阵风、变工况导致的趋势性变化,呈现出强非线性、非平稳的复杂特征^[9]。此外,风电机组三叶片沿轮毂 120°均匀分布的空间对称性,使得各叶片载荷存在天然的物理约束关系,对虚拟感知模型的动态表征能力提出了更高要求。

传统感知建模方法在处理此类问题时存在明显瓶颈。基于物理机理的模型(如气动-伺服-弹性模型)虽能刻画载荷传递规律,但依赖精确的叶片气动参数与复杂流场计算,实时性差,且无法充分利用 SCADA 系统的海量实测数据^[10]。在深度学习方法的探索中,付德义等^[11]基于反向传播(back propagation, BP)神经网络构建了风电机组叶片载荷评估模型,实现了简单场景下的载荷虚拟感知,但未有效融合 SCADA 多变量与载荷数据的耦合特性。Santos 等^[12]提出一种数据驱动方法,利用机

舱加速度计数据、SCADA 数据及 3 台装有应变片的样板风机数据,训练模型进行全场范围的风机过渡段连接面疲劳载荷估算,9 个月内月度累积误差低于 5%,能识别异常风机并关联其运行条件;岳健等^[13]提出基于 Transformer 架构的多级特征提取模型,充分利用 SCADA 数据增强了小样本场景下的载荷预测效果,但固定的注意力分配模式难以适配 SCADA 变量与载荷数据间时空动态变化的关联关系。金晓航等^[14]提出一种改进多层自组织映射网络方法,通过长短期记忆网络(long short-term memory, LSTM)预测残差和分层 SOM(self organizing map)融合实现了部件到整机的状态监测,但其研究对象主要集中在传动链与电气系统等关键部件,尚未覆盖叶片这一易损且影响显著的部件。Moynihan 等^[15]采用高斯过程回归,基于 SCADA 数据实现了海上风机塔筒弯矩的虚拟感知,均方根误差(root mean square error, RMSE)均小于 15%,但存在对弯矩物理机制捕捉不足的问题。总体来看,现有数据驱动方法大多仅从单一维度对 SCADA 数据或载荷特征进行建模,未能充分挖掘 SCADA 多源传感变量与叶片载荷之间在时间与空间尺度上的动态关联特征,导致基于 SCADA 数据的载荷测量精度与工程适应性仍有提升空间。

近年来,物理信息与数据驱动融合的建模思路成为研究热点,SCADA 数据的核心价值被进一步凸显。例如, Cong 等^[16]提出一种基于轴承振动数据和自编码器-长短期记忆网络-注意力机制(auto-encoder long short-term memory attention, AE-LSTM-Attention)网络的叶片根部载荷监测方法,通过将齿轮箱传动比嵌入 LSTM 步长设计,实现了非侵入式的高精度载荷监测;Zou 等^[17]通过结合结构力学模型,实现物理-数据融合的贝叶斯建模,实现了对海上风电机组单桩基础泥线下应变载荷的虚拟感知,降低模型的不确定性;Feng 等^[18]提出频域分离技术,结合 SCADA 数据间接测量浮式风机载荷,平均相对误差小于 10%。但这些方法未针对 SCADA 多源传感数据与载荷数据间的强耦合、非平稳特性进行定制化设计,也未有效利用风电机组叶片的物理结构对称特性,难以通过物理约束提升 SCADA 载荷测量的精度与鲁棒性。

针对上述问题,本文提出一种基于 SCADA 运行数据的叶根载荷高精度虚拟感知测量方法,核心采用融合叶根载荷对称感知的时空可变形 Transformer 模型(symmetry-aware deformer, SADeformer),旨在为叶根载荷提供低成本、高精度、可规模化部署的 SCADA 虚拟传感解决方案。主要贡献为:

1)采用时空可变形注意力块协同架构进行特征提取,可动态捕获 SCADA 变量间非线性空间关联与时间序列长短期依赖,针对性解决 SCADA 与载荷的时空动态关联挖掘问题,提升虚拟感知精度。

2) 构建叶根载荷物理对称性损失函数,将叶片载荷空间一致性约束融入模型训练过程,通过物理约束与数据驱动的融合建模,适配叶片对称特性与载荷高频非线性特征,减少非物理性测量偏差。

1 载荷数据分析与特征工程

本文使用查尔姆斯理工大学公开的 45 kW 风电机组载荷实测公开数据集 (<https://zenodo.org/records/8230330>),该数据集采集自瑞典某风电场真实并网运行的陆上风电机组,数据采集与传感器布置符合 IEC 61400-13 风电机组载荷测量行业标准。机组额定功率为 45 kW,额定转速为 75 rpm,配备 30 m 高木质塔架,碳纤维叶片长 7.5 m,风轮直径 15.9 m,位置坐标为 (57.718 188 206 259 21, 11.683 382 148 764 485),该机组现场实拍情况如图 1 所示,展示了目标风电机组的整体结构、现场安装环境与并网运行状态,图 1 引自该公开数据集的配套说明文档。



图 1 风电机组现场实拍图
Fig. 1 On-site photo of the wind turbine

该数据集包含两大核心测量数据类型:1) 叶根载荷直接测量数据,2) 机组 SCADA 系统运行测量数据。其中,载荷数据对应风电机组的每个叶片叶根部位置 6 个应变传感器及其 2 个温度补偿器,用于采集叶片挥舞和摆振方向的载荷数据,传感器安装布局如图 2 所示,可以看到 6 个应变片分为 3 组,两两安装于叶根、叶中和叶尖的内表面对向位置,通过传感器计算得到叶片根部挥舞、摆振方向的载荷值,图 2 引自该公开数据集的配套说明文档。

同时,SCADA 数据来源于机组搭载的 SCADA 在线测量系统,集成了风速风向、桨距角、机舱加速度、发电机





图 2 叶片传感器安装位置
Fig. 2 Mounting diagram of blade sensors

温度和液压系统压力等多类传感测点,采集的运行数据包含 20 和 100 Hz 两种采样频率。原始 SCADA 数据集的高频测量信号中,包含传感器零点漂移、电磁干扰、机组启停带来的瞬时噪声和异常波动,会直接影响虚拟传感测量的精度,同时高频数据会增大测量算法的计算量,因此需对 SCADA 与载荷基准数据进行预处理,修正测量误差及统一数据基准。

1.1 数据预处理

该数据集包含两个不同采样频率的文件:1) 2022 年 7 月 5 日至 2023 年 6 月 9 日以 100 Hz 采样的测量值;2) 2022 年 7 月 5 日至 2023 年 8 月 2 日以 20 Hz 采样的测量值。数据由多个连续采样片段组成,每段采样的时间长度为 15 s~16 min 不等。本文的虚拟感知目标为风电机组 3 个叶片各自摆振和挥舞方向载荷值,共计 6 个风电机组叶根载荷变量。

图 3 展示了 6 个目标载荷变量在 5 min 时长内的秒级时序变化曲线,纵轴为叶根载荷弯矩数值,从时序特征中可观察到,三叶片同一方向的载荷变化趋势具有高度同步性,数值幅值范围上存在的差异主要是叶片沿 120°均匀分布的相位差导致,体现出叶片载荷间的旋转对称特性。






图3 风电机组叶根载荷变量时序图

Fig. 3 Time series of wind turbine blade root load variables

除6个风电机组叶根载荷分量数据外,原始数据中还包含风速、风向、桨距角、机舱加速度和发电机温度等60个SCADA运行参量,选取其中与载荷相关性较强的典型变量绘制的时域波形如图4所示。从图4可观察到:30 m高度风速(wind speed at 30 m height, WS30)、30 m高度风向(wind direction at 30 m height, WD30)、机舱加速度计X方向1(nacelle accelerometer X-axis 1, NAX1)等变量的随时序波动明显。物理意义上,风速风向的突变会直接引发叶根载荷的同步跳变并反应在机舱加速度等运行参量的变化上,验证了SCADA运行参量与叶根载荷之间存在强耦合关联,为后续基于SCADA数据构建载荷虚拟感知模型提供了数据基础。





图4 SCADA部分典型变量趋势

Fig. 4 SCADA partial typical variables trend

为提升虚拟感知模型的精度与稳定性,需对原始数据进行预处理,具体流程为:为剔除 SCADA 传感器测量异常、工况突变引发的离群数据,首先选取 30 m 高度处的风速、风向及叶片 1 摆振方向叶根弯矩 (blade 1 edgewise moment root, B1EMR) 作为局部离群因子 (local outlier factor, LOF) 离群值算法的特征列,对数据进行离群点清洗^[19],离群值算法处理前后的对比结果如图 5 所示。




图 5 基于局部异常因子的数据清洗结果对比
Fig. 5 Data cleaning result comparison based on LOF

可以观察到原始数据中因传感器瞬时干扰、机组工况突变引发的离群异常点,经 LOF 算法清洗后,数据点的离散程度下降,有效修正了 SCADA 测量的粗差误差,数据质量得到提升;随后对数据进行重采样,将 SCADA 数据和叶根载荷的采样频率统一为 1 Hz,统一多源传感数据的时间基准;最后选取时间长度大于 10 min 的采样片段整合为实验数据集,从两个不同原始采样频率的文件中共筛选得到 68 个有效片段,构成最终的虚拟传感测量实验数据集。

1.2 特征选择

SCADA 系统包含 60 个传感测量参量,其中存在大量与叶根载荷相关性弱、冗余度高的测量信号,直接输入会降低虚拟传感测量的精度与效率,因此采用斯皮尔曼相关系数法对所有数据字段进行相关性计算,如式 (1) 所示。

$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (1)$$

式中: d_i 表示第 i 对数据的秩次之差; n 表示数据对的数量。

图 6 为通过计算得到 SCADA 特征与 B1EMR 之间的相关性热力图。基于斯皮尔曼相关系数分析结果,结合风电机组运行的物理机理(载荷与风速、桨距角呈显著正相关^[20]),筛选与目标载荷变量正向相关系数 ≥ 0.2 的 SCADA 特征 14 个。其中,最高值为 30 m 高度风速,相关系数为 0.67,最低值为风估计,相关系数为 0.20。




图 6 SCADA 特征与载荷斯皮尔曼相关性热力图
Fig. 6 Spearman heatmap of SCADA features and loads

将上述特征与 3 个叶片的挥舞/摆振方向载荷目标变量(共 6 个)联合构建包含 20 个输入特征的数据集,具体特征名称及其对应编号见表 1。该环节确保了所选特征与载荷变量密切相关,提高模型准确性和计算效率。

表 1 模型输入参数
Table 1 Model input parameters

编号	特征	编号	特征
1	叶片 1 摆振方向叶根弯矩	11	30 m 高度风速
2	叶片 2 摆振方向叶根弯矩	12	机舱加速度计 Z 方向 2
3	叶片 3 摆振方向叶根弯矩	13	机舱加速度计 X 方向 2
4	叶片 1 挥舞方向叶根弯矩	14	叶片 1 桨距角设定值
5	叶片 2 挥舞方向叶根弯矩	15	叶片 1 桨距角
6	叶片 3 挥舞方向叶根弯矩	16	叶片 3 桨距角
7	30 m 高度风向	17	叶片 2 桨距角
8	空气湿度	18	液压马达压力 1
9	机舱加速度计 X 方向 1	19	叶片 1 的位置
10	叶片 1 位置	20	风估计

另外,为消除各数据特征的维度差异,减弱奇异样本数据带来的不利影响,使模型在反向传播中更易实现梯度下降,依据式 (2) 对数据进行标准化处理:

$$\bar{X} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

式中: X 为变量的原始数据; $\bar{X}$ 为标准化后数据; $X_{\min}$ 为该变量中的最小值; $X_{\max}$ 为该变量中的最大值。

2 基于 SADeformer 的叶根载荷虚拟感知

基于筛选后的 20 个输入特征,构建基于 SADeformer 的虚拟感知模型,实现 SCADA 多源传感数据到叶根载荷的高精度映射。以预处理后的 SCADA 多源测量特征为输

入,载荷实测数据为基准真值,构建基于 SADeformer 的叶根载荷虚拟传感测量模型,模型整体结构如图 7 所示。该模型为 SCADA 虚拟传感测量方法的核心算法,由可变形注意力机制特征提取器、多层感知机预测器和融合物理对称性的损失函数 3 部分构成,通过实验数据集完成模型训练与测试,最终实现风电机组叶根载荷的高精度间接测量。




图 7 基于对称感知的时空可变形 Transformer 模型结构

Fig. 7 Structure of symmetry-aware spatiotemporal deformable Transformer model

2.1 可变形注意力机制特征提取器

为充分挖掘 SCADA 多源测量数据与叶根载荷之间的时空关联特征,构建了时空可变形注意力机制特征提取器,其采用 DeformTime 编码器中的时空注意力模块结构,该模型由 Shu 等^[21]设计,并针对 SCADA 数据的强耦合、非平稳特性进行定制化适配。该架构的核心是通过部署可变形注意力块(deformable attention blocks, DABs)完成两项操作:1)通过变量维度可变形注意力块(variable deformable attention block, V-DAB)学习 SCADA 多传感变量与载荷变量间的非线性耦合关系,筛选与载荷测量强相关的有效特征;2)借助时间维度可变形注意力块(time deformable attention block, T-DAB),捕捉数据中的长短期动态关联,适配载荷的高频波动特性。

可变形注意力特征提取器包含 3 层编码器,每层编码器由 V-DAB 与 T-DAB 并行构成。输入的时序特征序列经邻域感知嵌入处理后,得到维度为 $Z_e \in \mathbb{R}^{L \times d}$ 的特征矩阵(其中 L 为时间步长, d 为隐藏维度);通过 V-DAB 与 T-DAB 分别捕捉变量维度非线性依赖与时间维度长短期关联,最终输出 SCADA 数据时空特性的特征序列 $Z_i \in \mathbb{R}^{L \times d}$,并将其输入至后续的预测器模块。

1) V-DAB 变量可变形注意力块

在变量可变形注意力块 V-DAB 中,首先将输入序列沿时间维度分割为长度为 L 、步长为 s 的块,得到 $n = (L - 1)/s + 1$ 个块 $Z_p \in \mathbb{R}^{L \times d}$ 。通过查询嵌入键值 Q_p ,计算变形偏移量,如式(3)所示。

$$\Delta p = \alpha \cdot \tanh(\theta_{\text{off}}(Q_p)) \quad (3)$$

式中: α 是可学习振幅; θ_{off} 为包括一个捕获相邻信息的 $k \times k$ 卷积层和投影线性特征的 1×1 投影层的二维卷积神经网络(2-dimensional convolutional neural network, 2D CNN)。

基于偏移量 Δp 对原始块 Z_p 进行双线性插值,得到变形后的块 Z_d ,若采样位置超出边界,使用零值进行插值。

基于变形后的块进而形成键值矩阵:

$$K_d = Z_d W_K \quad (4)$$

$$V_d = Z_d W_V + P_v \quad (5)$$

式中: W_K, W_V 为可学习权重矩阵; $P_v \in \mathbb{R}^{L \times d}$ 为相对位置偏置(维持变形后的位置信息)。

通过单头自注意力计算注意力输出:

$$A_i = \text{Softmax}\left(\frac{Q_p K_d^T}{\sqrt{d}}\right) V_d W_i \quad (6)$$

式中: $\mathbf{A}_i$ 为第 i 个补丁的注意力输出; $\mathbf{W}_i \in \mathbb{R}^{d \times d}$ 为投影权重矩阵。

最终通过投影得到变量依赖特征:

$$\mathbf{Z}_v = \mathbf{W}_v^T \mathbf{A} \quad (7)$$

式中: $\mathbf{A}$ 为所有补丁注意力嵌入的拼接结果; $\mathbf{W}_v \in \mathbb{R}^{(n \cdot l) \times L}$ 为全连接层权重; 最终输出 $\mathbf{Z}_v \in \mathbb{R}^{L \times d}$ 。

2) T-DAB 时间可变形注意力块

时间可变形注意力块 T-DAB 将归一化处理后的输入特征序列 $\mathbf{Z}_e \in \mathbb{R}^{L \times d}$ 进行时序重排, 将时间维度 L 转换为 $r \times \kappa$ 型矩阵, 其中 $\kappa = L/r$, r 为时间窗口数, κ 为单个时间窗口内的时间步长, 得到三维矩阵 $\mathbf{Z}'_e \in \mathbb{R}^{\kappa \times d}$; 该三维矩阵沿时间窗口维度拆分为 r 个时序块 $\mathbf{Z}_r \in \mathbb{R}^{\kappa \times d}$, 同时基于变量与目标载荷的相关性聚类结果, 沿隐藏层特征维度 d 按拆分为 G 组, 计算每组的共享偏移量:

$$\Delta p^{(g)} = \alpha \cdot \tanh(\eta_{\text{off}}(\mathbf{Q}_g)) \quad (8)$$

式中: $g = 1, 2, \dots, G$; α 为和 V-DAB 共享的可学习振幅; η_{off} 为用于提取邻域信息含 $k \times 1$ 卷积层和 1×1 投影层的一维卷积神经网络 (1-dimensional convolutional neural network, 1D CNN), $\mathbf{Q}_g \in \mathbb{R}^{\kappa \times (d/G)}$ 为第 g 组的查询嵌入 (G 为分组数)。

通过线性变换插值得到时序变形序列 $\mathbf{Z}_s = [\mathbf{Z}_s^{(1)}, \dots, \mathbf{Z}_s^{(G)}]$, 为所有组变形序列的拼接结果, 基于时序变形序列构建键值矩阵:

$$\mathbf{K}_s = \mathbf{Z}_s \mathbf{U}_K \quad (9)$$

$$\mathbf{V}_s = \mathbf{Z}_s \mathbf{U}_V + \mathbf{P}_t \quad (10)$$

式中: $\mathbf{U}_K, \mathbf{U}_V$ 为可学习权重矩阵; $\mathbf{P}_t \in \mathbb{R}^{\kappa \times d}$ 为时间维度的相对位置偏置。

通过多头注意力计算注意力输出:

$$\mathbf{A}_g = \text{Softmax}\left(\frac{\mathbf{Q}_g \mathbf{K}_g^T}{\sqrt{d/G}}\right) \mathbf{V}_g \quad (11)$$

式中: $\mathbf{K}_g, \mathbf{V}_g$ 为 $\mathbf{K}_s, \mathbf{V}_s$ 的第 g 组子矩阵; $\mathbf{A}_g$ 为第 g 头的注意力输出。

将所有注意力头拼接, 并经权重矩阵 $\mathbf{W}_i \in \mathbb{R}^{d \times d}$ 投影后, 重新排列为与输入长度一致的时序结构 $\mathbf{Z}_t \in \mathbb{R}^{L \times d}$ 。

3) 注意力机制块的协同输出

V-DAB 与 T-DAB 所得到的重构特征 $\mathbf{Z}_v$ 和 $\mathbf{Z}_t$, 先分别经过随机深度的随机失活 (dropout), 再通过包含修正线性单元 (rectified linear unit, ReLU) 的两层多层感知机 (multilayer perceptron, MLP), 并经归一化后获得中间输出 $\mathbf{Z}'_v$ 和 $\mathbf{Z}'_t$ 。

然后将变量间特征 $\mathbf{Z}'_v$ 和时间步间特征 $\mathbf{Z}'_t$ 沿特征维度拼接:

$$\mathbf{Z}_j = \text{Linear}(\text{Concat}(\mathbf{Z}'_v, \mathbf{Z}'_t)) \quad (12)$$

式中: $\text{Concat}(\cdot)$ 表示将 V-DAB 和 T-DAB 的输出沿特征维度拼接; $\text{Linear}(\cdot)$ 为全连接层。最终生成第 j 个编码

器的输出 $\mathbf{Z}_j$, 实现跨模块信息的协同融合。在特征提取器的层间传递中, 前一层编码器的输出作为下一层编码器的输入, 实现特征增强, 最终获得重构特征输出。

2.2 多层感知机预测器

预测器采用 3 层 MLP 结构, 将时空特征提取器输出的融合特征转换为目标变量的虚拟感知值, 兼顾计算效率与感知精度。预测器的输入为编码器输出的特征矩阵 $\mathbf{Z}_j \in \mathbb{R}^{L \times d}$, 输出为感知值序列 $\hat{\mathbf{y}} \in \mathbb{R}^{L \times 6}$ 。

预测器首先通过自适应平均池化 (adaptive average pooling, AvgPool) 将序列维度压缩^[22], 将输入 $\mathbf{Z}_j$ 从形状 $[\text{batch}, L, d]$ 转换为池化输入 $\mathbf{x}_{\text{pool}}$ 形状为 $[\text{batch}, d]$ 。

压缩后的特征通过两层全连接网络进行非线性映射:

$$\mathbf{L}_2 = \mathbf{W}_2 \cdot \text{ReLU}(\mathbf{W}_1 \cdot \mathbf{x}_{\text{pool}} + \mathbf{b}_1) + \mathbf{b}_2 \quad (13)$$

式中: $\mathbf{W}_1$ 为第 1 层的权重; $\mathbf{b}_1$ 为第 1 隐层偏置向量; ReLU 为激活函数; $\mathbf{W}_2$ 为第 2 层的权重; $\mathbf{b}_2$ 为第 2 隐层偏置向量; 层间使用 dropout 抑制过拟合。

最终通过输出层直接映射到目标维度:

$$\hat{\mathbf{y}} = \mathbf{L}_2 \mathbf{W}_3 + \mathbf{b}_3 \quad (14)$$

式中: $\mathbf{W}_3$ 和 $\mathbf{b}_3$ 分别为输出层的权重和偏置; $\hat{\mathbf{y}}$ 为叶根载荷虚拟传感测量序列, 包含 6 通道的变量输出。

2.3 叶根载荷物理对称性损失函数设计

针对叶根载荷的高精度虚拟感知需求, 设计融合物理对称性约束的复合损失函数 (symmetric weighted error loss, SWE), 通过加权平衡逐点测量误差损失 $\mathcal{L}_{\text{point}}$ 与叶片载荷对称性误差损失 $\mathcal{L}_{\text{symmetry}}$, 既保证虚拟感知结果与真实值的拟合精度, 又引导模型学习符合三叶片结构物理规律的载荷分布模式, 提升虚拟感知结果的物理合理性与鲁棒性。

风电机组的三叶片结构在理想状态下应保持载荷分布的对称性, 特别是在稳定风速条件下, 叶片间载荷差异应满足以下物理约束: 三叶片沿轮毂均匀分布 (两两夹角 120°), 理想载荷应呈现近似的旋转对称性; 叶片载荷需保持动态平衡, 以减少机组振动和叶片疲劳; 相邻叶片的气动效应相互关联, 载荷波动具有协同性^[23]。因此, 在损失函数中引入对称性约束, 不仅能提升感知精度, 还能使模型学习到符合物理规律的载荷分布模式。

该复合损失函数的整体形式为:

$$\mathcal{L}_{\text{SWE}} = \beta \cdot \mathcal{L}_{\text{point}} + \gamma \cdot \mathcal{L}_{\text{symmetry}} \quad (15)$$

式中: β 和 γ 为可调节的权重参数, 默认均设置为 0.5。

逐点误差损失 $\mathcal{L}_{\text{point}}$ 首先分离每个样本的挥舞方向 (flapwise) 和摆振方向 (edgewise) 载荷, 再采用均方误差 (mean squared error, MSE)^[24] 计算:

$$\mathcal{L}_{b, \text{point}} = \sqrt{\frac{1}{2}((y_{b,e} - \hat{y}_{b,e})^2 + (y_{b,f} - \hat{y}_{b,f})^2)} \quad (16)$$

$$\mathcal{L}_{\text{point}} = \frac{1}{3} \sum_{b=1}^3 \mathcal{L}_{b,\text{point}} \quad (17)$$

式中: $y_{b,e}$ 、 $y_{b,f}$ 分别为叶片 b 摆振方向和挥舞方向逐点载荷的实际值; $\hat{y}_{b,e}$ 、 $\hat{y}_{b,f}$ 分别为叶片 b 两方向载荷的虚拟感知值; $\mathcal{L}_{b,\text{point}}$ 为叶片 b 的逐点误差损失, $b=1,2,3$ 。

叶片对称性损失 $\mathcal{L}_{\text{symmetry}}$ 用于衡量 3 个叶片间载荷感知结果的一致性,通过计算所有叶片对之间的均方误差 MSE 实现:

$$MSE_{12} = (\hat{y}_{1,e} - \hat{y}_{2,e})^2 + (\hat{y}_{1,f} - \hat{y}_{2,f})^2 \quad (18)$$

$$MSE_{23} = (\hat{y}_{2,e} - \hat{y}_{3,e})^2 + (\hat{y}_{2,f} - \hat{y}_{3,f})^2 \quad (19)$$

$$MSE_{31} = (\hat{y}_{3,e} - \hat{y}_{1,e})^2 + (\hat{y}_{3,f} - \hat{y}_{1,f})^2 \quad (20)$$

式中: $\hat{y}_{1,e}$ 、 $\hat{y}_{1,f}$ 分别为叶片 1 摆振和挥舞方向载荷的虚拟感知结果,其余符号同理。

对称性误差损失为所有叶片对 MSE 的平均值:

$$\mathcal{L}_{\text{symmetry}} = \frac{1}{3} (MSE_{12} + MSE_{23} + MSE_{31}) \quad (21)$$

通过最小化综合对称性损失值 $\mathcal{L}_{\text{SWE}}$,即可寻优得到叶根载荷的最佳虚拟感知预测结果。

3 结果与分析

3.1 实验设置与模型训练

本文根据 1.1 节中预处理得到的 SCADA 和载荷整合秒级数据集,进行模型的训练和叶根载荷值的虚拟感知。数据集包含 68 个不等长时间片段,按照约 60%、30% 和 10% 的比例将不同时间片段划分为训练集、验证集和测试集,且在模型训练过程中保证不同片段间无数数据泄露,避免模型错误学习时序关系。最终得到的训练集、验证集、测试集样本数分别为 153 801、73 417 和 24 978。

模型参数设置方面,模型输入序列长度为 15,输入特征维度为 20,包含 14 个 SCADA 运行变量和 6 个叶根载荷变量;输出维度为 6,即三叶片挥舞、摆振方向总计 6 个叶根载荷的虚拟感知结果。

模型网络结构参数采用贝叶斯参数优化,编码器层数为 3 层,隐层维度为 512、256 和 128,注意力头数为 8,卷积核大小为 5,用于提取局部时序特征;块长度为 6,步长为 3,通过滑动窗口实现输入序列的分块处理。

模型训练的优化器采用自适应矩估计优化器 (adaptive moment estimation, Adam),初始学习率为 0.002 5,dropout 率为 0.2;解码器的隐藏层维度分别为 128 和 64,激活函数采用带泄露修正线性单元 (leaky rectified linear unit, LeakyReLU)。设置最大训练轮数为 400,采用早停机制,耐心值设置为 25;当验证损失连续 8 轮未改善时,学习率衰减为原来的 0.3 倍,最低学习率

设为 5×10^{-6} ;同时应用梯度裁切以稳定训练过程。

模型训练采用自定义的 SWE 损失函数,由于逐点误差损失与对称性误差损失的数量级一致,故权重系数 β 和 γ 均设置为 0.5。模型训练过程中,损失函数值的变化如图 8 所示。




图8 最优模型自定义损失曲线变化

Fig. 8 Custom loss curve variation of the optimal model

其中,验证损失为每 5 个训练轮计算一次。从图 8 中可观察到,实线训练损失与虚线验证损失均在训练前期快速下降,训练至 130 轮后趋于收敛;验证损失最低为 0.123 1,且训练损失与验证损失的差距始终较小,未出现过拟合现象,表明模型具有良好的泛化能力。通过早停机制,模型在第 200 轮停止训练,总训练耗时 18 min 36 s。

3.2 叶根载荷感知结果

叶根载荷真实值与虚拟感知预测值的对比结果如图 9 所示,SADeformer 模型能够准确感知载荷数据的波动趋势,在样本数 2 000~5 000 区间,载荷出现突变,对应风电场实际的阵风动态工况,模型仍能实现有效跟踪,仅在载荷突变峰值处的跟踪感知能力略有下降,说明本方法在动态工况下的测量鲁棒性优异,大部分场景下的感知结果准确性较高。这一结果验证了轻量化 MLP 预测器在载荷感知任务中的有效性。通过简化解码器结构,模型在保持感知精度的同时,显著降低了计算复杂度,更适用于工程场景中的实时载荷虚拟传感测量需求。

图 10 给出了各载荷变量决定系数 (R -squared, R^2) 的虚拟感知值与真实值散点对比图。其中虚线为感知预测值与真实值完全相同的参考线,数据分布越接近参考线,表明感知精度越高。

可以看出,SADeformer 时序虚拟感知模型在摆振方向的感知能力稍弱,原因可能是摆振方向载荷受机组传动链振动影响更大,对应的 SCADA 关联参量更少,且叶根摆振方向应变传感器的采样灵敏度低于挥舞方向,导致模型对摆振载荷的瞬态冲击信号难以通过多层线性变换充分拟合,载荷的较大跳变使模型无法实现精准跟踪;而在挥舞方向,模型仅在较大极端值处的感知结果偏





图9 感知值与真实值对比

Fig. 9 Comparisons between perceived and actual values

图10 载荷变量 R^2 感知值与真实值散点对比Fig. 10 Perceived vs. actual R^2 values scatter plot for load variables

离散点图中心,整体虚拟感知效果良好,各叶片挥舞方向载荷的 R^2 均接近 0.96。

3.3 模型对比分析

为验证本文提出的 SADeformer 虚拟感知方法的优越性和有效性,选取多个常用的时序虚拟感知基线模型进行训练结果对比,基线方法包括双向长短期记忆网络 (bidirectional long short-term memory, BiLSTM)^[25]、Transformer、iTransformer^[26]、TimeXer^[27] 和现代时间卷积网络 (modern temporal convolutional network, Modern TCN)^[28],同时选取单独的 MLP 结构作为基线,以验证本文所提特征提取器对 SCADA 特征与载荷特征时空关联性的捕捉能力。所有对比方案均采用相同的训练集训

练、相同的测试集评估,通过 R^2 、平均绝对误差 (mean absolute error, MAE)、MSE、RMSE、平均绝对百分比误差 (mean absolute percentage error, MAPE) 及算法耗时等指标进行误差与性能评价^[24],对比结果如表 2 所示。

由表 2 可知,本文提出的 SCADA 虚拟感知方法在核心评价指标上全面优于对比模型: R^2 达 0.952,较 BiLSTM 的 0.941、Modern TCN 的 0.925 分别提升 1.17%、2.92%;MAE 值为 5.0×10^{-6} 、RMSE 值为 8.0×10^{-6} ,二者均为最低值,表明模型的载荷测量精度更优。

在工程适配性方面,SADeformer 展现出良好的计算效率,其训练耗时仅为 18 min 36 s,虽略高于计算效率

表 2 各模型虚拟感知结果对比

Table 2 Comparison of virtual sensing results of various models

模型	训练耗时	MAE	MSE	RMSE	R^2	MAPE/%
BiLSTM	23 min 58 s	6.8×10^{-6}	8.5×10^{-11}	9.2×10^{-6}	0.941	3.6
Transformer	12 min 58 s	5.2×10^{-6}	7.2×10^{-11}	9.5×10^{-6}	0.942	3.6
iTransformer	39 min 28 s	5.5×10^{-6}	7.8×10^{-11}	8.8×10^{-6}	0.940	3.3
TimeXer	23 min 43 s	7.0×10^{-6}	1.0×10^{-10}	1.0×10^{-5}	0.934	1.4
Modern TCN	31 min 12 s	6.0×10^{-6}	1.0×10^{-10}	1.0×10^{-5}	0.925	1.2
MLP(3 layer)	12 min 33 s	2.4×10^{-5}	6.1×10^{-10}	2.4×10^{-5}	0.886	2.5
SADeformer	18 min 36 s	5.0×10^{-6}	2.5×10^{-11}	8.0×10^{-6}	0.952	0.8

最优的基础 Transformer 的 12 min 58 s 与简易 MLP 预测器的 12 min 33 s,但远低于结构复杂的 iTransformer 的 39 min 28 s 与 Modern TCN 的 31 min 12 s。这种适中的时间成本换来了感知精度的大幅提升,特别是在与 MLP 模型对比中,SADeformer 在 R^2 上实现了 7.4%的提升,验证了其中所设计的时空可变形注意力特征提取器在有效捕获 SCADA 多元测量数据与载荷数据深层时空依赖关系方面的关键作用。

如图 11 的分方向载荷感知结果对比图所示,可进一

步看出,SADeformer 在挥舞方向 (flapwise moment root, FMR)与摆振方向 (edgewise moment root,EMR)的平均决定系数 R^2 均高于对比模型,尤其在摆振方向的感知精度提升更为显著,这得益于对称性损失函数对叶片载荷物理约束的强化,避免了单一方向载荷感知偏差过大的问题。相较于不包含时空特征提取器的 3 层 MLP 模型,训练时间上略有增加,但学习到了更多的变量和时间步长间的相关关系,因此在各项评价指标上全面优于简单的 3 层 MLP 模型。




图 11 各模型挥舞和摆振方向载荷虚拟感知结果对比

Fig. 11 Comparative plot of flapwise and edgewise load virtual sensing results of various models

为进一步验证自定义损失函数 SWE 对模型泛化性能与测量精度的影响,选取机器学习领域广泛应用的、以最小化 MAE 和 MSE 为优化目标的损失函数进行对

比实验,结果如表 3 所示。综合多维度评估指标分析,引入物理对称性约束的 SWE 损失函数展现出显著的性能优势。

表 3 不同损失函数对比

Table 3 Comparison of different loss functions

损失函数	挥舞方向 MAE	摆振方向 MAE	MSE	RMSE	R^2	MAPE/%
最小化 MSE 损失	3.3×10^{-6}	9.4×10^{-6}	2.7×10^{-11}	1.0×10^{-5}	0.934	1.1
最小化 MAE 损失	4.0×10^{-6}	9.7×10^{-6}	1.2×10^{-10}	1.1×10^{-5}	0.858	1.2
自定义 SWE 损失	3.7×10^{-6}	6.4×10^{-6}	2.5×10^{-11}	8.0×10^{-6}	0.952	0.8

在测量精度方面,SWE 在摆振方向载荷反演中表现突出,其 MAE 值为 6.4×10^{-6} ,相较于最小化 MAE 和 MSE 为优化目标的损失函数的 MAE 值分别降低了 31.9%和

34.0%,有效提升了对摆振载荷这一关键工程参数的捕捉能力;在挥舞方向,SWE 的 MAE 为 3.7×10^{-6} ,略高于以最小化 MSE 为优化目标的损失函数的 3.3×10^{-6} ,但仍

保持较高精度水平。

从误差分布特性看,SWE 在 RMSE 和 MSE 两项指标上均取得最优值,分别为 8.0×10^{-6} 和 2.5×10^{-11} , 比以最小化 MSE 为优化目标的损失函数降低 20.0% 和 7.4%,表明其能有效控制误差整体分布,减少极端异常值影响;同时 SWE 的 MAPE 值为三者最低,达到 0.8%,相比最小化 MAE 和 MSE 为优化目标的损失函数分别降低 33.3% 和 27.3%,显示其在相对误差控制方面的明显优势。

从模型拟合质量评估,SWE 对应的 R^2 决定系数达到 0.952,较以最小化 MSE 为优化目标的损失函数的 0.934 提升 1.9%,较以最小化 MAE 为优化目标损失函数的 0.858 显著提升 11.0%,证明引入物理对称性约束后,模型对载荷数据变异的解释能力最强,理论感知值与实际观测值的拟合优度最高。

综上,自定义对称性损失函数 SWE 通过融合物理先验知识,在保持挥舞方向虚拟感知测量稳定性的同时,显著提升了摆振方向的测量精度,优化了整体误差分布特性,增强了模型的理论解释能力。这一结果为复杂载荷感知测量任务中损失函数的物理引导设计提供了有益参考,自定义损失函数通过约束不同叶片感知值差异满足了风电机组叶片载荷物理对称性这一先验知识,有效约束了非对称性误差(如单侧叶片载荷感知结果异常偏高),提升了模型的物理可解释性和不同方向测量结果的鲁棒性。

4 结 论

本文针对风电机组叶根载荷直接测量成本高、难以规模化部署的工程难题,提出了一种基于风电机组 SCADA 系统的叶根载荷虚拟感知高精度测量方法,核心采用 SADeformer 实现载荷反演,解决了 SCADA 多源传感数据强耦合、非平稳特性带来的测量精度不足问题。通过理论分析与实验验证,主要得出以下结论:

1) SADeformer 采用 V-DAB 与 T-DAB 的协同架构,能够动态捕获变量间的非线性依赖与时间序列的长短期依赖,其虚拟能感知性能优于其他主流模型,证明了变量耦合特征与时间动态特征对叶根载荷虚拟感知的重要性。

2) 设计的叶根载荷对称性损失函数,通过融合逐点误差与叶片间对称性约束,有效减少了模型的非物理性测量偏差,提升了感知精度,验证了物理先验知识对数据驱动模型的补充与优化作用,为复杂载荷测量任务中损失函数的物理引导设计提供了有益参考。

本研究基于真实风电机组 SCADA 实测运行数据与载荷基准数据,为叶根载荷虚拟感知提供了兼具精度与

计算效率的工程化解决方案,验证了所提 SADeformer 方法的有效性与工程可行性。但该方法在塔影效应和极端湍流工况下的感知稳定性仍需进一步研究和优化,未来的研究工作将聚焦于极端运行工况下的虚拟感知精度提升、现场工程化部署验证,并融合更多叶片气动物理机理约束,以进一步提升方法在复杂工程工况下的鲁棒性与实际应用适配性。

参考文献

- [1] 金晓航,王奇超,张元鸣,等. 知识图谱与时空图神经网络融合驱动的风电机组状态监测[J]. 仪器仪表学报, 2025, 46(12): 59-74.
JIN X H, WANG Q CH, ZHANG Y M, et al. Research on condition monitoring of wind turbines driven by fusion of knowledge graph and spatiotemporal graph neural network[J]. Chinese Journal of Scientific Instrument, 2025, 46(12): 59-74.
- [2] CIVERA M, SURACE C. Non-destructive techniques for the condition and structural health monitoring of wind turbines: A literature review of the last 20 years[J]. Sensors, 2022, 22(4): 1627.
- [3] 刘军,曹文翱,夏嘉辰,等. 风力机叶片剩余使用寿命预测方法研究[J]. 自动化仪表, 2025, 46(8): 22-28.
LIU J, CAO W AO, XIA J CH, et al. Research on remaining useful life prediction methods of wind turbine blades[J]. Process Automation Instrumentation, 2025, 46(8): 22-28.
- [4] 李湘晖,鲁昊,杨盼盼,等. 偏航尾流影响下风力发电机叶片寿命预测[J]. 振动与冲击, 2025, 44(19): 98-105, 124.
LI X H, LU H, YANG P P, et al. Life prediction of wind turbine blades under the influence of yaw wake[J]. Journal of Vibration and Shock, 2025, 44(19): 98-105, 124.
- [5] LIU Y F, CHENG J. Prediction of blade root loads for wind turbine based on RBMO-VMD and TCN-BiLSTM-Attention[J]. Mathematics, 2026, 14(2): 218.
- [6] 金晓航,孙毅,单继宏,等. 风力发电机组故障诊断与预测技术研究综述[J]. 仪器仪表学报, 2017, 38(5): 1041-1053.
JIN X H, SUN Y, SHAN J H, et al. Review on fault diagnosis and prediction technologies of wind turbine generators[J]. Chinese Journal of Scientific Instrument, 2017, 38(5): 1041-1053.
- [7] 程逸,张杨宇,胡阳,等. 海上风电机组关键温度测点

- 虚拟感知及应用方法[J]. 太阳能学报, 2025, 46(10): 735-745.
- CHENG Y, ZHANG Y Y, HU Y, et al. Virtual sensing and application method of key temperature measurement points for offshore wind turbines[J]. *Acta Energiae Solaris Sinica*, 2025, 46(10): 735-745.
- [8] 曹利宵,贾晓冰,李宁,等. 基于自回归嵌入的风电机组传动系统双阈值状态监测[J]. 仪器仪表学报, 2025, 46(9): 360-371.
- CAO L X, JIA X B, LI N, et al. Double-threshold condition monitoring of wind turbine transmission system based on autoregressive embedding[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(9): 360-371.
- [9] 周勃,张丽新,包洪兵,等. 稳态工况下在役风力机叶片的载荷测试和识别[J]. 太阳能学报, 2025, 46(6): 597-606.
- ZHOU B, ZHANG L X, BAO H B, et al. Load testing and identification of in-service wind turbine blades under steady-state conditions[J]. *Acta Energiae Solaris Sinica*, 2025, 46(6): 597-606.
- [10] 秦斌,易怀洋,王欣. 基于极限学习机的风电机组叶根载荷辨识建模[J]. 振动与冲击, 2018, 37(4): 257-262.
- QIN B, YI H Y, WANG X. Modeling of wind turbine blade root load identification based on extreme learning machine[J]. *Journal of Vibration and Shock*, 2018, 37(4): 257-262.
- [11] 付德义,张晓东,王瑞明,等. 特定场址条件下风电机组载荷适应性评估[J]. 太阳能学报, 2021, 42(6): 425-431.
- FU D Y, ZHANG X D, WANG R M, et al. Load adaptability evaluation of wind turbine generators under specific site conditions[J]. *Acta Energiae Solaris Sinica*, 2021, 42(6): 425-431.
- [12] SANTOS F, D'ANTUONO P, ROBBELEIN K, et al. Long-term fatigue estimation on offshore wind turbines interface loads through loss function physics-guided learning of neural networks[J]. *Renewable Energy*, 2023, 205: 461-474.
- [13] 岳健,史秉帅,范寒,等. 基于多级特征提取框架的风电机组载荷预测方法[J]. 太阳能学报, 2024, 45(12): 350-359.
- YUE J, SHI B SH, FAN H, et al. Wind turbine load prediction method based on multi-level feature extraction framework[J]. *Acta Energiae Solaris Sinica*, 2024, 45(12): 350-359.
- [14] 金晓航,杨宇辰,喻轩昂. 改进多层自组织映射网络驱动的风电机组状态监测[J]. 仪器仪表学报, 2025, 46(3): 231-241.
- JIN X H, YANG Y CH, YU X ANG. Condition monitoring of wind turbines driven by improved multi-layer self-organizing map network[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(3): 231-241.
- [15] MOYNIHAN B, TRONCI E M, HUGHES M C, et al. Virtual sensing via Gaussian process for bending moment response prediction of an offshore wind turbine using SCADA data[J]. *Renewable Energy*, 2024, 227: 120466.
- [16] CONG F Y, LIANG CH, HU W F, et al. A novel approach of wind turbine blade root load monitoring based on bearings vibrational data and a new AE-LSTM-Attention neural network[J]. *Wind Energy*, 2025, 28(5): 70006.
- [17] ZOU J, LOURENS E M, CICIRELLO A. Virtual sensing of subsoil strain response in monopile-based offshore wind turbines via Gaussian process latent force models[J]. *Mechanical Systems and Signal Processing*, 2023, 200: 110488.
- [18] FENG X H, LIN Y G, GU Y J, et al. Indirect load measurement method and experimental verification of floating offshore wind turbine[J]. *Ocean Engineering*, 2024, 303: 117734.
- [19] 张戈,盖赟. 局部离群因子算法(LOF)在异常检测中的应用研究[J]. 网络安全技术与应用, 2020(11): 49-50.
- ZHANG G, GAI Y. Research on application of local outlier factor (LOF) algorithm in anomaly detection[J]. *Network Security Technology & Application*, 2020(11): 49-50.
- [20] ZHANG F, DAI J CH, LIU D SH, et al. Investigation of the pitch load of large-scale wind turbines using field SCADA data[J]. *Energies*, 2019, 12(3): 509.
- [21] SHU Y X, LAMPOS V. DeformTime: Capturing variable dependencies with deformable attention for time series forecasting[J]. *ArXiv preprint arXiv: 2406.07438*, 2024.
- [22] STERGIOU A, POPPE R. AdaPool: Exponential adaptive pooling for information-retaining downsampling[J]. *IEEE Transactions on Image Processing*, 2023, 32: 251-266.
- [23] PAYNE G S, STALLARD T, MARTINEZ R, et al.

Variation of loads on a three-bladed horizontal axis tidal turbine with frequency and blade position[J]. Journal of Fluids and Structures, 2018, 83: 156-170.

[24] 王毓灿,元海文,孙齐,等. 不同地质条件下盾构机掘进速度预测方法[J]. 仪器仪表学报,2025, 46(3): 30-40.

WANG Y C, YUAN H W, SUN Q, et al. Prediction method of shield tunneling speed under different geological condition [J]. Chinese Journal of Scientific Instrument, 2025, 46(3): 30-40.

[25] RIZA B S, YUNITA R, ROSNELLY R. Comparative analysis of LSTM and BiLSTM in image detection processing[J]. Journal of Wireless Mobile Networks, Ubiquitous Computing and Dependable Applications, 2024, 15(1): 244-260.

[26] ZOU Y J, CHEN Y B, XU Y J, et al. Short-term freeway traffic speed multistep prediction using an iTransformer model [J]. Physica A: Statistical Mechanics and its Applications, 2024, 655: 130185.

[27] WANG Y X, WU H X, DONG J X, et al. Timexer: Empowering transformers for time series forecasting with exogenous variables[J]. Advances in Neural Information Processing Systems, 2024, 37: 469-498.

[28] LI X, ZHU W W, LI Q, et al. Re-distributing facial features for engagement prediction with moderntcn [J].

Computers, Materials, & Continua, 2024, 81(1): 369-391.

作者简介



江国乾(通信作者), 分别在 2011 年和 2018 年于燕山大学获得学士学位和博士学位, 现为燕山大学教授, 主要研究方向为风电装备智能感知、监测与诊断预测。

E-mail:jiangguoqian@ ysu. edu. cn

Jiang Guoqian (Corresponding author) received his B. Sc. degree and Ph. D. degree both from Yanshan University in 2011 and 2018, respectively. He is currently a professor at Yanshan University. His main research interests include intelligent sensing, monitoring, diagnostics, and prognostics of wind turbines.



岳健,2014 年于河北工业大学获得学士学位,2020 年于北京大学获得硕士学位,现为北京金风慧能技术有限公司副总经理,主要研究方向新能源设备健康管理、风机技改及再制造。

E-mail:yuejian@ goldwind. com

Yue Jian received his B. Sc. degree from Hebei University of Technology in 2014, and his M. Sc. degree from Beijing University in 2020. He is currently a deputy general manager at Beijing Goldwind Smart Energy Technology Co. , Ltd. His main research interests include health management of new energy equipment, retrofitting and remanufacturing of wind turbin.