

DOI: 10.19650/j.cnki.cjsi.12614973

基于物理信息图神经网络的风电机组 状态监测方法研究*

金晓航^{1,2}, 刘家光¹, 吴鹏洪¹, 王 宇³, 彭一真²

(1. 浙江工业大学机械工程学院 杭州 310023; 2. 高端装备机械传动全国重点实验室 重庆 400044;
3. 西安交通大学机械工程学院 西安 710054)

摘 要:风电机组(WTs)是一个强耦合关联的系统,其高效与安全运行依赖于数据采集与监控(SCADA)系统的支撑。考虑实际工程条件以及受限于传感器的数量与安装,机组运行过程中部分物理参量难以直接测量;此外,传统数据驱动方法因欠缺物理约束,对机组动态复杂的运行状态难以有效建模。鉴于此,提出一种面向风电机组状态监测的物理信息图神经网络(PIGNN)方法。该方法以图结构建模风电机组不同部件之间的耦合关系,通过图神经网络(GNN)学习 SCADA 数据中的时空关联特征和表征机组运行动态特性,在此基础上引入物理信息神经网络(PINN),将功率、力矩、电压和温度的平衡以及运行边界约束等方面的关系系统一表示为物理约束损失,进而实现物理先验与数据驱动模型的有效融合。为解决数据拟合损失与物理约束损失数量级不一致问题,提出一种基于指数移动平均的自适应归一化策略,实现不同损失项数值尺度的平衡,以提升模型训练的稳定性。最后,通过两台风电机组的案例分析表明,所提 PIGNN 方法在保证模型预测精度的同时,能够有效平衡数据拟合目标与物理约束目标,提升异常状态识别和早期故障预警的能力,验证了物理约束建模在风电机组状态监测中的有效性。

关键词: 风电机组;状态监测;物理信息图神经网络;物理约束设计;数据采集与监测系统

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

Condition monitoring of wind turbine based on physics-informed graph neural network

Jin Xiaohang^{1,2}, Liu Jiaguang¹, Wu Penghong¹, Wang Yu³, Peng Yizhen²

(1. College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023, China;
2. State Key Laboratory of Mechanical Transmission for Advanced Equipment, Chongqing 400044, China;
3. School of Mechanical Engineering, Xi'an JiaoTong University, Xi'an 710054, China)

Abstract: Wind turbines (WTs) are highly coupled systems, whose safe and efficient operation rely on the supervisory control and data acquisition (SCADA) system. Considering the limitations of sensor placement and practical engineering, some physical quantities cannot be directly acquired during the operation. As a result, the traditional data-driven methods often fail to model the complex operating conditions of WT effectively due to the lack of relevant physical constraints. To address this issue, this paper proposes a physics-informed graph neural network (PIGNN) method for the WT condition monitoring. First, a graph structure is built by representing the coupling relationships among different WT components, then a graph neural network (GNN) is employed to learn spatiotemporal correlation features of SCADA data and capture the dynamic characteristics of WT. And then a physics-informed neural network (PINN) is embedded into the proposed framework, whose physics-based loss terms can express the physical relationships including power balance, torque balance, voltage balance, temperature constraints and operating boundary constraints. In this way, the physical prior knowledge could be integrated into the data-driven model effectively. Furthermore, an adaptive normalization strategy based on an exponential moving average is developed to address the magnitude inconsistency between the data fitting loss and the physics-based constraint losses. This could balance the

收稿日期:2026-02-28 Received Date: 2026-02-28

* 基金项目:国家自然科学基金(62473336)、浙江省自然科学基金(LZ25F030004)、国家重点研发计划(2022YFE0198900);高端装备机械传动全国重点实验室开放课题(SKLM-T-MSKF-KT-202315)项目资助

magnitude difference of different loss terms and improve the stability of model training. Finally, the experiments are carried out on two real WT cases. Results show that the proposed PIGNN method can balance the data fitting objective and the physics-based constraint objective effectively while providing the high prediction accuracy. It could also improve the performance of anomaly detection and early warning, which verifies the effectiveness of physics-based constraint modeling for WT condition monitoring.

Keywords: wind turbine; condition monitoring; physics-informed graph neural network; physical constraints design; supervisory control and data acquisition

0 引 言

在全球能源低碳转型及国内“双碳”战略背景下, 可再生清洁能源发电已成为中国未来发展的重点领域^[1-2], 风电机组 (wind turbines, WTs) 作为风能利用的高端装备受到广泛采用。受强载荷波动与恶劣工况的影响, 机组关键部件疲劳损伤逐渐累积, 故障发生概率随之增加, 运维成本高, 传统人工巡检在覆盖范围和实施条件方面已难以满足工程需求^[3-4]。受制造与安装差异、部件老化、复杂环境及变工况运行等因素影响, 风电机组年均因失效停机维护的时间可达 52~237 h^[5]。因此, 构建高效可靠的风电机组健康监测与故障预警方法具有重要意义。

传统风电机组状态监测方法可分为侵入式与非侵入式两大类^[6]。侵入式方法 (如油液监测) 需额外布设传感器或对机组结构进行改动, 增加运维成本。非侵入式方法 (如红外测量) 不需对结构进行改动, 但设备布置受限、测量结果易受环境因素干扰, 监测结果可靠性有限。基于数据驱动的状态监测方法通常依托于非侵入式监测手段获取运行数据, 其核心在于通过挖掘历史运行数据中的机组状态信息。相较于传统监测方法, 数据驱动方法在复杂系统建模与状态预测方面展现出更强的表达能力, 因而逐渐成为风电机组状态监测的重要技术路径^[7]。

数据采集与监控 (supervisory control and data acquisition, SCADA) 系统作为风电机组状态监测的重要数据来源, 可获取机组运行过程中的多维度信息。SCADA 数据具备丰富的时序特性与良好的可获得性。相比其他数据驱动方法, 基于 SCADA 数据的数据驱动方法能够利用机组运行过程中的多变量时间序列信息刻画机组行为, 从而更适用于复杂工况下的状态建模与分析。风电机组故障的发生往往与其结构特性及载荷传递路径密切相关。齿轮箱、发电机等关键部件在长期交变载荷与复杂工况作用下的故障具有隐蔽性和传递性, 其异常特征可通过机械与电气信号路径向系统层面扩散。因此, 从结构演化与失效机理角度开展状态监测研究, 对实现故障早期识别与运行风险评估具有关键作用^[8]。在上述背景下, 基于 SCADA 数据的数据驱动状态监测方法得到了广泛研究并取得了一定进展。一些研究人员分别从

轴承、齿轮箱、叶片等风电机组关键部件出发, 结合时序建模与深度学习方法开展故障诊断方法研究^[9-11]。如金晓航等^[12]使用多层自组织映射网络 (multilayer self-organizing map, MLSOM) 模型的输入构建部件的正常行为模型构建发电机、齿轮箱、变流器等关键部件的监测模型。

考虑到风电机组内不同零部件间存在显著的结构与功能耦合关系, SCADA 数据中各状态变量之间呈现出复杂的相互依赖关系, 图神经网络 (graph neural network, GNN) 通过引入图结构对变量间关系进行建模, 能够更有效地刻画机组运行状态的系统级特征。如 Jin 等^[13]通过构建有向时空图刻画风电机组故障传播路径, 提高了模型对系统结构关系的表达能力。郑毅等^[14]基于功能单元构建多级时空图结构, 实现了 SCADA 数据时空相关性的有效建模。温楷儒等^[15]基于传感器空间关系提出可解释时空图卷积网络实现对齿轮箱的故障诊断。然而, 上述方法主要依赖图结构和历史运行数据, 难以充分约束复杂物理过程, 在数据分布发生变化时, 模型泛化能力与物理一致性存在一定局限, 因此需要引入物理机理信息加以约束。

在风电机组状态监测中, 白箱 (机理) 模型受限于参数不确定性, 难以准确描述复杂变工况条件下的机组动态特性; 黑箱 (数据驱动) 模型虽能捕捉系统行为, 但缺乏物理可解释性。因此, 融合物理机理与数据驱动优势的混合建模方法逐渐成为状态监测领域的重要研究方向。物理信息神经网络 (physics-informed neural network, PINN) 通过在神经网络中引入物理约束, 将机理知识与数据驱动方法相结合, 在稳健性与可解释性方面具有优势^[16]。Li 等^[17]基于风电机组结构气动弹性模型引入物理约束, 实现机组载荷预测。Zhou 等^[18]构建物理-数据耦合模型用于风电机组功率预测。

尽管 PINN 在融合机理与数据方面表现出良好的潜力, 但在工程应用中仍面临物理机理模型不完备、部分状态难以观测及训练成本较高等问题。为解决上述问题, 研究者将图神经网络引入物理信息建模框架, 提出了物理信息图神经网络 (physics-informed graph neural network, PIGNN) 方法。相关研究表明, PIGNN 在复杂系统建模中具有一定优势。Zhang 等^[19]将 PIGNN 与有限差分法结合, 用于偏微分方程求解, 提高了在不规则结构

下的建模精度;Park 等^[20]基于图结构与功率转换机理刻画机组交互特性,实现风电机组的功率估计;Chen 等^[21]通过融合 GNN 与物理方程,提高了多孔介质中流体流动过程的建模精度。PIGNN 在刻画系统变量结构关联关系的同时引入物理约束信息,在描述复杂时空耦合过程方面具有一定优势,为风电机组状态监测提供了新的研究思路。

鉴于 PINN、GNN 在工程应用中的局限性以及 PIGNN 在刻画系统变量结构关联和物理规律方面的优势,提出一种面向风电机组状态监测的 PIGNN 方法,主要贡献为:

1) 构建了一种基于 SCADA 数据的 PIGNN 框架,将物理关系引入为软约束项,该框架在物理模型不完备条件下实现 PINN 与 GNN 的有效融合,提升了在风电机组状态监测任务中的适用性与泛化能力;

2) 提出一种基于指数移动平均的自适应归一化策略,对每个物理约束项在反归一化条件下独立计算残差,该方法能够平衡不同物理约束与数据驱动目标之间的影响,提高损失函数优化过程的数值稳定性。

1 风电机组图模型构建

GNN 通过消息传递机制在图中节点邻域内更新信息,挖掘复杂拓扑关系,通过多层传播机制捕捉整体特性,在装备状态监测、故障诊断和时空信息建模中表现出优势。考虑到风电机组各子系统的高度耦合特点,SCADA 特征间存在明确的物理依赖与能量传递路径,引入图结构通过节点与边显式刻画特征间的耦合关系,实现对风电机组拓扑关系的有效利用。

1.1 特征图构建

针对机组状态监测任务,重点关注温度、功率与转矩等反映健康状态的关键特征;此外,引入物理约束并结合机组结构,选取具有明确物理意义的 SCADA 变量作为输入特征,如表 1 所示。每个选取的 SCADA 特征在图结构中对应一个节点。图是不规则的欧几里德结构,用 $G = \{V, E\}$ 表示,其中节点集合 V 为 SCADA 特征集合,边集合 E 为不同特征间的拓扑关系。

皮尔逊相关系数用于衡量两组数据之间的线性相关程度,其取值范围为 $[-1, 1]$ ^[22]。各节点之间的相关性如图 1 所示,在此基础上构造的节点连接图如图 2 所示。图 1 与 2 的节点含义一致,其中节点编号与对应物理量的关系见表 1。

图结构中边的构建考虑方向性与连接关系,有向边的方向主要依据风电机组内部结构和能量流动确定,即同时考虑下文的 2) 机组结构与 3) 能量流动,而有向边的连接关系综合考虑下文的 3 个方面:

表 1 风电机组 SCADA 部分特征信息
Table 1 Some variables of wind turbine's SCADA system

节点序号	风电机组特征	数据范围	单位
1	平均有功功率 30 s	1.0~1 560.0	kW
2	无功功率	-51.2~245.0	kVar
3	电网电压 1	389.0~426.0	V
4	电网电流 1	6.0~1317.0	A
5	平均风速 30 s	3.0~22.655	m/s
6	平均风向 30 s	0.028~359.914	°
7	发电机转速	4.0~1 955.0	rpm
8	发电机绕组 2 温度	-1.1~68.9	℃
9	发电机驱动端轴承温度	-1.2~26.0	℃
10	发电机非驱动端轴承温度	-3.0~36.2	℃
11	主轴转速	0.12~16.59	rpm
12	偏航夹角	-118.817~109.062	°
13	桨叶 1 实际值	-0.01~90.07	°
14	机舱控制柜温度	-1.5~10.5	℃
15	机舱温度	6.9~34.7	℃
16	环境温度	-1.0~26.2	℃

1) 相关性(ρ):基于相关性构建连接关系。当皮尔逊相关系数高($|\rho| > 0.8$)时,认为两个节点之间存在较强线性相关性,优先建立连接;当 $|\rho| \in [0.4, 0.8]$ 且位于同一能量或控制链路中的节点,保留连接关系。例如风向(节点 6)与主轴转速(节点 11)的 ρ 为 0.58,但由于其处于同一能量传递路径中,因此将其进行连接。对于相关性高但缺乏直接拓扑连接关系或因果联系的节点不建立边连接。例如平均有功功率 30 s(节点 1)与风速(节点 5)的 ρ 为 0.95,但未构建边,因为两者之间不存在直接作用关系,其相关性高主要由于风能经传动链与发电机间的能量传递。

2) 机组结构:基于风轮叶片、主轴、齿轮箱、发电机到电网构成的系统构建图结构。如桨叶 1 实际值(节点 13)与主轴转速(节点 11)为风轮和主轴直接连接;发电机驱动端轴承温度(节点 9)与发电机非驱动端轴承温度(节点 10)的 ρ 为 0.72,虽然两个特征间相关性不强,但仍相连。

3) 能量流动:依据“风能—气动模型—传动系统—发电系统—电气系统”这一能量流动路径,连接明确存在于该路径上的节点。如路径上的平均风速 30 s(节点 5)、主轴转速(节点 11)、发电机转速(节点 7)和平均有功功率 30 s(节点 1)特征节点相连。

综上,得到构造的节点连接图。该图结构在保留变量间统计相关信息的同时,引入物理拓扑与能量传递约

束,使每条边均具有明确的依据,为后续模型构建工作奠定基础。




图1 各节点皮尔逊相关系数

Fig. 1 Pearson correlation coefficient plot for each node




图2 风电机组对应的图结构

Fig. 2 The constructed wind turbine's graph

1.2 图神经网络的时空模型构建

时空模型结构包含图注意力网络 (graph attention networks, GAT)、门控循环单元 (gated recurrent unit, GRU) 和全连接层,通过 GAT 捕捉空间信息,随后经过 GRU 捕捉时序信息,最后经过全连接层得到图中各节点的预测结果。

GAT 通过多头注意力机制对每个节点的邻域特征进行加权聚合,不同注意力头在独立参数空间上并行学习,从而增强节点对局部拓扑结构及邻域特征的代表能力。对于包含 N 个节点,每个节点具有 L 维特征的输入数据 $\mathbf{h} = \{\vec{h}_1, \vec{h}_2, \dots, \vec{h}_N\}$, $\vec{h}_i \in \mathbf{R}^L$,经过一层 GAT 对节点特征进行加权聚合后,其节点信息为: $\mathbf{h}' = \{\vec{h}'_1, \vec{h}'_2, \dots, \vec{h}'_N\}$, $\vec{h}'_i \in$

$\mathbf{R}^L$ 。相邻节点 (i, j) 间的注意力值计算公式为:

$$e_{ij} = \text{LeakyReLU}(\mathbf{a}^T \mathbf{W} \mathbf{h}_i \| \mathbf{W} \mathbf{h}_j) \quad (1)$$

其中, e_{ij} 是节点 j 对节点 i 的重要度 (非对称), $\text{LeakyReLU}()$ 是激活函数, $\mathbf{a}^T$ 是向量参数, $\mathbf{W}$ 是可学习权重。整个图注意力公式为:

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(\mathbf{a}^T [\mathbf{W} \mathbf{h}_i \| \mathbf{W} \mathbf{h}_j]))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(\mathbf{a}^T [\mathbf{W} \mathbf{h}_i \| \mathbf{W} \mathbf{h}_k]))} \quad (2)$$

其中, $\exp()$ 是指数函数。文中采用多头注意力机制,对所有注意力头数计算的结果取平均。

为刻画不同节点的交互关系,本研究在 PIGNN 框架中引入双通道 GAT,不同注意力头侧重于不同范围的结构特征与运行模式,从多个不同角度同时捕获关系信息。在多层 GAT 之间引入残差连接,防止层数过多引起的信息丢失,避免深层网络带来信息衰减问题。在 GAT 进行信息更新之后,使用 GRU 进行时间序列建模,以刻画风电机组运行中的动态特性。GRU 利用门控机制对时间序列特征进行递归更新,动态调节历史信息与当前观测的权重,实现长期依赖建模,同时计算的复杂度较低。GRU 的前向传播计算为:

$$\begin{cases} \mathbf{u}_t = \sigma(\mathbf{W}_{xu} \mathbf{x}_t + \mathbf{W}_{hu} \mathbf{h}_{t-1} + \mathbf{b}_u) \\ \mathbf{r}_t = \sigma(\mathbf{W}_{xr} \mathbf{x}_t + \mathbf{W}_{hr} \mathbf{h}_{t-1} + \mathbf{b}_r) \\ \tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_{xh} \mathbf{x}_t + \mathbf{W}_{hh} (\mathbf{r}_t \odot \mathbf{h}_{t-1}) + \mathbf{b}_h) \\ \mathbf{h}_t = \mathbf{u}_t \mathbf{h}_{t-1} + (1 - \mathbf{u}_t) \odot \tilde{\mathbf{h}}_t \end{cases} \quad (3)$$

其中, $\mathbf{u}, \mathbf{r}$ 表示更新门和复位门, $\mathbf{W}$ 和 $\mathbf{b}$ 表示网络的权重矩阵和偏置向量。

在经过 GAT 与 GRU 模块提取特征后,模型采用全连接回归层将高维表示映射至目标变量空间,从而完成风电机组关键变量的预测。

2 风电机组物理信息约束设计

通过 GNN 前向传播得到模型的预测输出,需要通过损失函数计算损失进行反向传播和梯度更新,使时空模型在遵循物理规律的同时,保持对观测数据的拟合能力。后文介绍模型在物理约束下的损失函数计算方式。

2.1 PINN 模型

PINN 通过构建连续可导的神经网络 $\hat{y}(x, t; \theta)$, 对系统物理状态 $y(x, t) \in \mathbf{R}^d$ 进行参数化表示。对应风电机组的运行状态, PINN 中 x 表示空间或状态变量, t 为时间, θ 为网络参数。状态变量满足的物理方程为: $F(y, \partial y, \dots, x, t) = 0$, 其中 F 是函数关系, 括号内的是方程涉及到的各种类型算子。若监测变量实际值与预测值为 y 和 $\hat{y}$, 则可得损失项: $\mathcal{L} = a(\hat{y}, y)$, a 是表示预测值与真实值之间误差的度量函数, 在物理损失项中, a 结合物理规

律刻画这种偏差,对于数据拟合项, a 为基于统计指标的误差度量,例如均方误差(mean square error, MSE)。总损失构造如式(4)所述,模型参数优化的总损失函数为:

$$\mathcal{L}_{\text{total}} = \lambda_{\text{phys}} \mathcal{L}_{\text{phys}} + \lambda_{\text{fit}} \mathcal{L}_{\text{fit}} \quad (4)$$

其中, λ_{phys} 和 $\mathcal{L}_{\text{phys}}$ 分别为物理约束的权重和损失项, λ_{fit} 和 $\mathcal{L}_{\text{fit}}$ 分别为数据拟合的权重和损失项,数据损失为了约束预测值接近真实值,本研究使用 MSE 衡量模型监测变量的预测值和真实值的拟合效果。MSE 定义为:




图3 风电机组物理约束模型构建

Fig. 3 Physical constraint modeling of wind turbine

物理项损失构成为:

$$\mathcal{L}_{\text{phys}} = \mathcal{L}_{\text{pwr}} + \mathcal{L}_{\text{tq}} + \mathcal{L}_{\text{volt}} + \mathcal{L}_{\text{temp}} + \mathcal{L}_{\text{bdry}} \quad (6)$$

其中, $\mathcal{L}_{\text{pwr}}$ 、 $\mathcal{L}_{\text{tq}}$ 、 $\mathcal{L}_{\text{volt}}$ 、 $\mathcal{L}_{\text{temp}}$ 和 $\mathcal{L}_{\text{bdry}}$ 分别为功率损失、力矩损失、电压损失、温度损失和边界损失。

1) 功率损失。基于风电机组的气动功率模型^[23],并结合实测有功功率计算损失。计算公式如式(7)所示。

$$\mathcal{L}_{\text{pwr}} = \frac{\text{MSE}(P_{\text{calc}}, P_{\text{act}})}{(P_{\text{act}})^2} \quad (7)$$

其中, P_{calc} 和 P_{act} 分别为计算和实测功率,其中 P_{calc} 通过基于贝兹定律^[24]的功率公式(如式(8))计算得到,即:

$$P_{\text{calc}} = \frac{1}{2} \rho \pi R^2 v_{\text{wind}}^3 C_p \eta_g \quad (8)$$

其中, ρ 为空气密度, R 为叶轮半径, v_{wind} 为风速, η_g 为传动系统总效率, η_g 为发电系统效率, C_p 为风能利用系数^[25],是风电机组将风能转换为电能的效率,与叶尖速比和桨距角相关。

2) 力矩损失。该损失项基于传动系统的动力学方程,最小化气动转矩与电磁转矩之间的残差,来满足转矩平衡。风电机组动力学方程^[26]为:

$$J \frac{d\omega}{dt} = T_m - T_e \quad (9)$$

其中, J 为风电机组等效发电机侧的转动惯量, $d\omega/dt$ 为基于有限差分法计算发电机角加速度, T_m 为机械输入转矩, T_e 为电磁力矩。发电机在机械转矩驱动下,通过电磁转矩实现机械能向电能的转换,与发电机内部

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

其中, n 为总样本数, y_i 和 $\hat{y}_i$ 为第 i 个样本的真实值和预测值。

2.2 模型各项物理约束设计

在风电机组的状态监测任务中,依据机理的损失函数构建方法如图3所示。图3中给出了各物理约束项的构成关系及其计算方法,下面详细阐述损失函数的构建过程。

$$\begin{aligned} 1. \text{功率平衡} & P_{\text{calc}} = \frac{1}{2} \rho \pi R^2 v_{\text{wind}}^3 C_p \eta_g \\ 2. \text{力矩平衡} & J \frac{d\omega}{dt} = T_m - T_e \\ 3. \text{电压平衡} & V = V_0 + aQ + bP \\ 4. \text{温度平衡} & \frac{dT_g(t)}{dt} = H(t) - T_g(t) + T_e(t) \\ 5. \text{边界限制} & y_{\text{pred}} = \{y(t) | y(t) \in [y_{\min}, y_{\max}], \underbrace{V_r, y \in L^2}_{\text{正则化}}, \underbrace{p(y) \approx p_{\text{dtm}}}_{\text{密度一致}}\} \end{aligned}$$

参数相关。

转矩平衡损失项的定义为:

$$\mathcal{L}_{\text{tq}} = \left[\frac{J \frac{d\omega}{dt} - (T_m - T_e)}{T_m} \right]^2 \quad (10)$$

3) 电压损失。考虑到变流器与电网侧的电气特性,并借鉴文献[27]中电压和功率的关系的建模思想,构造电压平衡损失项为:

$$\mathcal{L}_{\text{volt}} = \text{MSE}(V, V_0 + aQ + bP) \quad (11)$$

其中, V 表示并网点电压, V_0 是变压器低压侧电压, Q 和 a 分别表示无功功率和对应的电压灵敏度, P 和 b 分别表示有功功率和对应的电压灵敏度,考虑到数据的精确度有限,采用线性化电压-功率敏感度模型描述低电压侧电压行为。电压项变化对模型起到正则化的作用。

4) 温度损失。依据电流生热、环境散热的物理规律,借鉴文献[28]中将电损作为热源输入并与散热项耦合的建模方法,在模型中引入简化的热动力学方程作为约束损失项。温度损失项定义为:

$$\mathcal{L}_{\text{temp}} = \left(\frac{dT_g}{dt} - (H - T_g + T_e) \right)^2 \quad (12)$$

其中, T_g 为发电机绕组温度, T_e 为环境温度, dT_g/dt 表示为温度变化率, H 表示铜损,由于绕组发热主要由铜损引起,近似与电网电流的平方成正比。

5) 边界损失。考虑到数据驱动方法存在预测值越界、样本维度上不平滑和预测分布与真实分布不一致的

情况,构建了一种边界损失函数。PINN 中的边界损失项(如式(13)所示)以软约束形式嵌入损失函数施加惩罚^[29]。

$$\mathcal{L}_{\text{bdry}} = \delta \cdot (\mathcal{L}_{\text{ADC}} + \mathcal{L}_{\text{SP}} + \mathcal{L}_{\text{DDC}}) \quad (13)$$

其中, δ 为调整系数,文中将其设定 δ 为 0.1。 $\mathcal{L}_{\text{ADC}}$ 、 $\mathcal{L}_{\text{SP}}$ 和 $\mathcal{L}_{\text{DDC}}$ 分别为可行域约束、平滑度惩罚和概率密度约束。

(1) 可行域约束。当预测值落在界内即 $y_{\text{pred}} \in [y_{\min}, y_{\max}]$ 时,损失为 0,当预测值越界时做出惩罚,定义为:

$$\mathcal{L}_{\text{ADC}} = \frac{1}{N} \sum_{i=1}^N [\max(0, y_{\min} - \hat{y}_i) + \max(0, \hat{y}_i - y_{\max})] \quad (14)$$

其中, $\hat{y}_i$ 表示模型第 i 个的预测输出, N 是一个 batch 内的采样点数, $y_{\min}$ 和 $y_{\max}$ 表示由历史 SCADA 数据统计得到的全局最小边界和全局最大边界, $\max(0, \cdot)$ 表示 ReLU 函数,保证预测结果符合机组实际运行范围。

(2) 平滑度惩罚。此项用于抑制预测序列在相邻时间步之间出现非物理的剧烈震荡^[30],对时间连续性约束,即:

$$\mathcal{L}_{\text{SP}} = \frac{1}{N-1} \sum_{i=1}^{N-1} (\hat{y}_{i+1} - \hat{y}_i)^2 \quad (15)$$

其中, $\hat{y}_i$ 和 $\hat{y}_{i+1}$ 为模型第 i 和第 $i+1$ 个预测值。

(3) 概率密度约束。参考把分布差异作为物理约束的思想^[31],采用核密度估计(kernel density estimation, KDE)获取的两两节点之间的密度信息,用于约束模型预测结果在统计意义上与真实运行状态上的分布的一致,即:

$$\mathcal{L}_{\text{DDC}} = \left(\frac{1}{M} \sum_{i=1}^M \tilde{y}_i - \frac{1}{N} \sum_{j=1}^N \tilde{z}_j \right)^2 \quad (16)$$

其中, $z = \{z_i\}_{i=1}^N$ 代表由历史数据估计得到的运行边界概率密度分布样本, $\tilde{y}_i$ 代表归一化后的预测输出, $\tilde{z}_i$ 代表归一化后的边界分布样本, M 为模型预测的样本数, N 为用于构建历史边界分布的样本数。

2.3 数据数量级处理

考虑到式(6)涉及多种物理量的损失,为统一量纲,处理流程包括物理量的反归一化预处理以及损失计算中的归一化操作。

1) 物理量的反归一化预处理。考虑到不同 SCADA 变量在量纲与数值尺度上存在显著差异,前向传播模型的输入与输出均为归一化后的数据。因此,在计算物理损失项时,需将模型预测结果反归一化(如式(17)所示)至实际物理量空间,以保证物理约束的有效性。

$$x = x \cdot (x_{\max} - x_{\min}) + x_{\min} \quad (17)$$

其中, $x_{\max}$ 和 $x_{\min}$ 为训练数据集 X 的中节点特征的最大值和最小值。

2) 损失计算中的归一化操作。若将真实尺度的物理损失项直接参与反向传播,将导致梯度更新不平衡,影响训练稳定性。为了避免不同物理量纲对总损失的影响,需平衡多项损失,让其在相近数量级内参与模型训练。损失计算中的归一化公式为:

$$\mathcal{L}_i^{\text{phys(norm)}} = \frac{\mathcal{L}_i^{\text{phys}}}{\text{EMA}_i^{(t)} + \varepsilon} \quad (18)$$

其中, $\mathcal{L}_i^{\text{phys(norm)}}$ 是归一化后的单项物理损失项,通过指数移动平均(exponential moving average, EMA)方法^[32]对各损失项的统计量进行平滑更新。在训练过程中,该方法实现了不同物理损失项在数值尺度上的统一,使梯度计算更加稳定,并保持各损失项的物理意义。 $\text{EMA}_i^{(t)}$ 为采用 EMA 方法后 t 时刻的指数移动平均。EMA 对历史损失施加指数衰减权重,实现时序信号的平滑处理,可有效抑制噪声波动并稳定刻画动态变化趋势,可视作为一种动态归一化策略,如式(19)所示。

$$\text{EMA}_i^{(t)} = \beta \text{EMA}_i^{(t-1)} + (1 - \beta) \mathcal{L}_{\text{scale}}(t) \quad (19)$$

其中, $\mathcal{L}_i^{\text{phys}}(t)$ 是第 t 次迭代计算的原始物理损失, $\text{EMA}_i^{(t-1)}$ 第 $t-1$ 时刻迭代的指数移动平均, β 为平滑系数。 $\mathcal{L}_{\text{scale}}(t)$ 是指变换后的残差。如式(20)所示。

$$\mathcal{L}_{\text{scale}} = \begin{cases} \log(1 + |\mathcal{L}_{\text{raw}}|), & \mathcal{L}_{\text{raw}} \in \{\text{pwr}, \text{tq}, \text{volt}\} \\ |\mathcal{L}_{\text{raw}}|, & \mathcal{L}_{\text{raw}} \in \{\text{temp}, \text{bdry}\} \end{cases} \quad (20)$$

其中, $\mathcal{L}_{\text{raw}}$ 为原始残差, $\mathcal{L}_{\text{scale}}$ 为尺度处理的残差。鉴于功率、力矩及电压在复杂工况下具有非平稳突变特征,其对应的物理损失项易产生幅值较大的异常波动对梯度更新造成干扰,故本研究对此 3 项损失采用对数变换,以压缩数值范围并提高梯度更新的稳定性。温度与边界损失变化较为平滑,故采用绝对值形式以保持约束关系的线性特征,从而提高训练稳定性。

3 基于物理信息图神经网络的风电机组状态监测方法

对于风电机组的状态监测,单独使用 PINN 建模在对刻画变量间耦合关系方面仍面临一些挑战。GNN 能够通过消息传递机制,有助于提升模型对复杂系统运行状态的表达能力。在此基础上,引入物理约束,将关键物理规律融入模型训练,对模型参数更新进行辅助优化。PIGNN 为复杂系统状态监测提供了预测精度较高且稳定的建模方法。

正常行为建模(normal behavior modeling, NBM)由于无需额外传感器配置且不依赖故障样本,被认为是一种成本较低、具有工程应用潜力的风电机组故障检测手段^[14]。风电机组数据故障样本少,健康数据占据大多数,状态监测具有较高复杂性,适合使用 NBM 方法刻画

风电机组在健康状态下的运行模型。基于 PIGNN 的风电机组正常行为建模方法如图 4 所示,将预处理后的正常风电机组 SCADA 数据依据先验知识构图形成图数据

输入到 PIGNN 模型中,计算模型预测残差的同时考虑物理规律的约束,通过反向传播更新模型参数,得到机组正常行为模型。




图 4 基于 PIGNN 的风电机组正常行为建模方法
Fig. 4 PIGNN-based normal behavior modeling of wind turbine

构建 NBM 的流程为:

1) 对历史健康机组的 SCADA 数据进行预处理与归一化。预处理包括去除缺失值、零功率等异常点。归一化是指采用最大最小归一化,保证尺度统一,以保证多变量输入在数值上的稳定性与可靠性;

2) 依据风电机组能量传递路径及部件耦合关系,构建表征关键运行特征之间物理关联的图结构。其中,节点对应关键运行特征,边刻画功率传递、力矩耦合及控制关系等物理相关性,为图神经网络建模引入风电机组先验结构知识;

3) 在前向传播建模中,构建以 PIGNN 为核心的预测模型。模型采用 GAT 刻画关键运行特征间的空间依赖关系,并结合 GRU 对 SCADA 时序数据进行建模,输出归一化空间中各节点的预测结果;

4) 通过计算模型预测值与观测值的残差构建总损失,总损失由数据拟合损失与物理约束损失组成,并通过反向传播优化模型参数。物理约束损失涵盖功率、力矩、电压、温度及边界等关键物理量,模型输出首先反归一化至物理单位空间后逐项计算各损失,并进行平滑处理以提高训练稳定性。

基于离线训练好的 PIGNN 模型,可对实时 SCADA 数据进行在线状态评估。在线监测阶段沿用离线训练阶段相一致的数据预处理与图构建流程,但不进行物理损失计算与参数更新。通过计算模型预测结果与实际观测值之间的偏差构造残差序列,并利用离线数据残差的统计特征确认阈值,用于判定机组运行状态,从而实现对风电机组状态监测。

4 风电机组案例分析与讨论

本研究利用两台双馈式风电机组的实际 SCADA 数

据对所提方法进行验证。案例 1 采用机组#1 的数据,其中包含故障记录;案例 2 采用一台健康运行的机组(机组#2)数据。机组信息如表 2 所示。

表 2 风电机组信息表		
Table 2 Information of wind turbines		
机组信息	机组#1	机组#2
额定功率	1.5 MW	1.5 MW
地理位置	西南地区	华北地区
采样周期	5 min	5 min
训练样本	59 072	13 312
时间区间	2016.01 至 2017.02	2017.06 至 2018.06
故障记录	有	-
故障部位	发电机	-
故障时间	2017 年 2 月 5 日	-

4.1 案例 1-故障机组分析

采用该风电机组在 2016 年 1 月 1 日到 2017 年 2 月 5 日的 SCADA 数据进行分析,数据采样间隔为 5 min。根据运维日志,该机组在 2017 年 2 月 5 日 11:20:00 报警。首先,对原始数据进行预处理,将清洗后在 2016 年 1 月 1 日至 2016 年 12 月 31 日期间的数据作为正常数据集,并把正常数据集按照 7:3 划分为训练集和验证集;2017 年 1 月 1 日至 2017 年 2 月 5 日期间的数据作为测试集。然后,选择表 1 中的节点特征构建图结构(如图 2 所示),通过设置滑动窗口对各节点下一时刻状态进行预测,其中正常数据集总计有 59 072 个样本,测试集有 7 936 个样本。模型参数通过 AdamW 算法进行迭代更新。

在模型训练过程中需对相关参数进行设置,其具体取值见表 3。模型由两层 GAT、一层 GRU 及线性输出层

组成。模型采用双通道 GAT 结构,双通道 GAT 是一种并行多分支的图注意力结构,每个通道拥有独立的参数,通过不同的注意力映射分别捕捉节点间的多样化关联特征,有助于提高模型对特征关系的表达能力。

表 3 风电机组 PIGNN 状态监测模型超参数设置

Table 3 The hyperparameter settings of PIGNN-based condition monitoring model for wind turbine

模块	参数项	数值设定
GAT(第 1 层)	隐藏层数	32
	注意力头数	16(通道 1)/32(通道 2)
GAT(第 2 层)	隐藏层数	64
	注意力头数	8(通道 1)/16(通道 2)
GRU	隐藏层数	64
线性输出	层 1 维度	32
	层 2 维度	16
训练设置	训练次数	500
	学习率	0.001

在第 1 层 GAT 中,隐藏特征维度设置为 32,注意力头数分别为 16 和 32;在第 2 层 GAT 中,隐藏特征维度设置为 64,注意力头数分别为 8 和 16。较高的隐藏特征维度能够为节点表示提供更大的特征表达空间,从而有助于刻画复杂变量关系,通过不同数量注意力头的组合,使模型能够获得更加丰富的节点特征表示。GRU 的隐藏层数为 64,表示每个时间步的输出特征维度为 64。初始学习率设置为 0.001,当验证损失在连续 30 轮训练中未出现下降时,将学习率按 0.7 的比例衰减。

在本研究中,监测目标选取为有功功率。因为有功功率作为风电机组能量转换过程的最终输出,能够综合反映气动、机械及电气子系统的耦合响应,因此在系统异常时能够较为敏感地表征各子系统运行状态的偏离。此外,模型训练阶段构造的物理约束损失函数亦与功率密切相关。因此,将有功功率残差作为主要监测指标,可兼顾监测有效性与工程可实现性^[33]。在分析有功功率残差时,通过训练集确定阈值,将测试集中连续 3 次超过阈值的样本认定为异常样本。

在模型结构、训练参数和监测目标确定的基础上,为分析物理约束权重对模型性能的影响,设计了不同物理项权重的对比实验,结果如表 4 所示。

其中报警率定义为超过设定阈值的样本数占测试集总样本数的比例。在故障数据集上,较高的报警率通常表明模型具有更强的异常识别能力。RMSE 衡量模型预测值与真实值之间的平均偏差大小,反映预测误差的绝对量级,数值越小表示拟合效果越好。当物理项权重

表 4 PIGNN 模型损失权重设置对比

Table 4 Comparisons of loss weight settings in PIGNN

物理项权重	RMSE	报警率/%	报警时间
0.01	0.097 8	0.11	2017-02-01
0.02	0.101 1	0.83	2017-01-31
0.03	0.103 4	1.45	2017-01-28
0.04	0.129 1	0.04	2017-01-30
0.05	0.106 2	5.46	2017-01-27
0.06	0.134 4	0.15	2017-01-30

为 0.05 时,RMSE 数值相对较小为 0.106 2、报警率相对较高为 5.46% 和报警时间相对较早为 2017-01-27。此外,随着物理项权重增加至 0.06,反而导致报警率下降,说明过强的物理约束会造成模型过拟合。综合考虑拟合精度与预警效果,物理项权重设定为 0.05 时,能够在保证 RMSE 合理的同时最大化异常检测能力,实现数据拟合与故障预警的平衡。

为探讨各物理约束在模型训练中的作用,本文进行了消融实验,分析不同约束对模型性能的影响。具体设置包括:1)功率约束项 $\mathcal{L}_{\text{pwr}}$;2)力矩约束项 $\mathcal{L}_{\text{tq}}$;3)电压约束项 $\mathcal{L}_{\text{volt}}$;4)温度约束项 $\mathcal{L}_{\text{temp}}$;5)边界约束项 $\mathcal{L}_{\text{bdry}}$;6)数据拟合项($\mathcal{L}_{\text{fit}}$)。实验引入决定系数(coefficient of determination, R^2)表示模型的拟合精度,其数值越接近 1 表明模型对数据的拟合能力越强。组合上述损失项并记录各组合下的 RMSE、 R^2 、报警率及报警时间,实验结果如表 5 所示。

表 5 PIGNN 模型损失函数物理项消融实验

Table 5 Ablation study of physical losses in PIGNN

损失函数	RMSE	R^2	报警率/%	报警时间
1+6	0.094 8	0.926 3	3.30	2017-01-27
1+2+6	0.097 9	0.921 3	0.88	2017-01-31
1+2+3+6	0.098 7	0.920 1	4.10	2017-01-28
1+2+3+4+6	0.111 9	0.897 3	0.98	2017-01-30
1+2+3+4+5+6	0.106 2	0.907 4	5.46	2017-01-27

使用关键损失项(1+6)可获得较低的 RMSE 和较高 R^2 ;逐步加入其他损失项 2)~5)后的实验组在预测精度和报警性能表现上存在差异,最后一个实验组(1+2+3+4+5+6)在 RMSE 和 R^2 上略低于部分子组合,但在报警率与报警时间方面表现更优,报警率仅为 5.46%,可显著增强预警效果。综上,本研究选取包含所有 6 项损失的组合,以在保持预测精度的同时实现报警的高可靠性和及时性,该组合能充分发挥各物理约束的互补作用,使模型在复杂工况下稳健识别异常运行状态。

基于上述分析,在物理项消融分析的基础上,固定物理项权重为 0.05,进一步对完整的传播模型进行性能对比实验,综合评估 RMSE、 R^2 、报警率及报警时间,以验证选定损失函数组合的有效性。随后,基于确定的正常行为模型结构,分析有功功率残差,模型结果如表 6 所示。

表 6 PIGNN 正常行为模型对比试验

Table 6 NBM comparisons of PIGNN

模型	RMSE	R^2	报警率/%	报警时间
GAT+TCN	0.105 3	0.909 0	0.23	2017-01-30
GAT+Transformer	0.102 6	0.913 6	0.37	2017-01-30
双通道 GAT	0.113 9	0.893 5	0.53	2017-01-30
单通道 GAT	0.143 2	0.831 8	0.01	2017-02-01
PIGNN	0.106 2	0.907 4	5.46	2017-01-27

可以看出,单通道 GAT 模型报警时间最晚、报警率低,且 RMSE 较高、 R^2 较低,表明预测精度有限;双通道 GAT 模型相比于单通道在各项指标上表现均有,但整体预测性能仍受限制。GAT+TCN 模型和 GAT+Transformer 模型都引入了处理时间序列的模块, RMSE 和 R^2 均高于单/双通道 GAT,说明预测精度较高,但报警率较低,说明其在识别机组故障时的灵敏度有限。相比之下,PIGNN 在保持较高预测精度 ($RMSE = 0.106\ 2$, $R^2 = 0.907\ 4$) 的同时,报警率显著提高 (5.46%),体现了其在早期预警与异常识别方面的优势,即模型不仅能准确拟合观测数据,还能更有效地捕捉潜在异常行为。

基于上述结果,进一步分析 PIGNN 模型在状态监测中的表现,如图 5 所示,其中模型在测试集上的有功功率残差如图 5(b) 所示。报警时间为 2017 年 1 月 27 日 22:45,且超出阈值比较明显。结果表明,在引入 PINN 物理约束后,有功功率预测残差在物理尺度下出现明显增大,部分时刻的数据点超出基于训练残差分布设定的阈值线。与图 5(a)中仅基于 MSE 损失函数的模型预测残差相比,PIGNN 模型的预测残差显示出引入物理约束后模型的明显改善。





图 5 案例 1 风电机组状态监测结果
Fig. 5 Wind turbine condition monitoring results at case 1

- 残差超出阈值的现象较为明显,存在两方面因素:
- 1) 有功功率作为多物理过程耦合后的综合量,对物理建模误差和参数不确定性高度敏感;
 - 2) 模型损失函数输出的不是归一化损失,而基于真实物理量下处理后的残差,详细分析见前文 2.3 节。

在此背景下,PIGNN 模型在数据拟合与物理一致性之间进行折中优化,使得部分原本被模型捕捉到的物理差异性在预测残差中被放大。

进一步分析各物理约束损失项的收敛情况,图 6 给出了不同物理项的残差变化,其中图 6(a)展示了案例 1 各损失项变化的详细结果。




图 6 不同物理项的残差变化
Fig. 6 Variations of different physical residuals

可以看出,在训练 500 轮后各物理损失已逐渐下降并趋于稳定,表明模型能够较快学习到相关的物理关系。其中,功率平衡损失在前期表现出一定的振荡收敛特性,这是由于该损失项通过气动功率模型建立风速、转速与桨距角之间的非线性耦合关系,对输入变化较为敏感所致;相比之下,力矩平衡、电压平衡及边界约束损失收敛较快且波动较小,主要由于相关物理量在 SCADA 数据中变化范围有限并受到控制系统约束,使模型在训练初期即可较好地满足约束条件。温度动态损失则表现为逐步收敛的趋势,这与温度变化具有时间累积特性有关。随着训练轮数增加,各物理损失项逐步收敛。

4.2 案例 2-健康机组分析

本案例选取东北地区一台健康机组的运行数据,该机组在 2017 年 6 月至 2018 年 6 月期间保持正常运行,详细数据见表 2。对该机组的数据采用与案例 1 相同的方法进行状态监测与分析。由于数据缺失问题,选取 2017 年 6 月至 2017 年 8 月时间段的数据为正常数据集,选取 2018 年 5 月至 2018 年 6 月时间段的数据为测试集。通过设置滑动窗口对时间序列数据进行样本构造,其中正常数据集总计有 13 312 个样本,测试集有 2 496 个样本。模型参数采用 AdamW 算法进行迭代更新。模型结构的超参数设置与案例 1 相同,见表 3,以验证模型在不同机组上的适用性与稳定性。

首先,对数据进行了预处理,包括缺失值删除、异常值剔除及限功率数据处理,以确保输入特征的有效性和一致性。为便于对比,本次实验选取同样的 16 个节点特征(见表 1)。

在此基础上,分别使用基于 MSE 损失的正常行为模型和基于物理损失的 PIGNN 模型对机组数据进行训练,在测试集中监测有功功率残差,结果如图 7 所示。




图7 案例2风电机组状态监测结果

Fig. 7 Wind turbine condition monitoring results at case 2

通过对比两类模型的残差分布发现,PIGNN 在案例 2 中对于有功功率的拟合精度相对较高,阈值判定下的误报次数较少,残差稳定,显示其在新工况下保持较稳定预测的能力,并且有力地说明了 PIGNN 模型在监测异常机组时对故障的敏感性和监测健康机组的稳定性。

健康案例中,各物理损失项整体收敛较为平稳,详细结果如图 6(b) 所示。各项损失在训练后期均稳定在相近水平附近,其中功率与力矩损失在 100 轮后趋于稳定,而电压与边界损失自训练初期即保持稳定变化趋势,温度损失整体随着训练逐渐收敛,表明热动态关系能够较好地描述健康机组温度变化特征。

总体来看,不同机组的物理损失项均能够逐步收敛并保持稳定,但其收敛过程及波动特性存在一定差异,这在一定程度上反映了不同运行状态下机组物理特性的变化。结果表明,引入物理约束的 PIGNN 模型能够在保持稳定训练过程的同时,对机组运行状态变化表现出一定敏感性。综合残差变化与报警结果分析可知,所建立的 PIGNN 模型在风电机组状态监测与早期预警方面具有较好的应用效果。

5 结 论

针对风电机组状态监测中 SCADA 数据物理信息不完整、机组部件强耦合以及多物理过程难以有效建模等问题,本研究提出了一种 PIGNN 方法。该方法通过图结构刻画关键运行变量及其耦合关系,并将功率平衡、力矩平衡、电压约束、温度动态边界限制等物理演化规律以软约束的形式引入模型训练,实现了物理先验与数据驱动建模的有效融合。为解决数据拟合损失与物理约束损失在数量级上的差异,本研究进一步采用基于指数加权移动平均的自适应归一化策略,使各损失项在训练过程中统一至相近的数值范围,从而提升模型的收敛速度与训练稳定性。通过对两台风电机组的案例分析报告表明,PIGNN 不仅对有功功率预测效果较好,而且在训练过程中通过物理约束引导模型学习关键物理量之间的关联关系,提高了早期故障预警能力。结果显示,即使在物理模型不完整或部分变量不可观测的情况下,引入物理约束仍能够提高风电机组状态监测的可靠性,并提高模型在实际运行中的适用性。基于本研究,可进一步将物理规律融入模型结构,实现网络架构与物理信息的深度结合;同时,损失函数的构建也可探索其他创新方法,以增强模型对物理约束的表达能力。

参考文献

- [1] 曲凯, 闫大鹏, 郑晓东, 等. 基于 ADP-DANN 的小样本风电集群短期功率预测方法[J]. 电力系统自动化, 2026, 50(7): 206-223.

- QU K, YAN D P, ZHENG X D, et al. Few-shot short-term power forecasting method for wind power clusters based on adaptive dual-predictor domain adversarial neural network [J]. *Automation of Electric Power Systems*, 2026, 50(7): 206-223.
- [2] 刘军, 安柏任, 张维博, 等. 大型风力发电机组健康状况评价综述[J]. *电力系统保护与控制*, 2023, 51(1): 176-187.
- LIU J, AN B R, ZHANG W B, et al. Review of health status evaluation of large wind turbines [J]. *Power System Protection and Control*, 2023, 51(1): 176-187.
- [3] 金晓航, 泮恒拓, 徐正国. 数据驱动的风电机组变桨系统状态监测[J]. *太阳能学报*, 2022, 43(4): 409-417.
- JIN X H, PAN H T, XU ZH G. Data-driven condition monitoring of wind turbine pitch systems [J]. *Acta Energiae Solaris Sinica*, 2022, 43(4): 409-417.
- [4] 龙寰, 杨婷, 徐劭辉, 等. 基于数据驱动的风电机组状态监测与故障诊断技术综述[J]. *电力系统自动化*, 2023, 47(23): 55-69.
- LONG H, YANG T, XU SH H, et al. A data-driven review on condition monitoring and fault diagnosis technologies for wind turbines[J]. *Automation of Electric Power Systems*, 2023, 47(23): 55-69.
- [5] 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. Fault diagnosis and prognosis for wind turbines: An overview [J]. *Chinese Journal of Scientific Instrument*, 2017, 38(5): 1041-1053.
- [6] STETCO A, DINMOHAMMADI F, ZHAO X Y, et al. Machine learning methods for wind turbine condition monitoring: A review [J]. *Renewable Energy*, 2019, 133: 620-635.
- [7] RAHIMILARKI R, GAO ZH W, JIN N L, et al. Convolutional neural network fault classification based on time-series analysis for benchmark wind turbine machine[J]. *Renewable Energy*, 2022, 185: 916-931.
- [8] 黄晟, 凌吉莉, 魏娟, 等. 大规模风电机组服役质量调控方法研究综述[J]. *电工技术学报*, 2025, 40(10): 3274-3300.
- HUANG SH, LING J L, WEI J, et al. Review of quality control methods for large-scale wind farm operation[J]. *Transactions of China Electrotechnical Society*, 2025, 40(10): 3274-3300.
- [9] 尹诗, 侯国莲, 胡晓东, 等. 风力发电机组发电机前轴承故障预警及辨识[J]. *仪器仪表学报*, 2020, 41(5): 242-251.
- YIN SH, HOU G L, HU X D, et al. Fault warning and identification of front bearing of wind turbine generator[J]. *Chinese Journal of Scientific Instrument*, 2020, 41(5): 242-251.
- [10] 申艳杰, 李鹏飞, 武英杰, 等. 基于双馈式风电机组定子电流信号现象学模型的齿轮箱故障监测方法[J]. *仪器仪表学报*, 2025, 46(9): 348-359.
- SHEN Y J, LI P F, WU Y J, et al. A phenomenological model-based gearbox fault monitoring method using stator current analysis for doubly-fed induction wind turbines[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(9): 348-359.
- [11] WEI CH CH, CAI SH M, YANG H, et al. Advanced deep learning-based methodology for multi-class diagnosis of wind turbine blade faults at the wind farm level[J]. *Engineering Applications of Artificial Intelligence*, 2025, 160: 111801.
- [12] 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. Wind turbine condition monitoring based on improved multilayer self-organizing map[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(3): 231-241.
- [13] JIN X H, LYU SH Y, KONG Z Q, et al. Graph spatio-temporal networks for condition monitoring of wind turbine[J]. *IEEE Transactions on Sustainable Energy*, 2024, 15(4): 2276-2286.
- [14] 郑毅, 王承民, 刘保良, 等. 基于多层级时空图神经网络的风电机组在线异常检测[J]. *电力系统自动化*, 2024, 48(5): 107-119.
- ZHENG Y, WANG CH M, LIU B L, et al. Online anomaly detection for wind turbines based on multi-level spatio-temporal graph neural networks[J]. *Automation of Electric Power Systems*, 2024, 48(5): 107-119.
- [15] 温楷儒, 陈祝云, 黄如意, 等. 基于可解释时空图卷积网络的多传感数据融合诊断方法[J]. *机械工程学*, 2024, 60(12): 158-167.
- WEN K R, CHEN ZH Y, HUANG R Y, et al. Multi-sensor data fusion diagnosis method based on interpretable spatial-temporal graph convolutional network[J].

- Journal of Mechanical Engineering, 2024, 60(12): 158-167.
- [16] WU Y D, SICARD B, GADSDEN S A. Physics-informed machine learning: A comprehensive review on applications in anomaly detection and condition monitoring[J]. Expert Systems with Applications, 2024: 124678.
- [17] LI X, ZHANG W. Physics-informed deep learning model in wind turbine response prediction [J]. Renewable Energy, 2022, 185: 932-944.
- [18] ZHOU H Y, QIU Y N, FENG Y H, et al. Power prediction of wind turbine in the wake using hybrid physical process and machine learning models [J]. Renewable Energy, 2022, 198: 568-586.
- [19] ZHANG H, JIANG L X, CHU X K, et al. Combining physics-informed graph neural network and finite difference for solving forward and inverse spatiotemporal PDEs [J]. Computer Physics Communications, 2025, 308: 109462.
- [20] PARK J, PARK J. Physics-induced graph neural network: An application to wind-farm power estimation [J]. Energy, 2019, 187: 115883.
- [21] CHEN H Y, XUE L, LIU L, et al. Physics-informed graph neural network for predicting fluid flow in porous media [J]. Petroleum Science, 2025, 22(10): 4240-4253.
- [22] 纪德洋, 金锋, 冬雷, 等. 基于皮尔逊相关系数的光伏电站数据修复 [J]. 中国电机工程学报, 2022, 42(4): 1514-1523.
- JI D Y, JIN F, DONG L, et al. Data repairing of photovoltaic power plant based on pearson correlation coefficient [J]. Proceedings of the CSEE, 2022, 42(4): 1514-1523.
- [23] BURTON T, JENKINS N, SHARPE D, et al. Wind energy handbook [M]. John Wiley & Sons, 2011.
- [24] 邓兆顺, 朱介北, 俞露杰, 等. 实现转子转速保护的双馈异步发电机有功输出速降新方案 [J]. 电力系统保护与控制, 2021, 49(10): 113-122.
- DENG ZH SH, ZHU J B, YU L J, et al. A novel fast active power output reduction scheme of a DFIG for rotor speed security [J]. Power System Protection and Control, 2021, 49(10): 113-122.
- [25] SLOOTWEG J G, POLINDER H, KLING W L. Dynamic modelling of a wind turbine with doubly fed induction generator [C]. 2001 IEEE Power Engineering Society Summer Meeting, 2001: 644-649.
- [26] PERDANA A. Dynamic models of wind turbines [M]. Chalmers University of Technology, 2008.
- [27] XU H CH, DOMÍNGUEZ-GARCÍA A D, VEERAVALLI V V, et al. Data-driven voltage regulation in radial power distribution systems [J]. IEEE Transactions on Power Systems, 2019, 35(3): 2133-2143.
- [28] ARMANDO E, BOGLIETTI A, MANDRILE F, et al. Definition and experimental validation of a second-order thermal model for electrical machines [J]. IEEE Transactions on Industry Applications, 2021, 57(6): 5969-5982.
- [29] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. Journal of Computational Physics, 2019, 378: 686-707.
- [30] KISSAS G, YANG Y B, HWUANG E, et al. Machine learning in cardiovascular flows modeling: Predicting arterial blood pressure from non-invasive 4D flow MRI data using physics-informed neural networks [J]. Computer Methods in Applied Mechanics and Engineering, 2020, 358: 112623.
- [31] YANG L, ZHANG D K, KARNIADAKIS G E. Physics-informed generative adversarial networks for stochastic differential equations [J]. SIAM Journal on Scientific Computing, 2020, 42(1): A292-A317.
- [32] CAI ZH W, RAVICHANDRAN A, MAJI S, et al. Exponential moving average normalization for self-supervised and semi-supervised learning [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 194-203.
- [33] AZIZ U, CHARBONNIER S, BÉRENGUER C, et al. Critical comparison of power-based wind turbine fault-detection methods using a realistic framework for SCADA data simulation [J]. Renewable and Sustainable Energy Reviews, 2021, 144: 110961.

作者简介



金晓航(通信作者), 2014 年于香港城市大学获得博士学位, 现为浙江工业大学教授, 主要研究方向为工业大数据分析, 复杂装备的状态监测、故障诊断、寿命预测、智能运维。

E-mail: xhjin@zjut.edu.cn

Jin Xiaohang (Corresponding author) received his Ph. D. degree from City University of Hong Kong in 2014. He is a

professor in the College of Mechanical Engineering at Zhejiang University of Technology. His main research interests include industrial big data analysis, condition monitoring, fault diagnosis and prognosis, and intelligent maintenance for complex electromechanical equipment.



王宇,2005 年于西安理工大学获得学士学位,2008 年于西安交通大学获得硕士学位,2014 年获得香港城市大学获得博士学位,现为西安交通大学教授,主要研究方向为故障诊断与智能运维。
Email:ywang95@xjtu.edu.cn

Wang Yu received his B. Sc. degree from Xi'an University of Technology in 2005, his M. Sc. degree from Xi'an JiaoTong University in 2008, and his Ph. D. degree from City University of

Hong Kong in 2014. He is currently a professor at Xi'an JiaoTong University. His main research interests include fault diagnosis and intelligent operation and maintenance.



彭一真,2010 年于西安交通大学获得学士学位,2012 年于西安交通大学获得硕士学位,2018 年于西安交通大学获得博士学位,现为重庆大学副教授,主要研究方向为智能运维技术与数字孪生技术。
E-mail:pengyz@cqu.edu.cn。

Peng Yizhen received his B. Sc. , M. Sc. , and Ph. D. degrees all from Xi'an JiaoTong University in 2010, 2012, and 2018, respectively. He is currently an associate professor at Chongqing University. His main research interests include intelligent operation and maintenance and digital twin technology.