

采用变分网络的风力发电机组 叶片结冰程度量化方法

王倩月^{1,2}, 司刚全^{1,2}, 尹军华^{1,2}, 童文瀚^{1,2}, 李博^{1,2}, 王昕^{1,2}

(1. 西安交通大学电工材料电气绝缘全国重点实验室, 710049, 西安;

2. 西安交通大学电气工程学院, 710049, 西安)

摘要: 针对现有变分网络在风力发电机组监测数据特征提取和故障敏感性方面的不足,提出了一种面向风机正常状态建模的条件变分递归窗口网络(CVRWN),并据此构建叶片结冰程度量化方法。首先,采用引入自注意力机制的多组条件变分自编码器(CVAE)对窗口化的风机监测数据进行学习,以实现各时间窗口的潜在分布特征提取与风功率数据重构;其次,通过门控循环单元(GRU)实现跨窗口特征传递,并引入预测子模块以增强长期趋势建模能力,从而构建完整的 CVRWN 网络结构;随后,利用风机正常运行数据对所构建网络进行训练,通过联合优化重构损失与预测损失得到具备稳定建模能力的 CVRWN 模型;最终,将 CVRWN 模型最后一个窗口的风功率重构损失定义为风机叶片结冰指数 r ,实现叶片结冰程度的精准量化。实际运行数据验证表明,采用 CVRWN 模型进行风功率重构时,其精度较基础 CVAE 模型提升约 10%,验证了所提模型结构改进的合理性与有效性。在叶片结冰过程中,相较于基线模型,所提模型的结冰指数 r 能够精准动态表征叶片结冰演化过程,为极端环境下风力发电机组的安全运维提供量化参考。

关键词: 风力发电机组;叶片结冰;变分网络;正常状态建模;量化方法;重构损失

中图分类号: TP29 **文献标志码:** A

DOI: 10.7652/xjtuxb202508019 **文章编号:** 0253-987X(2025)08-0199-12

Quantification Method for Ice Accretion on Wind Turbine Blades Using Variational Network

WANG Qian Yue^{1,2}, SI Gangquan^{1,2}, YIN Junhua^{1,2},

TONG Wenhao^{1,2}, LI Bo^{1,2}, WANG Xin^{1,2}

(1. State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China;

2. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the limitation of existing variational networks in feature extraction and fault sensitivity for wind turbine monitoring data, this paper proposes a conditional variational recurrent window network (CVRWN) aimed at modeling the normal operating state of wind turbines, and constructs a quantification method for ice accretion on blades based on such network. First, multiple groups of conditional variational autoencoders (CVAEs) enhanced with self-attention mechanisms are employed to learn from windowed monitoring data, enabling the extraction of latent distribution features and the reconstruction of wind power data for each time

收稿日期: 2024-12-30。 作者简介: 王倩月(1999—),女,博士生;司刚全(通信作者),男,教授,博士生导师。

基金

项目: 国家重点研发计划资助项目(2021YFB2400800,2018AAA0101501)。

网络出版时间: 2025-04-10

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20250410.1135.002>

window. Next, gated recurrent units (GRUs) are used to facilitate cross-window feature transfer, and a predictive submodule is introduced to enhance long-term trend modeling capability, thereby constructing the complete CVRWN architecture. Subsequently, the constructed network is trained on turbine monitoring data under normal operating conditions, resulting in a stable CVRWN model obtained by jointly optimizing reconstruction and prediction losses. Finally, the reconstruction loss of wind power in the last window of the CVRWN model is defined as the ice accretion indicator r , which enables accurate quantification of the icing levels. Validation with actual operational data demonstrates that the CVRWN model improves wind power reconstruction accuracy by approximately 10% compared to the basic CVAE model, verifying the rationality and effectiveness of the proposed structural enhancements. During the ice accretion process, the proposed model's ice accretion indicator r can accurately and dynamically represent the evolution of blade icing compared to baseline models, providing a quantitative reference for the safe operation and maintenance of wind turbines in extreme environments.

Keywords: wind turbine; blade icing; variational network; normal behavior modeling; quantification method; reconstruction loss

随着全球能源结构向清洁化转型,风力发电作为重要的可再生能源形式在我国得到广泛应用。截至 2024 年底,我国风电累计装机容量达 5.3 亿 kW,占全球装机容量的 70%。然而,风机长期运行在复杂环境中,受高负荷运行、设备老化以及维护不及时等因素的影响,故障风险显著增加^[1]。其中,叶片结冰是北方及高海拔地区风电场面临的突出问题,如图 1 所示。叶片结冰会削弱风机的气动性能,降低发电效率,严重时甚至引发叶片断裂等恶性事故^[2-3]。针对不同程度的结冰情况,需要采取相应的处理措施和运行策略^[4]。例如,轻微结冰可通过调整运行参数应对,中度结冰需启动加热系统,而严重结冰则要求立即停机维护。因此,准确评估叶片结冰程度对于保障风机安全运行和提升发电效率至关重要。



(a)寒冷地区风机工作场景 (b)风机叶片结冰

图 1 风机叶片结冰场景示例图

Fig. 1 Example of wind turbine blade icing scenario

风机监控与数据采集(supervisory control and data acquisition, SCADA)系统的时序监测数据为风机状态监测提供了重要支撑^[5-7]。近年来,深度学习网络凭借强大的数据处理能力,在风电领域得到

了广泛应用^[8-9]。其中,递归神经网络(recurrent neural network, RNN)及其变体长短期记忆网络(long short-term memory network, LSTM)和门控循环单元(gated recurrent unit, GRU)擅长捕捉时序数据的动态特征^[10-11];卷积神经网络(convolutional neural network, CNN)能够有效提取数据的局部特征;自注意力机制通过挖掘序列中各位置之间的依赖关系,进一步提升模型的时序特征建模能力。这些网络在风机的故障诊断和状态监测中展现出显著优势^[12]。文献[13]利用 GRU 网络预测风机主轴承温度,并通过残差判断异常,实现早期故障预警。文献[14]构建了多种结合 CNN 网络与 RNN 网络的叶片结冰故障预测基础模型,并通过深度集成提升了预测性能。文献[15]进一步将时间注意力机制与 CNN 网络结合,增强了模型对时序依赖关系的捕捉能力,从而有效提升了结冰故障的识别精度。然而,上述文献主要依赖确定性模型,缺乏对数据潜在模式的深层理解,在应对噪声和分布变化较大的风机监测数据时有一定局限性。

变分自编码器(variational autoencoder, VAE)^[16]是一种基于概率建模的模型,广泛应用于复杂系统状态分析^[17-20]。其核心思想是利用编码器将输入数据映射至潜在空间,并通过最大化数据似然函数与最小化近似后验分布与先验分布的 KL (Kullback-Leibler, KL)散度,以学习数据的潜在结构与分布特性,再由解码器从潜在空间重构原始数据。在风机监测领域,VAE 模型能够在监测数据重构过程中挖掘风机状态的潜在模式,为状态评估与

异常检测提供可靠支持^[21-22]。文献[23]利用 VAE 模型学习 SCADA 数据在正常状态下的分布特征,通过重构误差检测异常数据,实现风机齿轮箱的早期故障预警。文献[24]将 VAE 网络与图注意力网络相结合,先利用图注意力网络提取数据间的空间依赖特征,再通过 VAE 网络学习特征的潜在分布,最终通过重构误差识别风机叶片的结冰状态。然而,上述文献仍缺乏针对叶片结冰状态的精确量化方法,且 VAE 网络在多维时序数据的特征提取和故障敏感性方面存在不足,难以满足叶片结冰程度量化的需求。

为解决上述问题,本文构建了一种条件变分递归窗口网络 (conditional variational recurrent window network, CVRWN),通过对风机正常运行状态进行建模,实现对叶片结冰引起监测数据异常的敏感识别,进而构建结冰程度的量化方法。该方法先将风机监测数据划分为多个时间窗口,然后在每个窗口内充分挖掘该窗口数据的潜在分布特征,最终实现风功率数据的高精度重构。通过跨窗口 GRU 模块实现特征的传递与信息融合,同时引入最后一个窗口风功率数据的预测任务,以增强模型的全局理解能力。最后一个窗口的重构任务综合考虑了当前时段的监测数据特征与历史信息,其重构效果能够全面表征风机运行状态的偏移程度。本文将最后一个窗口的风功率重构损失定义为叶片结冰指数 r ,通过融合风功率重构的表象误差与潜在分布差异,实现叶片结冰程度的精准量化。通过动态监测结冰指数 r ,运维人员可以实时跟踪叶片结冰状态的演化趋势,为制定差异化除冰策略和实施预防性维护提供有力的理论支撑。

1 理论基础

1.1 变分自编码器

VAE 网络由编码器和解码器组成,其结构如图 2(a)所示。给定数据集 $X = \{x_1, x_2, \dots, x_i, \dots, x_S\}$, $x_i (i = 1, 2, \dots, S)$ 为第 i 个样本, X 服从分布 $p(x_i)$ 。编码器会将输入样本 x_i 映射至潜在空间,并输出潜在空间的分布参数:均值 $\mu(x_i)$ 与对数方差 $\ln \sigma^2(x_i)$,接着利用重参数化技巧,从正态分布中采样得到潜在变量

$$z = \mu(x_i) + \epsilon \sigma(x_i), \epsilon \sim N(0, 1) \quad (1)$$

式中: z 为潜在变量; ϵ 为服从标准正态分布中采样的噪声。

解码器根据潜在变量 z 生成重构输出 $\hat{x}_i$,实现

数据在潜在空间的概率建模。所有样本重构结果汇总形成样本整体重构数据集 $\hat{X} = \{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_i, \dots, \hat{x}_S\}$ 。VAE 模型的目标是最大化数据的对数似然 $\ln p(x_i)$ 。由于直接优化该目标较为困难,采用变分推断方法,引入近似后验分布 $q(z|x_i)$,并通过构建变分下界 (evidence lower bound, ELBO) 优化。VAE 网络的损失函数定义为

$$L_r(X; \theta, \varphi) = \frac{1}{S} \sum_{i=1}^S [E_{q(z|x_i)} [\ln p(x_i | z)] - D_{KL}(q(z | x_i) \| p(z))] \quad (2)$$

式中: θ 和 φ 分别为编码器和解码器的网络参数; $E_{q(z|x_i)} [\ln p(x_i | z)]$ 为样本重构误差,确保解码器生成的样本尽可能接近真实数据; $D_{KL}(q(z | x_i) \| p(z))$ 为样本近似后验分布 $q(z|x_i)$ 与先验分布 $p(z)$ 的 KL 散度,用于确保潜在变量的合理分布,其值越小,表示这两个分布越相似。通常, $p(z)$ 被设定为标准高斯分布。

条件变分自编码器 (conditional variational autoencoder, CVAE) 网络^[25]在基础 VAE 网络中引入条件变量 C ,如图 2(b)所示。通过在给定条件信息下学习数据的潜在表示, CVAE 模型能生成与条件信息高度相关的样本,从而提升生成结果的针对性和准确性,则损失函数可表示为

$$L_r(X, C; \theta, \varphi) = \frac{1}{S} \sum_{i=1}^S [E_{q(z|x_i, c_i)} [\ln p(x_i | z, c_i)] - D_{KL}(q(z | x_i, c_i) \| p(z | c_i))] \quad (3)$$




图 2 VAE 与 CVAE 网络结构

Fig. 2 VAE and CVAE network structures

1.2 变分递归神经网络

变分递归神经网络 (variational recurrent neural network, VRNN)^[26]是一种将 RNN 网络与 VAE 网络相结合的深度学习模型,广泛用于时序数据分析。假设时间序列样本为 $\mathbf{x} = \{x_1, x_2, \dots, x_t, \dots, x_L\}$, 其中 x_t 表示第 t 时刻的观测数据, $t = 1, 2, \dots, L$ 。VRNN 模型在每个时刻 t 引入潜在变量 z_t 来捕捉数据的隐含特征,其 RNN 网络的隐藏状态 h_t

更新依赖于前一时刻的隐藏状态 h_{t-1} 、当前观测数据 x_t 和潜在变量 z_t ，如图 3(a) 所示；先验分布 $p(z_t | h_{t-1})$ 由 h_{t-1} 决定，如图 3(b) 所示；近似后验分布 $q(z_t | x_t, h_{t-1})$ 则通过当前观测数据 x_t 和和历史状态 h_{t-1} 进行推断，如图 3(c) 所示；最终，观测数据的重构生成基于解码器的条件分布 $p(x_t | z_t, h_{t-1})$ 完成，如图 3(d) 所示。

对于每一个时刻，VRNN 网络的损失函数为

$$L_r(x_t; \theta_t, \varphi_t) = E_{q(z_t | x_t, h_{t-1})} [\ln p(x_t | z_t, h_{t-1})] - D_{\text{KL}}(q(z_t | x_t, h_{t-1}) \parallel p(z_t | h_{t-1})) \quad (4)$$

式中： $E_{q(z_t | x_t, h_{t-1})} [\ln p(x_t | z_t, h_{t-1})]$ 为时刻 t 的重构误差； $D_{\text{KL}}(q(z_t | x_t, h_{t-1}) \parallel p(z_t | h_{t-1}))$ 为时刻 t 的近似后验分布 $q(z_t | x_t, h_{t-1})$ 与先验分布 $p(z_t | h_{t-1})$ 的 KL 散度。VRNN 网络的总损失为所有时刻的损失和，表达式如下

$$L_r(x; \theta, \varphi) = \sum_{t=1}^L L(x_t; \theta_t, \varphi_t) \quad (5)$$




图 3 VRNN 变量关系图

Fig. 3 VRNN's variable relationship graph

2 数据组成与网络结构

2.1 风机监测数据窗口化处理方法

风功率数据是衡量风机运行状态的重要指标，并与风速、环境温度、机舱内部温度等监测变量存在显著关联。在正常运行状态下，风功率数据呈现稳定的时序变化模式，与相关监测数据保持特定的约束关系。因此，本文将风机正常运行阶段的风功率数据作为重构目标，将相关监测数据作为条件信息，训练 CVRWN 网络，以捕捉数据的潜在分布，从而建立风机的正常运行模式。当叶片发生结冰时，风功率数据的时序模式及其与其他监测数据的相关性发生偏移，会导致重构网络产生明显的重构误差。随着结冰程度的加剧，这种偏移愈发明显，重构难度随之增加。

针对传统 VRNN 网络在逐时刻计算隐藏状态时，难以捕捉长期趋势且随序列增长性能下降的问题，本文提出一种窗口化处理方法。具体而言，将长度为 L 的时序数据划分为 M 个窗口，每个窗口时长为 T (即 $M = L/T$)。各窗口独立学习局部特征，并通过跨窗口信息传递实现全局状态融合，从而有效缩短梯度传播路径，提升模型的稳定性。在检测阶段，输入数据包括当前时刻及前 $L-1$ 个时刻的风功率数据 X ，以及对应时间区间的 N 维监测数据 (条件变量) C ，其数据结构可表示为

$$X = [x_1, x_2, \dots, x_m, \dots, x_M] \quad (6)$$

$$C = [c_1, c_2, \dots, c_m, \dots, c_M] \quad (7)$$

$$x_m = [x_m^1, x_m^2, \dots, x_m^t, \dots, x_m^T] \quad (8)$$

$$c_m = [c_m^1, c_m^2, \dots, c_m^t, \dots, c_m^T] \quad (9)$$

式中： x_m 与 c_m 分别为第 m 窗口的风功率与条件变量输入值； x_m^t 与 c_m^t 分别为第 m 窗口第 t 时刻的风功率值与条件变量值， $m = 1, 2, \dots, M, t = 1, 2, \dots, T$ 。

2.2 CVRWN 网络结构

CVRWN 网络由多个重构窗口叠加构成，各窗口间通过 GRU 模块实现时序特征传递与动态融合。每个 GRU 模块的输出特征均参与最后一个窗口的风功率预测任务，FC 表示全连接层，CVRWN 网络整体架构如图 4 所示。下文将详细阐述网络各模块的设计原理。




图 4 CVRWN 网络结构

Fig. 4 CVRWN network architecture

2.2.1 编码器与解码器

CVRWN 网络的每个重构窗口 m 由编码器、解码器与 GRU 模块组成,各窗口的输入数据依据 2.1 节的窗口化方法生成。为增强风功率数据与条件变量的特征表达能力,在输入网络之前,首先对其进行一维卷积编码,将原始数据投影至更高维度 d_m ,从而得到风功率嵌入 x_m 和条件变量嵌入 c_m 。该操作有助于提取数据的高阶特征,并便于后续不同特征的融合与拼接。

在重构窗口 m 中,编码器输入由 3 部分组成:风功率嵌入 x_m 、条件变量嵌入 c_m 与前序重构窗口的 GRU 模块隐藏层输出 h_{m-1} ($h_0 \sim N(0,1)$)。这些特征在时序维度进行拼接,形成完整的输入表示

$$x_{\text{enc}} = \text{cat}(x_m, c_m, h_{m-1}) \quad (10)$$

式中: $\text{cat}(\cdot)$ 表示向量的拼接操作。

在编码器部分,为了充分挖掘监测数据的时序依赖关系和潜在模式,CVRWN 网络采用自注意力机制和全连接层进行特征提取,如图 5 所示。自注意力机制能够有效捕捉监测中不同时刻之间的关联,增强模型对时序数据的深层理解和分析能力。具体而言,对于给定的输入数据 x_{enc} ,首先通过线性变换得到查询向量(Q)、键向量(K)和值向量(V)。其中, Q 用于衡量当前时刻与其他时刻的相关性, K 提供了各时刻的重要特征信息,而 V 则保留了各时刻的特征内容。随后,对 Q 和 K 的点积结果应用 softmax 归一化函数,将其映射为概率分布,从而生成注意力权重矩阵,以量化不同时刻之间的相关性强度。归一化后的注意力权重与 V 进行加权求和,最终得到能够表征序列内部依赖关系的上下文向量,使模型能够更关注对当前状态影响最显著的历史信息^[12],具体计算公式如下

$$\text{attention}(x_{\text{enc}}) = \left[\text{softmax}\left(\frac{QK^T}{\sqrt{d_m}}\right) \right] V \quad (11)$$




图 5 编码器网络结构

Fig. 5 Encoder network structure

为了满足后续全连接层的输入需求,生成的上下文向量经过展平操作转化为一维向量。随后,该向量依次通过两个全连接层,以进一步提取特征并

转换表示,最终输出该窗口对应的潜在分布参数,即均值 μ_m 与对方方差 $\ln\sigma_m^2$ 。基于这些参数,通过重参数化技巧进行采样,得到潜在变量 z_m 。

在解码阶段,将潜在变量 z_m 、条件变量嵌入 c_m 以及前序重构窗口的 GRU 模块的隐藏层输出 h_{m-1} 共同输入解码器,通过两个全连接层生成该窗口的风功率数据重构值 $\hat{x}_m = [\hat{x}_m^1, \hat{x}_m^2, \dots, \hat{x}_m^t, \dots, \hat{x}_m^T]$,其中, $\hat{x}_m^t$ 为第 m 窗口第 t 时刻的风功率重构值。这种简洁的解码器设计不仅有效降低了模型的复杂度和训练成本,还能促使网络充分利用潜在变量的信息,更精准地捕捉风机运行状态的潜在特征,从而缓解后验坍塌问题。

2.2.2 GRU 模块与预测模块

GRU 模块能够通过门控机制建模时间序列中的依赖关系,有效保留关键历史信息并抑制无关干扰。在 CVRWN 网络结构中,重构窗口按照时间顺序通过 GRU 模块连接,每个 GRU 模块由 T 个子模块组成,以确保模型能够持续提取和利用历史信息,从而实现对时序数据的选择性记忆与遗忘。重构窗口 m 对应的 GRU 模块的输入 y_m 由潜在变量 z_m 、风功率嵌入 x_m 与条件变量嵌入 c_m 在时间维度拼接得到

$$y_m = \text{cat}(z_m, x_m, c_m) = [y_m^1, y_m^2, \dots, y_m^t, \dots, y_m^T] \quad (12)$$

式中: y_m^t 表示第 m 窗口第 t 时刻的输入, $m = 1, 2, \dots, M, t = 1, 2, \dots, T$ 。

图 6 展示了重构窗口 m 的 GRU 模块的结构与数据的流向。每个时刻 t 的子模块 GRU_t 会接受 $t-1$ 时刻的隐藏状态 h_{m-1}^t 与对应时刻的输入 y_m^t ,从而计算得到当前时刻的隐藏状态 h_m^t 。结合所有时刻的隐藏状态得到该重构窗口的输出,可以表示为 $h_m = [h_m^1, \dots, h_m^t, \dots, h_m^T]$,其中, h_m^t 为第 m 窗口第 t 时刻的隐藏状态输出值。此外,重构窗口 m 的最后一个 GRU 子模块 GRU_T 的隐藏状态 h_m^T 会作为下一个重构窗口的初始隐藏状态 h_{m+1}^0 ,即 $h_m^T = h_{m+1}^0$ ($h_1^0 \sim N(0,1)$)。由此,类比图 3 中 VRNN 网络的变量关




图 6 GRU 模块结构

Fig. 6 GRU module architecture

系,可以得到 CVRWN 网络各个重构窗口之间变量的关系,如图 7 所示。




图 7 重构窗口变量关系

Fig. 7 Reconstruction window variable relationship

综上所述,重构窗口的 GRU 模块的隐藏状态能够有效表征累积的历史特征,其联合表示有助于反映数据的动态演化规律。为进一步强化模型对跨窗口时序信息的利用,本文引入预测子任务:通过全连接网络,以前 $M-1$ 个重构窗口的 GRU 模块的隐藏状态为输入,输出最后一个重构窗口的风功率数据预测值 $\mathbf{x}_{\text{pred}} = [x_{\text{pred}}^1, \dots, x_{\text{pred}}^t, \dots, x_{\text{pred}}^T]$, 其中 x_{pred}^t 为第 M 窗口第 t 时刻的风功率预测值。该机制促进窗口间的特征交互,使模型更充分地整合长时间跨度的信息,从而增强其对复杂时序模式的适应性与泛化能力。此外,通过联合优化重构任务和预测任务,模型在学习正常数据分布的同时,能够更敏感地捕捉潜在的异常演化趋势,为风机叶片结冰的监测提供更稳健的时序建模框架。

3 损失函数与风机叶片结冰指数

3.1 损失函数

CVRWN 网络的损失函数由重构窗口损失和预测损失两部分组成,旨在通过重构任务和预测任务的协同优化,提升模型对监测数据内在规律的深度理解和建模能力。对于任意重构窗口 m , 其重构损失 $L_{r,m}$ 表示为风功率数据的均方误差 (mean squared error, MSE) 与潜在变量的 KL 散度之和,分别衡量重构精度和潜在空间的合理性

$$L_{r,m} = L_{\text{MSE},m} + L_{\text{KL},m} \quad (13)$$

$$L_{\text{MSE},m} = \frac{1}{T} \sum_{t=1}^T \|x_m^t - \hat{x}_m^t\|^2 \quad (14)$$

$$L_{\text{KL},m} = -D_{\text{KL}}(q(\mathbf{z}_m | \mathbf{x}_m, \mathbf{c}_m, \mathbf{h}_{m-1}) \| p(\mathbf{z}_m | \mathbf{h}_{m-1})) \quad (15)$$

式中: $L_{\text{MSE},m}$ 为第 m 窗口的风功率重构均方误差,用于量化风功率重构值 $\hat{x}_m^t$ 与真实值 x_m^t 之间的偏差,从而直接评估模型的重构精度; $L_{\text{KL},m}$ 为第 m 窗口隐变量的近似后验分布 $q(\mathbf{z}_m | \mathbf{x}_m, \mathbf{c}_m, \mathbf{h}_{m-1})$ 与由历史

信息决定的先验分布 $p(\mathbf{z}_m | \mathbf{h}_{m-1})$ 之间的 KL 散度。这种设置使当前窗口的隐变量先验分布由前一个重构窗口 GRU 的隐藏状态决定,能够促使模型学习到具有时序连贯性的潜在状态表示。

预测损失 L_{pred} 为最后一个重构窗口风功率预测值 $\mathbf{x}_{\text{pred}}$ 与真实值 $\mathbf{x}_M$ 的均方误差,用于评估模型在前 $M-1$ 个重构窗口内对时序特征建模能力,验证其在捕捉跨窗口动态特征方面的有效性,表达式如下

$$L_{\text{pred}} = \frac{1}{T} \sum_{t=1}^T \|x_M^t - x_{\text{pred}}^t\|^2 \quad (16)$$

最终,CVRWN 网络的总损失函数由所有重构窗口的重构损失和预测损失之和表示,综合衡量模型的重构精度与时序建模能力,具体表达式如下

$$L_{\text{total}} = \sum_{m=1}^M L_{r,m} + L_{\text{pred}} \quad (17)$$

3.2 风机叶片结冰指数

风机叶片结冰是一个具有时间累积效应的动态过程,其对机组性能的负面影响呈现渐进式恶化特征,具体表现为监测数据的时序演变趋势与正常运行模式的系统性偏离。CVRWN 网络在最后一个重构窗口 M 中,通过融合最新监测数据和 GRU 模块传递的历史时序特征,同时受到预测模块的间接影响,使风功率重构过程兼顾当前状态的表观特征与历史演变趋势。因此,其风功率重构效果能够有效反应叶片结冰程度。基于此,本文将最后一个窗口的风功率重构损失定义为风机叶片结冰指数 r ,用于对结冰程度进行定量评估。其中,重构损失中的均方误差直接衡量风功率数据在观测空间的表象偏差,而 KL 散度刻画了重构数据的潜在分布与正常模式之间的差异。二者协同作用,综合评估重构窗口 M 的风功率重构效果,从而实现对叶片结冰程度的精准量化。风机叶片结冰指数 r 的计算公式如下

$$r = L_{r,M} = L_{\text{MSE},M} + L_{\text{KL},M} \quad (18)$$

在风机正常运行时,CVRWN 网络在重构窗口中持续学习并整合监测数据特征,最终在最后一个重构窗口实现高精度的风功率重构,使结冰指数 r 维持在较低水平。当叶片发生结冰时,风机运行特性发生变化,导致监测数据的潜在分布逐步偏离正常基准模式,且偏移程度与结冰严重程度呈显著正相关。在此过程中,CVRWN 网络凭借对整个输入时段特征的深度建模与对最后一个重构窗口的重点分析,使结冰指数 r 能够精准量化当前的结冰程度。

因此,基于 CVRWN 网络的监测数据挖掘与结冰指数 r 的计算,可实现风机状态的动态监测与结冰程度的精准识别,为运维团队提供可靠的决策依据,从而减少停机时间与维护成本,保障风机的安全运行与高效发电。

4 实例验证

4.1 数据描述

本文选用中国 2017 工业大数据竞赛提供的风机叶片结冰故障分析数据集,该数据集涵盖 2015 年 11 月 1 日至 2016 年 1 月 1 日期间某台风机的 26 种监测时序数据,并附有时间戳。为针对叶片结冰状态进行监测,选取风功率及另外 7 种与结冰密切相关的监测变量作为条件变量,具体变量信息详见表 1。该数据集记录了风机的正常运行状态和叶片结冰故障的全过程,并明确标注了故障发生时间。原始数据采样间隔为 7 s,存在大量数据缺失。为保证数据的连续性和分析的可靠性,首先对数据进行重采样,将时间分辨率调整至 1 min。分钟级数据不仅能够保留关键趋势和模式,有助于深度学习模型的特征提取,同时在计算效率、实时性与系统负担之间实现良好平衡。重采样后,从正常运行阶段筛选出 29 328 个样本,并按 8 : 2 的比例划分为训练集和测试集。为提升模型的学习效果,对训练集中的各监测变量进行归一化处理,并使用相同的归一化参数对测试集进行标准化,确保数据在统一尺度下保持一致性。

表 1 风机监测变量

Table 1 Wind turbine monitoring variables

序号	监测变量	序号	监测变量
1	风速	5	发电机转速
2	风功率	6	叶片 1 桨叶角
3	环境温度	7	叶片 2 桨叶角
4	机舱内部温度	8	叶片 3 桨叶角

4.2 模型参数与评价指标

风机叶片结冰通常在几十分钟到数小时内发展。因此,本研究将输入样本总长度设定为 120 min ($L=120\text{ min}$),重构窗口长度设定为 5 min ($T=5\text{ min}$),对应的重构窗口数量为 24 ($M=L/T=24$),以精准捕捉叶片结冰的时序特征。其中,120 min 的输入时长覆盖结冰前后的状态演变,确保模型学习结冰趋势,同时避免窗口过短导致的早期征兆缺失或过长引起的特征稀释;而 5 min 的重构窗口可刻画短时风功率波动,降低随机扰动影响,并增强模型对突

变特征的感知能力,提高结冰状态的表征精度。

CVRWN 模型的关键超参数如下:重构窗口输入嵌入维度 $d_m=64$ 、潜在状态维度 $z_m=16$ 、编码器自注意力头数 $n_{\text{head}}=4$ 、注意力层数 $l_{\text{attn}}=4$ 、GRU 模块隐藏层维度 $h=d_m=64$ 、GRU 模块层数 $l_{\text{GRU}}=1$ 。在训练阶段,首先构建具有上述参数的 CVRWN 网络,并使用式(17)中的损失函数对其进行训练。训练过程采用 Adam 优化算法进行梯度更新,学习率设为 0.001,迭代次数为 300 次,以确保网络参数收敛。通过训练上述网络,选取在测试集上重构效果最优的模型作为固定权重的最终模型。对于概率模型,为减小随机误差,在测试时,对每个样本运行 30 次,选取风功率重构值的中位数作为最终的重构值。

假设每个样本输入的风功率真实值为 $\mathbf{X}=\{x_1,x_2,\cdots,x_L\}\in\mathbf{R}^L$,模型重构的结果为 $\hat{\mathbf{X}}=\{\hat{x}_1,\hat{x}_2,\cdots,\hat{x}_L\}\in\mathbf{R}^L$,选用均值绝对误差(mean absolute error, E_{MAE})、均方根误差(root mean squared error, E_{RMSE})和决定系数(coefficient of determination, R^2)作为重构效果的评价指标。其中, E_{MAE} 是所有重构误差绝对值的均值; E_{RMSE} 是均方误差的平方根,对大误差更加敏感; R^2 值在 0 到 1 之间,值越接近 1 表示模型对数据拟合越好。以上 3 个指标的计算公式如下

$$E_{\text{MAE}}=\frac{1}{L}\sum_{i=1}^L(x_i-\hat{x}_i)^2\tag{19}$$

$$E_{\text{RMSE}}=\sqrt{\frac{1}{L}\sum_{i=1}^L(x_i-\hat{x}_i)^2}\tag{20}$$

$$R^2=1-\frac{\sum_{i=1}^L(x_i-\hat{x}_i)^2}{\sum_{i=1}^L(x_i-\bar{x})^2}\tag{21}$$

4.3 关键模块对 CVRWN 模型性能的影响

风机正常状态下的风功率重构性能体现了模型对正常运行模式的学习与表征能力,是基于重构损失量化叶片结冰程度的基础。为验证 CVRWN 网络中预测模块和自注意力机制这两个关键模块对重构效果的贡献,本文在相同的风机正常运行数据集上,分别训练和测试完整 CVRWN 模型(完整模型)、去除预测模块的 CVRWN(无预测模块)模型及去除自注意力机制的 CVRWN 模型(无自注意力)。为评估各模型在测试集上的风功率重构性能,计算了各个模型的 E_{MAE} 、 E_{RMSE} 和 R^2 指标,结果如表 2 所示。此外,为深入分析重构特性,选取代表性样本并可视化输入与重构的风功率数据,如图 8 所示。图中每连续 5 min 的风功率构成一个重构窗

口。特别地,考虑到风机结冰指数 r 是基于最后一个重构窗口建立的,图 8 放大了该窗口,以清晰展示各模型在关键时段的表现。

表 2 不同模型测试集上的风功率重构结果评价指标
Table 2 Evaluation metrics for wind power reconstruction results of different models on the test set

模型	E_{MAE}	E_{RMSE}	R^2
无预测模块	0.016 1	0.020 6	0.797 7
无自注意力	0.015 9	0.020 4	0.803 6
完整模型	0.014 2	0.018 5	0.836 1

注:黑体数据为最优值。




图 8 不同模型风功率重构结果示例

Fig.8 Examples of wind power reconstruction results from different models

从表 2 可见,完整模型在各项重构指标上的表现最佳,其 E_{MAE} 和 E_{RMSE} 分别为 0.014 2 和 0.018 5,且 R^2 达到 0.836 1,最接近理论最优值 1。这表明,完整模型能够充分捕捉监测数据的潜在特征,实现高精度的风功率重构。进一步分析图 8 的风功率重构曲线可发现,完整模型在最初两个重构窗口后,重构值已与真实值高度吻合,尤其在最后一个窗口展现出卓越的拟合效果。这表明,在风机正常运行状态下,训练后的模型可借助自注意力机制深度挖掘数据特征,并在窗口间高效传递信息。同时,预测模块有助于整合跨窗口信息,增强模型对整体趋势变化的理解。最终,完整模型在最后一个重构窗口综合当前与历史信息,实现高精度的风功率重构。

相比之下,移除预测模块或自注意力机制后,模型的风功率重构性能显著下降,各项指标均有所恶化,重构曲线与真实值的偏差增大。其中,去除预测

模块的模型在风功率剧烈变化时易出现较大偏离,且最后一个重构窗口与真实值的差距尤为明显,验证了预测模块在整合长期时序信息中的重要作用,其缺失会削弱模型对数据变化趋势的捕捉能力,进而降低重构精度。另一方面,去除自注意力机制后,模型仅在第 4 个窗口后才能较好地贴合真实数据,相较完整模型存在明显的响应延迟,同时在倒数第 3 个窗口仍出现较大偏差。这表明,自注意力机制对于复杂数据模式的理解至关重要,其缺失会削弱模型的特征提取能力,影响数据重构的准确性与鲁棒性。

基于式(18)计算各模型测试集的叶片结冰指数 r ,其分布特征如图 9 箱线图所示。箱线图下边缘、上边缘及中心线分别对应数据的下四分位数、上四分位数和中位数,上下四分位数的差值定义为四分位距,用于表征数据中间 50% 的离散程度。完整模型的叶片结冰指数 r 的中位数显著低于对比模型,表明其在最后一个重构窗口中能够更高精度地重构风功率数据。此外,完整模型的四分位距最小,表明其 r 值在正常工况下波动范围较窄、分布更集中,能够稳定识别正常运行状态,并有效降低噪声对模型判断的影响,提升风机状态监测的鲁棒性。相比之下,缺失预测模块或自注意力机制的模型,其 r 的中位数和四分位距均显著增大,说明这些模型在正常风功率数据的重构准确性和稳定性方面存在不足,更容易受到数据波动的干扰,导致误判风险增加。对比结果充分验证了自注意力机制与预测模块的协同作用在精准提取正常数据特征方面的关键作用,不仅提升了模型对正常状态的稳定识别能力,还为风机叶片结冰程度的量化提供了可靠的支撑。




图 9 不同模型在测试集上的 r 分布箱线图

Fig.9 Boxplot of r value distribution for different models on the test set

4.4 风机叶片结冰程度量化

本节基于训练好的 CVRWN 模型,在风机叶片结冰过程中进行测试,以验证其在结冰程度量化方

面的有效性。此外,选取经典的状态监测变分网络基线模型 CVAE 和 VRNN,在相同的正常运行数据集上进行训练和测试,并在测试集上计算结冰指数 r ,以对比分析不同模型在结冰程度量化中的性能。

为了使结冰指数 r 更直观地描述结冰程度,采用上限控制(upper control limit, UCL)方法,基于正常测试集 r 的均值 r_μ 和标准差 r_σ 定义风机叶片未结冰、轻微结冰、中度结冰与严重结冰的参考区间。区间划分方法如表 3 所示,其中各区间的上、下限按照公式 $r_k = r_\mu + kr_\sigma (k = 1, 2, 3)$ 计算。各模型在测试集上的 r 统计结果与各区间的上、下限记录于表 4。

表 3 风机叶片结冰程度参考区间

Table 3 Reference intervals of wind turbine blade icing degrees			
未结冰	轻微结冰	中度结冰	严重结冰
$(\quad, r_1)$	$[r_1, r_2)$	$[r_2, r_3)$	$[r_3, \quad)$

表 4 不同模型测试集上的 r 值相关数据

Table 4 Data related to r value for different models on the test set					
模型	r_μ	r_σ	r_1	r_2	r_3
CVAE	0.001 9	0.001 3	0.003 2	0.004 6	0.005 9
VRNN	0.000 9	0.000 6	0.001 4	0.002 0	0.002 6
CVRWN	0.001 3	0.001 2	0.002 5	0.003 7	0.004 8

以 2015 年 12 月 7 日 16 : 22 的叶片结冰事件为例,分析故障前 60 min 至故障持续 110 min 内的风机状态。为直观展示不同运行状态下的功率特性,绘制归一化的风速-风功率散点图如图 10 所示。图中,正常运行测试集数据(蓝色)符合理论功率曲线,而结冰阶段数据(浅红至深红色时序渐变映射)呈现明显偏离趋势,反映出结冰程度不断加深的动态演变过程。






图 10 归一化风速-风功率散点图

Fig. 10 Scatterplot of normalized wind speed-wind power


为评估各模型对结冰程度的量化能力,绘制了示例时间段内各模型的结冰指数 r 变化曲线,并标记了结冰起始时间及各模型不同结冰程度的参考区间,如图 11 所示。实验结果表明:CVAE 模型的 r 波动较大,正常运行阶段频繁突破 r_1 ,误报风险较高。结冰发生后 r 虽呈上升趋势,但波动剧烈,难以准确区分结冰程度,这表明 CVAE 模型在趋势信息提取方面存在不足,对短时扰动过于敏感,影响结冰程度判定的可靠性;VRNN 模型在正常运行阶段的 r 值波动有所改善,但轻度结冰时长时间低于 r_1 ,未能有效指示结冰的发生;进入中重度结冰后, r 值大幅波动,频繁跨越不同区间,影响稳定判定,这是由于 VRNN 模型简单的时间依赖和有限的特征提取能力,难以有效捕捉多维监测时序数据的复杂变化和变量间的深层关联,导致其在刻画叶片结冰状态时精度有限。



(a)CVAE 模型



(b)VRNN 模型




(c)CVRWN 模型

图 11 风机叶片结冰过程中不同模型的 r 变化


Fig. 11 Variation of r value of different models during the wind turbine blade icing

本文提出的 CVRWN 模型在风机正常运行时 r 值稳定保持在 r_1 以下。当结冰开始时, r 值逐渐上升并迅速超越 r_1 。在轻微结冰累积后, r 值达到中度结冰的区间 $[r_2, r_3)$, 并在一段时间后急速上升超过 r_3 , 表明进入严重结冰状态。整个过程中, r 值在各个阶段保持相对稳定, 能够清晰准确地指示当前风机的结冰程度。这有助于工作人员在明确状态的情况下做出相应的处理决策, 符合预期目标。


图 12 展示了 CVRWN 模型在不同结冰阶段的风功率重构效果。在风机正常运行时, 重构值从首窗口到末窗口逐步逼近真实数据, 展现出理想的重构效果, 表明该模型能精准学习正常工况下风功率的时序模式及其与监测数据的内在关联。在轻微结冰阶段, 最后一个窗口的重构误差略增, 反映模型可捕捉数据模式的轻微偏离。随着结冰加剧, 最后几个重构窗口的风功率重构误差逐步上升, 表明模型能够有效感知异常模式, 并及时在对应窗口的重构精度变化中体现结冰影响。重度结冰时, 模型的重构值从较早的窗口开始明显偏离真实数据, 且在最后一个窗口的偏离程度达到最大, 反映叶片结冰已持续并发展至严重程度。上述结果表明, CVRWN 模型通过连续重构窗口的渐进式学习, 能够充分捕获风功率数据的时序趋势及其与其他监测参数的非线性关系。最后一个窗口不仅关注当前数据特征, 还综合考虑历史信息, 其风功率重构效果能有效反应风机叶片结冰状态。基于该窗口风功率重构损失构建的叶片结冰指数 r , 能够将复杂的结冰状态转换为可量化指标, 实现对风机叶片结冰程度的实时精准量化。




(a) 正常运行



(b) 轻微结冰



(c) 中度结冰



(d) 严重结冰

图 12 不同叶片结冰程度下 CVRWN 风功率重构结果示例
Fig. 12 Example of CVRWN wind power reconstruction results under different blade icing degrees

5 结 论

本文针对风力发电机组叶片结冰故障提出一种风功率时序数据重构深度学习模型 CVRWN, 并基于重构结果构建风机叶片结冰指数 r , 以精准量化叶片结冰程度, 主要结论如下。

(1) 提出基于窗口划分的时序数据处理框架, 通过约束模型在独立窗口内挖掘局部特征, 显著提升局部特征提取能力。同时, 利用 GRU 模块构建跨窗口信息传递机制, 实现历史数据的动态融合与趋势继承, 使模型兼顾长期依赖关系, 有效表征风机运行状态及潜在异常。

(2) 单个重构窗口内, 融合自注意力机制的变分推断网络提升了模型对监测数据复杂依赖关系的建模能力, 加强对数据潜在分布的学习。跨窗口风功率预测子任务整合历史信息, 进一步增强模型对风功率动态演化规律的全局理解。

(3) CVRWN 网络最后一个重构窗口融合了当前监测数据特征与历史信息, 可以全面表征风机的运行状态。以该窗口风功率重构损失定义的叶片结冰指数 r 。通过综合考虑风功率重构误差与潜在分布偏差, 能够精准反映叶片结冰程度。

(4) 正常工况下的风功率重构测试表明, 自注意力机制与预测模块显著提升了模型的重构精度与稳

定性。在结冰监测任务中,基于 CVRWN 模型的结冰指数 r 相较基线模型,可准确区分未结冰、轻微结冰、中度结冰与严重结冰 4 类状态,并实现结冰程度的精准动态评估,为风力发电机组的安全运维提供理论依据与技术支持。

参考文献:

[1] 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 Huan, YANG Ting, XU Shaohui, et al. Review of data-driven condition monitoring and fault diagnosis technologies for wind turbines [J]. Automation of Electric Power Systems, 2023, 47(23): 55-69.

[2] 胡琴,王欢,舒立春,等. 覆冰条件下风力发电机叶片防/除冰方法综述 [J]. 电工技术学报, 2024, 39(17): 5482-5496.
HU Qin, WANG Huan, SHU Lichun, et al. Review of anti-/de-icing methods for wind turbine blades under icing conditions [J]. Transactions of China Electrotechnical Society, 2024, 39(17): 5482-5496.

[3] YANG Li, LI Gaoyang, ZHANG Zihan, et al. Operations & maintenance optimization of wind turbines integrating wind and aging information [J]. IEEE Transactions on Sustainable Energy, 2021, 12(1): 211-221.

[4] BADIHI H, ZHANG Youmin, JIANG Bin, et al. A comprehensive review on signal-based and model-based condition monitoring of wind turbines: fault diagnosis and lifetime prognosis [J]. Proceedings of the IEEE, 2022, 110(6): 754-806.

[5] CHENG Xu, SHI Fan, LIU Xiufeng, et al. A novel deep class-imbalanced semisupervised model for wind turbine blade icing detection [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(6): 2558-2570.

[6] 李特,王荣喜,高建民. 风电机组数据采集与监控系统异常数据识别方法 [J]. 西安交通大学学报, 2024, 58(3): 106-116.
LI Te, WANG Rongxi, GAO Jianmin. A method for abnormal data recognition of wind turbine supervisory control and data acquisition systems [J]. Journal of Xi'an Jiaotong University, 2024, 58(3): 106-116.

[7] 曾祥军,冯琛,杨明,等. 考虑运行状态相似性的风电机组数据异常检测方法 [J]. 电力系统自动化, 2022, 46(11): 170-180.
ZENG Xiangjun, FENG Chen, YANG Ming, et al. Data anomaly detection method for wind turbines con-

sidering operation state similarity [J]. Automation of Electric Power Systems, 2022, 46(11): 170-180.

[8] 王爽心,郭婷婷,李蒙. 风电机组变工况变桨系统异常状态在线识别 [J]. 中国电机工程学报, 2019, 39(17): 5144-5152.
WANG Shuangxin, GUO Tingting, LI Meng. On-line abnormal state identification of pitch system based on transitional mode for wind turbine [J]. Proceedings of the CSEE, 2019, 39(17): 5144-5152.

[9] XIANG Ling, WANG Penghe, YANG Xin, et al. Fault detection of wind turbine based on SCADA data analysis using CNN and LSTM with attention mechanism [J]. Measurement, 2021, 175: 109094.

[10] ZHENG Zhong, ZHANG Zijun. A stochastic recurrent encoder decoder network for multistep probabilistic wind power predictions [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(7): 9565-9578.

[11] 兰孝升,李云凤,苏元浩,等. 基于关联度与自检验长短期记忆网络的风电机组轴承寿命预测模型 [J]. 高电压技术, 2023, 49(6): 2652-2661.
LAN Xiaosheng, LI Yunfeng, SU Yuanhao, et al. Wind turbine bearing life prediction model based on indexed relation and self-checking long short-term memory [J]. High Voltage Engineering, 2023, 49(6): 2652-2661.

[12] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 6000-6010.

[13] ENCALADA-DÁVILA Á, MOYÓN L, TUTIVÉN C, et al. Early fault detection in the main bearing of wind turbines based on gated recurrent unit (GRU) neural networks and SCADA data [J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(6): 5583-5593.

[14] XIAO Jin, LI Chunyan, LIU Bo, et al. Prediction of wind turbine blade icing fault based on selective deep ensemble model [J]. Knowledge-Based Systems, 2022, 242: 108290.

[15] CHENG Xu, SHI Fan, ZHAO Meng, et al. Temporal attention convolutional neural network for estimation of icing probability on wind turbine blades [J]. IEEE Transactions on Industrial Electronics, 2022, 69(6): 6371-6380.

[16] 翟正利,梁振明,周炜,等. 变分自编码器模型综述 [J]. 计算机工程与应用, 2019, 55(3): 1-9.

- ZHAI Zhengli, LIANG Zhenming, ZHOU Wei, et al. Research overview of variational auto-encoders models [J]. Computer Engineering and Applications, 2019, 55(3): 1-9.
- [17] QIN Yi, ZHOU Jianghong, CHEN Dingliang. Unsupervised health indicator construction by a novel degradation-trend-constrained variational autoencoder and its applications [J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(3): 1447-1456.
- [18] 张聪, 朱永生, 杨敏燕, 等. 采用多变量耦合网络与变分图自编码器的机械设备异常检测方法 [J]. 西安交通大学学报, 2021, 55(4): 20-28.
- ZHANG Cong, ZHU Yongsheng, YANG Minyan, et al. Anomaly detection method with multivariable coupling network and variational graph autoencoder [J]. Journal of Xi'an Jiaotong University, 2021, 55(4): 20-28.
- [19] 段雪源, 付钰, 王坤. 基于 VAE-WGAN 的多维时间序列异常检测方法 [J]. 通信学报, 2022, 43(3): 1-13.
- DUAN Xueyuan, FU Yu, WANG Kun. Multi-dimensional time series anomaly detection method based on VAE-WGAN [J]. Journal on Communications, 2022, 43(3): 1-13.
- [20] LIN Shuyu, CLARK R, BIRKE R, et al. Anomaly detection for time series using VAE-LSTM hybrid model [C]//ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway, NJ, USA: IEEE, 2020: 4322-4326.
- [21] 甘雨, 郭鹏, 林立栋. 基于变分贝叶斯推断的 DPGMM 风电机组异常数据识别研究 [J]. 动力工程学报, 2023, 43(7): 885-892.
- GAN Yu, GUO Peng, LIN Lidong. Abnormal wind turbine data identification using a Dirichlet process Gaussian mixture model based on variational Bayesian inference [J]. Journal of Chinese Society of Power Engineering, 2023, 43(7): 885-892.
- [22] 吴岚, 柳亦兵, 吴仕明, 等. 基于 VMD 倒频变换的风电机组齿轮箱复合故障诊断 [J]. 振动与冲击, 2023, 42(24): 221-227.
- WU Lan, LIU Yibing, WU Shiming, et al. Composite fault diagnosis of wind turbine gearboxes based on VMD cepstral transform [J]. Journal of Vibration and Shock, 2023, 42(24): 221-227.
- [23] 任建亭, 汤宝平, 雍彬, 等. 基于深度变分自编码网络融合 SCADA 数据的风电齿轮箱故障预警 [J]. 太阳能学报, 2021, 42(4): 403-408.
- REN Jianting, TANG Baoping, YONG Bin, et al. Wind turbine gearbox fault warning based on depth variational autoencoders network fusion SCADA data [J]. Acta Energiae Solaris Sinica, 2021, 42(4): 403-408.
- [24] WANG Lei, HE Yigang, SHAO Kaixuan, et al. An unsupervised approach to wind turbine blade icing detection based on beta variational graph attention autoencoder [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-12.
- [25] POL A A, BERGER V, GERMAIN C, et al. Anomaly detection with conditional variational autoencoders [C]//2019 18th IEEE International Conference on Machine Learning and Applications (ICMLA). Piscataway, NJ, USA: IEEE, 2019: 1651-1657.
- [26] CHUNG J, KASTNER K, DINH L, et al. A recurrent latent variable model for sequential data [C]//Proceedings of the 29th International Conference on Neural Information Processing Systems. Cambridge, MA, USA: MIT Press, 2015: 2980-2988.

(编辑 刘杨 陶晴)