

DOI: 10.19650/j.cnki.cjsi.J2614904

基于对比盲去噪自编码器的风机覆冰组合检测方法

袁 军¹, 蒙文川², 邓韦斯³, 李 彬¹, 王 进¹

(1. 长沙理工大学电气与信息工程学院 长沙 410014; 2. 南方电网能源发展研究院 广州 510663;
3. 中国南方电力调度控制中心 广州 510663)

摘 要: 风机覆冰检测中数据易受到噪声干扰, 现有去噪方法极易在进行噪声去除时造成信号过度平滑并丢失关键特征。针对现有方法在数据噪声处理方面的不足, 提出了一种基于对比盲去噪自编码器的风机覆冰组合检测方法。首先, 利用带有噪声对比估计机制(NCE)的自编码器作为自适应去噪模块。该模块基于重构损失机制与噪声对比估计机制实现噪声去除与特征保留的平衡, 在去除噪声干扰的同时, 最大程度保留了覆冰关键时序特征。该模块能够在缺乏噪声先验知识与纯净标签数据的条件下, 通过自监督学习对原始信号进行自适应盲去噪。在此去噪模块的基础上, 进一步设计了时序特征提取与特征增强并行的双分支组合检测网络, 时序分支由双向长短期记忆网络(BiLSTM)与收缩广播注意力模块(CBSA)构成, 增强分支则由自动化特征模块与柯尔莫哥洛夫-阿诺德网络(KAN)组成。该组合网络协同挖掘数据在时序维度的动态演化规律与特征维度的非线性耦合关系, 实现对覆冰状态的准确识别。基于实际风场数据的多维实验验证了所提方法的有效性。实验结果表明, 该方法能抑制干扰导致的覆冰错误识别, 提升了综合检测精度, 并在不同噪声强度下保持稳定, 展现出一定的抗噪鲁棒性与泛化能力, 为工程实际应用提供了可靠支撑。

关键词: 覆冰检测; SCADA 数据; 盲去噪; 噪声对比估计; 组合网络

中图分类号: TH17 TM315 **文献标识码:** A **国家标准学科分类代码:** 470.40

Combined detection method for wind turbine icing based on a contrastive blind denoising autoencoder

Yuan Jun¹, Meng Wenchuan², Deng Weisi³, Li Bin¹, Wang Jin¹

(1. School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410014, China; 2. Energy Development Research Institute, China Southern Power Grid, Guangzhou 510663, China;
3. China Southern Power Grid Dispatching and Control Center, Guangzhou 510663, China)

Abstract: Data used for wind turbine icing detection are highly susceptible to noise interference, and existing denoising methods often cause excessive signal smoothing and the loss of critical features. To address these shortcomings in d denoising, a novel hybrid method for wind turbine icing detection based on a contrastive blind denoising autoencoder is proposed. First, an autoencoder incorporating a noise contrastive estimation(NCE) mechanism is employed as an adaptive denoising module. By leveraging both reconstruction loss and the NCE mechanism, this module achieves a balance between noise removal and feature preservation; effectively preserving the key temporal features of icing while effectively filtering out noise interference. Notably, this module can perform adaptive blind denoising on raw signals through self-supervised learning, without requiring any prior knowledge of the noise or clean reference data. Building upon this denoising module, a dual-branch detection network is designed, with parallel branches for temporal feature extraction and feature enhancement. The temporal branch consists of a bidirectional long short-term memory (BiLSTM) network and a contract-and-broadcast self-attention (CBSA) module, whereas the enhancement branch comprises an OpenFE-based feature engineering module and a Kolmogorov-Arnold network (KAN). This network jointly captures the dynamic evolution patterns of the data in the temporal dimension and the nonlinear coupling relationships in the feature dimension, thereby enabling accurate identification of icing conditions. Multi-dimensional experiments based on actual wind farm data were conducted to verify the effectiveness of the proposed method. The

experimental results demonstrate that this approach effectively suppresses false icing detections caused by interference, improves comprehensive detection accuracy, and maintains stability across varying noise intensities. It demonstrates a certain level of anti-noise robustness and generalization capability, offering reliable support for practical engineering applications.

Keywords: icing detection; SCADA data; blind denoising; noise-contrastive estimation; combined network

0 引言

随着全球能源结构转型,风能作为一种可再生的清洁能源已在世界范围广泛开发和利用^[1]。高海拔地区、山区以及海上区域拥有丰富的风能资源,然而在低温高湿条件下,风机叶片表面极易覆冰,造成气动性能退化^[2],引发功率损失、结构振动加剧等问题,甚至可能引发结构损伤和冰层脱落等安全隐患^[3]。因此,对风机覆冰状态的准确检测识别,对于保障风电机组安全运行、提升发电效率以及降低运维成本具有重要意义。

传统的风机覆冰检测主要依赖直接检测法,即通过在风机上部署物理传感器直接获取叶片覆冰信息,如温湿度传感器^[4]、超声波^[5]和红外辐射^[6]等,虽然能直接检测风机覆冰情况,但传感器的安装会增加叶片负担,人力与材料成本受限,并且在覆冰环境下传感器设备极易冻结失效,无法可靠反馈覆冰情况^[7]。

针对传统方法的局限性,基于数据驱动的信号检测技术的间接方法被广泛研究,间接法主要依托风机广泛部署的风机数据采集与监视控制(supervisory control and data acquisition, SCADA)系统,通过建立 SCADA 系统中的运行数据与覆冰故障之间的高度非线性映射关系识别覆冰故障。间接法无需在叶片上安装额外传感器,并且丰富的历史运行数据为基于数据驱动的机器学习算法提供了数据基础和应用空间^[8]。

机器学习算法凭借强大的特征提取能力和非线性拟合优势,已广泛应用于风机覆冰检测领域。其中,以随机森林^[9]、极限梯度提升树^[10]、轻量级梯度提升机^[11]的集成决策树算法,该类算法无需繁琐的数据归一化预处理且能捕捉特征间的高阶交互关系;支持向量机^[12]与极限学习机^[13]等模型也得到应用。但浅层模型难以挖掘数据深层的非线性,缺乏对时间序列动态依赖关系的建模能力,并且对数据集中的异常值与噪声敏感,模型结构不稳定。相比之下,深度学习算法如卷积神经网络^[14]、循环神经网络^[15]及其变体门控循环单元^[16]和长短期记忆网络(long short term memory, LSTM)^[17],能够自动从原始信号中提取高阶表征,并有效捕捉长距离的时序演变规律。

尽管上述基于数据驱动的机器学习方法在风机覆冰检测方面取得了显著进展,证明了数据驱动模式的可行

性,但研究大多聚焦于后端检测模型的改进,而忽视了前端数据预处理阶段中时序维度的噪声去除问题。风电机组常年运行于低温、高湿等恶劣自然环境,其 SCADA 系统采集的高频监测数据不可避免地受到环境、测量以及传输等多重因素影响,导致原始时间序列中混杂着噪声。若将此类含噪数据直接作为输入数据,极易使模型学习到错误的特征映射关系,引发特征提取偏差,从而导致检测精度的下降以及误报率与漏报率的升高。以往研究大多依赖统计阈值或基于密度的聚类算法进行去除^[18],如基于密度的空间聚类算法(density based spatial clustering of applications with noise, DBSCAN)^[19],此类方法从静态的空间分布识别离群点,将连续的风机运行 SCADA 数据视为独立的离散样本,但忽略了数据的时序依赖性。传统的滤波方法如卡尔曼滤波^[20]等依赖于精确的系统模型与先验参数估计;而小波去噪^[21]、变分模态分解(variational mode decomposition, VMD)^[22]等信号处理方法虽利用统计特性去噪,却需预先确定最佳阈值。此外,实际场景中极难获取纯净无噪的基准数据,使得标准去噪自编码器(denoising autoencoder, DAE)等监督学习算法难以落地。

针对上述问题,本研究提出一种基于对比盲去噪自编码器的风机覆冰组合检测方法:

1) 基于噪声对比估计与自编码器的耦合架构,在无需纯净基准数据的前提下,对原始高噪 SCADA 数据进行自监督学习与清洗,有效剥离环境噪声并重构关键信号趋势,为后续算法提供高质量的纯净输入。

2) 提出多角度特征融合网络,将去噪后的数据输入时序-增强并行组合检测网络,分别从长短期时序演化与多变量特征耦合两个维度进行深度挖掘,通过多视角特征融合,实现对风机覆冰状态的精准表征与识别。

1 自适应去噪与覆冰检测网络架构

1.1 自适应去噪原理

本文在覆冰检测框架的前端引入对比盲去噪自编码器(contrast blind denoising autoencoder, CBDAE)作为核心预处理模块。该方法创新性地结合了噪声对比估计(noise contrastive estimation, NCE)机制,能够在无需噪声先验知识且缺乏基准数据的条件下,实现对 SCADA 信号的自适应去噪。

自编码器(autoencoder, AE)^[23]旨在通过反向传播

算法学习输入数据的高效低维表示,不需要标签,利用数据本身作为监督信号,通过最小化重构误差来驱动网络

参数的更新。设定 n 维 SCADA 时序数据 $\mathbf{y}(t)$, 如图 1 所示。




图1 CBDAE 模型架构

Fig. 1 Architecture of the CBDAE model

标准的自编码器架构包含编码器网络 f_{θ_E} 与解码器网络 g_{θ_D} , 其原理为: 编码器将高维输入向量 $\mathbf{y}(t)$ 映射至低维潜在空间, 生成潜在表示向量 $\mathbf{z}$, 公式为:

$$\mathbf{z} = f_{\theta_E}(\mathbf{y}(t)) = \sigma(\mathbf{W}_{\theta_E} \mathbf{y}(t) + \mathbf{b}_{\theta_E}) \quad (1)$$

式中: $\mathbf{W}_{\theta_E}$ 和 $\mathbf{b}_{\theta_E}$ 为编码器可训练的权重参数; σ 为激活函数。在生成潜在表示向量 $\mathbf{z}$ 后, 解码器尝试从表示向量 $\mathbf{z}$ 中恢复原始输入, 得到重构向量 $\hat{\mathbf{y}}(t)$, 公式为:

$$\hat{\mathbf{y}}(t) = g_{\theta_D}(\mathbf{z}) = \sigma(\mathbf{W}_{\theta_D} \mathbf{z} + \mathbf{b}_{\theta_D}) \quad (2)$$

式中: $\mathbf{W}_{\theta_D}$ 和 $\mathbf{b}_{\theta_D}$ 为解码器可训练的权重参数。自编码器训练目标是得到最小化输出与输入之间的重构误差时最优参数 θ^* , 公式为:

$$\theta^* = \operatorname{argmin}_{\theta} \|\hat{\mathbf{y}}(t) - \mathbf{y}(t)\|^2 \quad (3)$$

本文选择采用门控循环单元 (gate recurrent unit, GRU) 以及全连接层 (fully connected layer, FC) 的组合堆叠作为编码器与解码器, 编码器负责将输入的噪声序列映射至低维潜在空间, GRU 状态更新过程为:

$$\mathbf{z}^l(j) = \sigma(\mathbf{W}_z \mathbf{p}^l(j) + \mathbf{U}_z \mathbf{h}^l(j) + \mathbf{b}_z^l) \quad (4)$$

$$\mathbf{r}^l(j) = \sigma(\mathbf{W}_r \mathbf{p}^l(j) + \mathbf{U}_r \mathbf{h}^l(j) + \mathbf{b}_r^l) \quad (5)$$

$$\mathbf{n}^l(j) = \tanh(\mathbf{W}_n \mathbf{p}^l(j) + \mathbf{r}^l(j) \odot (\mathbf{U}_n \mathbf{h}^l(j) + \mathbf{b}_n^l)) \quad (6)$$

$$\mathbf{h}^l(j) = (1 - \mathbf{z}^l(j)) \odot \mathbf{n}^l(j) + \mathbf{z}^l(j) \odot \mathbf{h}^l(j) \quad (7)$$

式中: $\mathbf{h}^l(j)$ 为第 l 层在时间 j 的隐藏状态; $\mathbf{p}^l(j)$ 为第 l 层在时间 j 的输入; $\mathbf{r}^l$ 、 $\mathbf{z}^l$ 以及 $\mathbf{n}^l$ 为多维有限长序列, 分别代表了 GRU 中的重置门、更新门以及候选隐藏向量; $\mathbf{W}$ 、 $\mathbf{U}$ 以及 $\mathbf{b}$ 分别代表输入权重矩阵、循环权重矩阵以及偏置向量; σ 和 $\tanh$ 分别代表 s 型和双曲正切激活函数; $\odot$ 为 Hadamard 积。

传统的去噪自编码器 DAE 通过引入噪声并以纯净信号为目标进行训练, 具备较强的特征提取能力。但在风机实际工况中, 由于无法获取理想的无噪基准数据, DAE 的监督训练模式难以落地。为此, CBDAE 采用了一种创新的自监督架构。在获得潜在隐藏状态 $\mathbf{H}(t)$ 后, 解码器利用隐藏状态重构原始序列; 同时, 对比学习模块将

隐藏状态映射至度量空间。通过噪声对比估计 NCE 正则化约束, 最大化相邻时间步特征的余弦相似度, 并利用 NCE 正则化项构建损失函数。该机制迫使网络捕捉输入序列内在的时间相关性, 从而自适应地忽略不具备时间连续性的随机噪声, 最终实现了无需干净标签的输入数据盲去噪。噪声对比估计通过将密度估计转化为区分真实样本与噪声样本的二分类问题^[24], 有效降低了计算复杂度。CBDAE 将此思想应用于时序去噪, 依据时间相关性构建对比任务。

具体而言, 如图 2 所示, 模型将切分后的时间窗口子序列分类, 时间连续的序列构成正样本集 $\mathbf{B}_c$, 随机采样的非连续序列构成负样本集 $\mathbf{B}_r$ 。




图2 正负样本集合划分

Fig. 2 Partition of positive and negative sample sets

在得到正负样本集合后将顺序与随机序列串联形成一个批次训练的数据集 $\mathbf{B}$, 即:

$$\mathbf{B} = \mathbf{B}_c \oplus \mathbf{B}_r \quad (8)$$

式中: $\oplus$ 表示级联算子。对于批次训练数据集 $\mathbf{B}$, 经过编码器生成隐藏状态 $\mathbf{H}(t)$, 经由对比学习进行非线性变换, 对正负样本特征向量进行拼接得到总的重构特征向量集 $\mathbf{Z}$, 即:

$$\mathbf{Z} = [\mathbf{Z}_c \oplus \mathbf{Z}_r] \quad (9)$$

式中: $\mathbf{Z}_c$ 、 $\mathbf{Z}_r$ 分别是正样本集 $\mathbf{B}_c$ 和负样本集 $\mathbf{B}_r$ 经过编码器特征提取后进行非线性变换的特征向量。

CBDAE 损失函数定义为:

$$L = L_{AE} + \beta L_{NCE} \quad (10)$$

式中: L_{AE} 为解码器的重构损失; L_{NCE} 为对比学习损失; β 为权衡参数, 本文取 0.1。解码器重构损失公式为:

$$L_{AE} = \frac{1}{BNT} \sum_{k=1}^B \sum_{i=1}^N \sum_{j=1}^T |\hat{Y}_j(k) - \tilde{Y}_j(k)| \quad (11)$$

式中: B 、 N 和 T 分别代表批次大小、特征数量和序列长度; $\hat{Y}$ 与 $\tilde{Y}$ 分别为重构值与输入值。

噪声对比估计损失函数公式为:

$$L_{NCE} = \frac{1}{D} \sum_{k=1}^D (l(k, k+1, k-1) + l(k+1, k, k+2)) \quad (12)$$

$$l(i, j, s) = -\log \left(\frac{\exp(\text{sim}(\mathbf{Z}_i, \mathbf{Z}_j))}{\sum_{k=1}^B Q_{k \neq i, s} \exp(\text{sim}(\mathbf{Z}_i, \mathbf{Z}_k))} \right) \quad (13)$$

式中: $D=2s-1$; sim 表示余弦相似度; Q 为指标函数, 如果 $k \neq i$ 以及 $k \neq s$ 则赋值为 1, 否则为 0。

综上所述, CBDAE 模型在数据保真度与噪声去除中寻找最优平衡, 重构损失保证了模型不会丢失原始信号中的主要趋势, 而 NCE 正则化强迫编码器在潜在空间中

过滤掉高频、非连续的随机噪声, 使编码器的重构序列保留了特征信号, 实现有效盲去噪。

1.2 组合检测网络框架

鉴于风机覆冰过程兼具长期时序依赖性与多变量非线性耦合的复杂特性, 传统单一模型往往难以在时序动态捕捉与深层特征挖掘之间取得平衡。为此, 本文设计了一种时序-增强组合检测架构。该架构由两条并行分支构成: 时序分支采用双向长短期记忆网络 (bi-directional LSTM, BiLSTM) 与收缩广播注意力模块 (contract and broadcast self-attention, CBSA) 的级联结构, 从时间维度精准捕捉 SCADA 数据的长期演变规律, 有效建模历史状态对当前覆冰的累积效应; 特征分支则引入自动化特征模块 (open feature engineering, OpenFE) 算法, 深度挖掘原始变量间的隐式交互关系, 并结合柯尔莫哥洛夫-阿诺德网络 (Kolmogorov-Arnold networks, KAN) 卓越的非线性函数逼近能力, 实现复杂工况的高维映射。最终, 模型通过对并行的时序动态特征与强化空间特征进行拼接融合, 实现了从数据广度与时间深度两个维度对覆冰状态的全面表征。

1) 时序分支结构

本文基于 BiLSTM 与 CBSA 的级联架构作为捕捉风机覆冰的时间依赖性, 如图 3 所示, 时序分支结构利用 BiLSTM 捕捉双向时序上下文, 随后串联收缩广播注意力模块。




图3 时序分支结构

Fig. 3 Structure of the temporal branch

BiLSTM 模块建立在标准 LSTM 单元上, LSTM 通过遗忘门、输入门以及输出门动态调整信息存储与丢弃, 从而保留重要的历史记忆。其内部状态更新过程为:

$$\mathbf{c}_t = \mathbf{f}_t \odot \mathbf{c}_{t-1} + \mathbf{i}_t \odot \tilde{\mathbf{c}}_t \quad (14)$$

$$\mathbf{h}_t = \mathbf{o}_t \odot \tanh(\mathbf{c}_t) \quad (15)$$

式中: $\mathbf{f}_t$ 、 $\mathbf{i}_t$ 和 $\mathbf{o}_t$ 分别为遗忘门、输入门和输出门; $\odot$ 表示逐元素乘积; $\mathbf{c}_t$ 和 $\mathbf{c}_{t-1}$ 分别为 t 时刻与 $t-1$ 时刻的储存状态; $\mathbf{h}_t$ 为当前时刻的隐藏向量; $\tilde{\mathbf{c}}_t$ 为候选状态, 公式为:

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c \mathbf{x}_t + \mathbf{U}_c \mathbf{h}_{t-1} + \mathbf{b}_c) \quad (16)$$

式中: $\mathbf{W}_c$ 、 $\mathbf{U}_c$ 为网络权重; $\mathbf{b}_c$ 为偏置量; $\mathbf{x}_t$ 为输入值。

遗忘门 f_t 根据历史隐状态 h_{t-1} 和当前输入 x_t 动态调节信息流,通过与上一时刻细胞状态 c_{t-1} 进行 Hadamard 运算来决定信息的保留与丢弃。3 个门控单元的数学表达为:

$$\begin{bmatrix} f_t \\ i_t \\ o_t \end{bmatrix} = \begin{bmatrix} \sigma \\ \sigma \\ \sigma \end{bmatrix} (W[x_t, h_{t-1}] + b) \quad (17)$$

BiLSTM 结合前向信息和反向信息传播,具有更强的预测能力,预测结构由正向和反向隐藏层组合而成。当输出 t 时刻时,正向 LSTM 层分析 $t-1$ 时刻信息,反向 LSTM 层分析 $t+1$ 时刻信息。前向隐藏层 $\bar{h}_t$ 和反向隐藏层 $\tilde{h}_t$ 表达式为:

$$\bar{h}_t = \sigma(\omega_{hx} x_t + \omega_{hh} h + b_h) \quad (18)$$

$$\tilde{h}_t = \sigma(\omega_{hx} x_t + \omega_{hh} h + b_h) \quad (19)$$

正向和反向 LSTM 层的输出合并得到最终时序特征提取向量。BiLSTM 能有效提取序列中的双向联系特征,为了进一步挖掘全局依赖模式,本文使用 CBSA 模块通过压缩潜在空间内进行全局交互,使模型能从局部时序细节中提取全局状态,其收缩与广播自注意力结果计算过程为:

$$\text{CBSA}(Z|U_k) \approx \underbrace{U_k^T Q \text{Softmax}((U_k^T Q)^T (U_k^T Q))}_{\text{Contraction via self-attention}} \quad (20)$$

式中: U 为标准正交基; T 表示转置; Softmax 为归一化操作;收缩项构成自注意力操作,查询、键和值的 Q 、 K 和 V 矩阵均为 U_k^T ; A_k^T 为广播项,公式为:

$$A_k = \text{Softmax}((U_k^T Z)^T (U_k^T Q_{ini})) \quad (21)$$

其中, Q_{ini} 为初始查询矩阵,公式为:

$$Q_{ini} = \text{sg}(\text{avgpool}(U_k^T Z)) \quad (22)$$

式中: avgpool 为平均池化操作; sg 表示停止梯度算子,算子保证初始策略不影响后续计算。

$$U_k^T Q = U_k^T Q_{ini} + \eta U_k^T Z A_k \quad (23)$$

式中: η 为可学习步长。

综上所述,时序分支利用 BiLSTM 保证了时间步之间的连续性,并利用 CBSA 增强了全局相关性捕捉能力。

2) 特征增强分支

风电机组在覆冰工况下的运行状态呈现复杂的非线性特征,尽管原始的 SCADA 变量包含的基础的运行信息,但覆冰信息往往隐藏在多变量深层的耦合过程中。传统的特征工程难以全面覆盖多变量间的高阶交互,为此,本文设计了基于 OpenFE 算法的特征增强分支,通过自动化特征挖掘技术构建具有物理语义感知的特征增强空间,OpenFE 能利用启发式搜索策略,在广阔的算子空间内自动发现表征覆冰故障规律的最优组合,从而将隐含的物理约束转为显示的数学特征。

如图 4 所示,本文基于 OpenFE 特征增强过程为:针对滑动窗口内大小为 $N \times T$,原始数据构建大小为 $N \times 7$ 的基础特征集 F_{base} ,其中 N 为特征数量, T 为滑动窗口大小,其公式为:

$$F_{base} = \{\mu, \sigma, \max, \min, \text{Skew}, \text{Kurt}, \text{CV}\} \quad (24)$$

式中: μ 为均值; σ 为标准差; $\max$ 与 $\min$ 为最大、最小值; Skew 与 Kurt 为偏度与峰度; CV 为变异系数,定义为标准差与均值的比值。




图4 OpenFE 流程

Fig. 4 Flowchart of OpenFE

OpenFE 算法在基础特征集上递归应用代数算子,其中基础算子包含加减乘除等操作,高级算子包括特征组合与分组聚合操作,用于挖掘深层的数据关系。在生成候选特征的同时,OpenFE 会训练一个决策树模型进行预测以此评估新生成的特征对模型改进的潜在贡献,快速定位对模型有增益的特征,最后通过互信息度对增益特征进行筛选,提出冗余特征。本文选取对模型性能贡献前 100 的特征作为增强特征集输入至 KAN 网络中构成完整的特征增强分支。

KAN 网络的核心思想是将输入变量映射到一个可学习的高维函数空间中,从而有效逼近复杂的非线性函数。柯尔莫哥洛夫-阿诺德定理表明,任何连续多变量函数 f 都可表示为:

$$f(x_1, \dots, x_n) = \sum_{q=1}^{2n+1} \phi_q \left(\sum_{p=1}^n \psi_{q,p}(x_p) \right) \quad (25)$$

式中: ϕ_q 和 $\psi_{q,p}$ 为连续函数,分别用于对输入变量进行变换,其中,基函数 $\psi_{q,p}$ 通常是由神经网络学习得到的非线性映射函数,组合函数 ϕ_q 则可以是多项式或其他高维映射形式。

KAN 网络的数学特性能使其在高维数据上有效逼近复杂的非线性映射,提取输入数据复杂特征,进而提升模型的学习能力。

本文提出的风机覆冰检测整体框架如图 5 所示。

首先,对原始 SCADA 数据执行基础预处理,包括异常值剔除、缺失值插补及 Z-Score 标准化,以构建标准输入空间。随后,利用基于重构损失与 NCE 正则化双重机制的 CBDAE 自适应去噪网络对预处理数据进行去噪重构。重构后的去噪信号被并行输入至双分支网络,




图 5 覆冰检测算法流程

Fig. 5 Flowchart of the icing detection algorithm

BiLSTM-CBSA 分支捕获时序动态特征,OpenFE-KAN 分支挖掘高阶关联。最终,两路特征向量拼接并经由全连接分类器映射为覆冰概率,实现端到端的故障状态判定。具体而言,两路特征向量采用特征通道维度的拼接操作,在特征维度上进行展平与对齐,组合成更高维度的联合特征向量。采用基于 Sigmoid 激活函数的多层感知机作为分类器,实现对覆冰概率的映射,其前向传播计算公式为:

$$P = \frac{1}{1 + e^{-(W_{out} \cdot H_{hidden} + b_{out})}} \tag{26}$$

式中: W_{out} 、 b_{out} 分别为输出层的权重矩阵和偏置项; H_{hidden} 为上一隐藏层的输出; P 即为最终模型输出的覆冰概率。

2 实例验证

2.1 数据集描述与数据预处理

为了验证所提基于 CBDAE 自适应去噪双分支覆冰检测组合模型的有效性,本研究采用内蒙古某风电场两台机组的实测 SCADA 数据作为实验对象。该数据集的采样间隔为 7 s,涵盖了机组在覆冰频发时段的详细运行记录。其中,第 1 台机组的数据跨度为 2015 年 11 月 1 日至 2016 年 1 月 1 日,第 2 台机组为 2015 年 11 月 1 日至 2015 年 12 月 1 日。原始数据共包含 26 维监测变量,具体特征定义如表 1 所示。

由于原始 SCADA 数据存在量纲不一以及特征冗余等问题,直接将原始数据输入模型中会导致收敛困难以及过拟合,为此本文采用下列数据预处理流程。

表 1 SCADA 特征定义

Table 1 Description of SCADA features

特征名	特征解释	特征名	特征解释
Wind_speed	风速	Pitch1_moto_tmp	电机 1 温度
Generator_speed	发电机转速	Pitch2_moto_tmp	电机 2 温度
Power	网侧有功	Pitch3_moto_tmp	电机 3 温度
Acc_x	X 加速度	Wind_direction	对风角
Acc_y	Y 加速度	Wind_direction_mean	平均风角
Yaw_position	偏航位置	Environment_tmp	环境温度
Yaw_speed	偏航速度	Int_tmp	机舱温度
Pitch1_angle	叶片 1 角度	Pitch1_ng5_tmp	Ng5 1 温度
Pitch2_angle	叶片 2 角度	Pitch2_ng5_tmp	Ng5 2 温度
Pitch3_angle	叶片 3 角度	Pitch3_ng5_tmp	Ng5 3 温度
Pitch1_speed	叶片 1 速度	Pitch1_ng5_DC	Ng5 1 电流
Pitch2_speed	叶片 2 速度	Pitch2_ng5_DC	Ng5 2 电流
Pitch3_speed	叶片 3 速度	Pitch3_ng5_DC	Ng5 3 电流

1) 基于基尼系数的特征选择

原始 SCADA 数据中包含 26 个监测变量,但并非所有特征对覆冰故障具有显著的识别贡献,因此,本文引入基于随机森林的基尼重要性评价机制,对原始特征空间进行降维筛选。随机森林通过构建多颗决策树并集成结果,具有天然的抗过拟合能力。本文基于基尼重要性对特征进行量化排序。对于特征 f_j ,其重要性评分 VI_j 计算为该特征在森林中所有树 t 的所有节点 m 上带来的不纯度减少量的加权和,即:

$$VI_j = \frac{1}{N_{tree}} \sum_{t=1}^{N_{tree}} \sum_{m \in M_t} p(m) \cdot \Delta i(s_m, m) \tag{27}$$

式中: N_{tree} 为决策树数量; $p(m)$ 为节点 m 的样本比例; $\Delta i(s_m, m)$ 为特征在节点处分裂所带来的基尼不纯度下降值。基尼重要性系数越大,对应特征对判断覆冰越关键,说明该特征对风机正常与覆冰状态的区分能力越强。最终结果如图 6 所示。将 26 个特征进行重要性评分后,对其进行归一化并按降序排序,本文采用累积贡献度筛选策略,保留前 12 个特征,其累积贡献度达到 95%。既保证了特征信息的密度集中,同时抑制冗余变量。

2) 数据集构建与数据标准化

基于滑动窗口技术对原始 SCADA 时间序列进行切分与样本构建。由于不同传感器数据物理量纲差异大,为了消除量纲影响,本文采用 Z-Score 标准化对数据进行预处理,分别将各变量映射为均值为 0、标准差为 1 的正态分布,公式为:

$$x^* = \frac{x - \mu}{\sigma} \tag{28}$$




图6 特征基尼重要性排序

Fig. 6 Ranking of feature gini importance

式中: x 为原始特征值; μ 和 σ 分别为该特征对应数据集上的均值与标准差; x^* 为标准化后的特征输入。

在数据集的划分与评估策略上, 本文采用五折交叉验证策略, 将构建好的样本集随机划分为 5 个互斥的子集, 轮流选取其中 1 个子集作为独立测试集, 其余 4 个子集作为训练数据。此外, 进一步从训练数据中随机划分出 15% 的样本作为验证集用于监控模型收敛状态。

2.2 评价指标与模型参数

为了全面评估本文所提方法在风机覆冰检测任务中的性能, 本文采用基于混淆矩阵的评价指标, 设定覆冰状态为 1, 正常状态为 0, 对应准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 以及 F1 分数计算公式如式 (29) ~ (32) 所示。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (29)$$

$$Precision = \frac{TP}{TP + FP} \quad (30)$$

$$Recall = \frac{TP}{TP + FN} \quad (31)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (32)$$

式中: TP 、 FP 、 TN 以及 FN 如图 7 所示分别为真正例、假正例、真负例以及假负例。准确率直观反映了模型整体的分类能力。精确率主要反映模型预测为覆冰样本中实际发生覆冰的比例, 与模型误报程度有关。召回率为实际覆冰事件中被模型成功识别的比例。F1 分数综合衡量模型性能。

本文提出的模型架构主要由数据去噪 CBDAE 模块、时序特征提取分支以及特征增强分支构成。各模块的具体参数配置为:




图7 混淆矩阵定义

Fig. 7 Definition of the confusion matrix

1) 采用 GRU 作为编码器与解码器主干, 其隐藏层维度设定为 64。投影头包含两个全连接层, 节点数分别设定为 64 与 16。该模块训练轮次为 100, 初始学习率设定为 1×10^{-3} ;

2) 时序特征分支: 基于双层 BiLSTM 网络构建, 隐藏单元数设为 128。为防止过拟合, 引入比率为 0.3 的随机失活 Dropout 策略。CBDAE 注意力机制配置为 4 个注意力头, 单头维度为 64;

3) 特征增强分支采用 3 层 KAN 网络进行堆叠, 各层输出维度依次为 128、128 和 64。每层 KAN 后均级联层归一化与 Sigmoid 加权线性单元激活函数。KAN 内部参数网格大小设为 5, 样条阶数设为 3。

最终, 双分支提取的特征向量经拼接后输入至全连接分类器。针对双分支网络交叉验证的每一折数据, 采用二元交叉熵损失函数进行优化, 训练轮次设定为 100, 学习率为 1×10^{-5} , 最终性能评价指标取实验平均值。

2.3 模型性能与对比

1) 去噪模型性能

由于风机 SCADA 数据在真实工况下缺乏理想的无噪基准信号, 本文采用统计残差与双向掩码恢复相结合的策略, 从频域统计特性和时域重构能力两个维度分析 CBDAE 模型的盲去噪性能。

CBDAE 算法去噪的核心目标是将原始序列分解为潜在的真实信号与噪声, 为了验证模型对噪声的有效分离, 如图 8 所示去噪前后的信号的残差对比, 残差序列呈现出显著的随机性与平稳性, 未表现出明显的周期性与趋势项, 这意味这模型成功分离了数据中的随机扰动分量。

为了进一步从统计学角度验证模型的去噪性能, 如图 9 所示基于残差的自相关函数以及经 P-value 检验的残差概率分布直方图。

自相关函数 (autocorrelation function, ACF) 用于衡量时间序列在不同滞后阶数 Lag 下自身相关程度。对于盲




图8 去噪前后残差图

Fig. 8 Residual plots before and after denoising




图9 去噪前后 ACF 值与残差分布

Fig. 9 ACF values and residual distributions before and after denoising

去噪算法而言理想的去噪残差应不存在显著的时间依赖性,如图9左侧子图所示,残差序列的ACF值在滞后阶数Lag>0时迅速衰减至95%置信区间,即阴影区间,这表明残差序列内部不存在显著的时间相关性,残差部分仅为随机噪声。

残差分布正态性检验旨在从概率学角度验证残差分布的正态性,如图9右侧子图的残差概率分布直方图呈现标准的钟形曲线,经过正态性检验,其计算P-value均0.9以上,在统计显著性水平上无法拒绝残差服从正态分布,说明CBDAE模型去除噪声高度近似于零均值高斯分布,有效保留了有效信号。

为了验证模型的真实信号的捕捉能力,引入自监督学习中的掩码恢复任务,在验证集中随机掩盖(mask)连续的时间片段,掩盖占比为15%,迫使模型利用上下文信息对其进行重构。

如图10所示CBDAE模型对被遮盖区域的重构结果,黑色圆点为遮盖数据。即使在数据缺失的情况下,CBDAE模型能够根据前后文的依赖关系,较好地补全缺失的风速与功率轨迹,真正捕捉SCADA数据的内在物理演变规律。




图10 掩码恢复性能

Fig. 10 Performance of masked reconstruction

2) 故障检测性能与对比

本文首先通过滑窗长度灵敏度实验确定输入数据的最佳时间步长,随后基于最优参数,在五折交叉验证框架下将所提双分支网络与当前主流方法进行对比。输入序列的滑动窗口大小决定模型能够捕捉到的历史上下文信息的长度,直接影响特征提取的完整性与故障检测的事实性,若滑窗太小,模型不能以捕捉长期的时序依赖关系,滑窗过大,则会增加计算开销与引入无关信息。

为研究不同滑窗长度对故障特征提取的影响,本文分别设置了10、15、25、50的长度下进行五折交叉验证,各窗口大小下的详细性能变化如图11所示。当窗口大小从10增加至15时,各项指标均达到最优值。当窗口进一步增大,模型性能反而下降并且标准差显著增大,这表明对于风机覆冰而言,过长的输入序列反而引入了冗余信息。综上所述,本文数据滑窗长度设置为15,此时模型能取得最高的分类精度且保持了极低的标准差。

为了全面验证本文所提双分支融合网络的性能优势,本节选取了当前风机覆冰检测领域的主流算法进行




图 11 滑窗长度性能变化

Fig. 11 Performance variations with different sliding window lengths

对比实验。为确保实验的公平性并排除原始数据噪声的

干扰,所有对比模型均统一采用经由 CBDAE 模块去噪后的数据作为输入。基准模型涵盖了多层感知机 (multi-layer perceptron, MLP)^[25]、集成学习算法轻量级梯度提升机 (light gradient boosting machine, LGBM)^[11]、类别特征提升 (categorical boosting, Catboost)^[26] 以及深度学习架构胶囊网络 (capsule networks, Capnet)^[27]、Transformer 模型^[28],具体实验结果如表 2 所示。

实验数据表明,尽管部分对比模型在精确率 Precision 上具有微弱优势,但其召回率 Recall 普遍低于本文模型。这表明现有算法在面对故障特征时存在较高的漏检风险,难以满足高可靠性的运维需求。相比之下,本文所提的双分支融合网络凭借时序特征提取与 KAN 特征增强的协同作用,在保持高准确率的同时显著提升了召回率,有效增强了模型对覆冰故障样本的敏感性,从而大幅降低了漏报率。

2.4 消融实验与泛化性能分析

为了定量评估本文所提自适应去噪模块与双分支融合架构对故障检测性能的独立贡献,本节设计消融实验。具体而言,实验通过逐步移除自适应去噪模块 CBDAE、时序特征提取分支以及 KAN 特征增强分支,构建了 3 种变体模型与完整模型进行对比,具体结果如表 3 所示。

表 2 各模型性能对比

Table 2 Performance comparison of different models

模型种类	Accuracy	Precision	Recall	F1
MLP	0.987 0±0.001 6	0.917 0±0.026 7	0.869 5±0.023 6	0.892 1±0.012 6
LGBM	0.989 3±0.000 5	0.972 9±0.006 1	0.851 1±0.006 2	0.907 9±0.004 7
Catboost	0.991 0±0.000 2	0.980 8±0.004 1	0.871 7±0.005 5	0.923 0±0.001 6
Capnet	0.989 0±0.000 9	0.930 6±0.013 9	0.888 9±0.023 6	0.908 9±0.008 6
Transformer	0.991 0±0.002 0	0.974 6±0.012 2	0.877 9±0.026 0	0.923 6±0.017 4
双分支网络	0.994 7±0.001 3	0.961 7±0.015 9	0.953 0±0.009 2	0.957 2±0.010 0

表 3 各消融实验性能对比

Table 3 Performance comparison of ablation studies

消融类型	Accuracy	Precision	Recall	F1
无 CBDAE	0.986 3±0.005 8	0.973 1±0.006 8	0.800 1±0.095 0	0.875 0±0.061 2
无时序特征	0.992 5±0.001 3	0.946 9±0.006 9	0.931 5±0.021 9	0.939 0±0.011 0
无特征增强	0.991 5±0.001 1	0.958 8±0.013 5	0.901 1±0.024 3	0.928 8±0.009 7
双分支网络	0.994 7±0.001 3	0.961 7±0.015 9	0.953 0±0.009 2	0.957 2±0.010 0

实验结果表明,CBDAE 模块的移除对模型性能影响最为显著,导致召回率大幅下降。这说明当输入数据包含高频噪声时,模型难以精准界定覆冰信号与环境噪声

的决策边界,从而产生严重的漏检现象。此外,双分支架构表现出了显著的互补性,移除特征增强分支使得单纯的时序建模难以拟合 SCADA 数据中复杂的非线性映射

关系,而移除时序分支则导致模型丧失了对故障演变趋势的捕捉能力。综上所述,本文构建的完整检测流程在综合性能上取得最优结果,F1 分数达 0.957 2,并保持了极低的标准差,充分验证了所提方法在实现故障有效检测中的必要性。

为了进一步评估去噪算法在极端工况下的稳定性,本节开展了噪声灵敏度测试。实验通过向原始数据叠加不同强度噪声,即 0.1~0.5 倍标准差的高斯白噪声,旨在模拟传感器精度退化或传输干扰加剧的恶劣场景。同时选取小波去噪分解、VMD 去噪以及卡尔曼滤波 3 类工业常用的去噪算法进行对比,小波去噪选用 db4 小波、分解层数为 4;VMD 去噪模态数为 5,带宽限制为 2 000;卡尔曼滤波测量噪声协方差为 0.01,过程噪声协方差为 0.5。本研究选取平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、决定系数(coefficient of determination, R2)以及信噪比(signal-to-noise ratio, SNR)作为量化评价指标,具体结果如图 12 所示。




图 12 不同噪声强度下去噪性能变化

Fig. 12 Denoising performance under different noise intensities

结果表明,随着噪声标准差从 0.1 增加至 0.5,MAE 与 RMSE 呈现出近似线性的增长趋势,同时 R2 与 SNR 随噪声强度的增加而逐渐下降。尽管性能指标随噪声增强出现了一定程度的衰减,但整体去噪效果仍维持在较高水平,表明该算法在较强干扰环境下依然具备稳定的

信号重构能力。与传统去噪算法相比,CBDAE 算法在全测试区间内均表现出最优的综合性能证明了其优于传统方法的稳定性与抗噪能力。

本节将经不同算法处理后的多级噪声数据作为模型输入,并采用 F1 分数作为覆冰识别性能的综合评价指标,具体趋势如图 13 所示,随着噪声强度的增加,模型的识别性能均呈现下降趋势。与无去噪情况相比,经过去噪后的数据具有更高的识别精度。与对比算法相比,CBDAE 模块在有效去除噪声的同时,最大程度地保留了关键的时序特征,在不同噪声水平下均保持了优异的识别能力。




图 13 不同去噪算法的识别性能对比

Fig. 13 Comparison of the denoising performance of different algorithms

为了进一步评估模型的泛化能力,本文在上述基础上开展了跨机组独立验证实验。有别于五折交叉验证,本实验严格将一台机组的全量数据作为训练集,另一台独立机组的数据作为测试集,并进行了多次重复实验。如图 14 所示,在面对未曾参与训练的跨机组测试集时,模型的各项评价指标较五折交叉验证结果有一定程度的下降,但整体性能依然保持在较高水平。这一结果表明,本文所提算法能够适应不同机组间的差异,具备一定的跨设备泛化能力。




图 14 跨机组泛化能力验证

Fig. 14 Validation of cross-turbine generalization performance

3 结 论

针对工业场景下风机 SCADA 数据噪声干扰严重无有效时序去噪方法的难题,本文提出了一种基于对比盲去噪自编码器 CBDAE 的风机覆冰组合检测框架。该方法通过 CBDAE 模块实现了无基准数据下的自适应盲去噪,在有效剥离噪声的同时保留了原始信号的时序趋势,为下游任务提供了高质量的数据基础。在此基础上,本文构建了时序-增强并行组合检测网络,利用多视角特征融合策略,同时捕捉参数随时间演化的规律以及风速、功率以及温度等多变量间的非线性耦合关系。综合实验表明,CBDAE 去噪方法显著改善了模型评价指标,有效克服了噪声干扰导致的覆冰错误识别问题,且并行网络架构的检测性能明显优于单一网络架构。未来工作将致力于在数据驱动方法中融入物理机制模型,以进一步提升模型的鲁棒性与可解释性。

参考文献

- [1] 姜永祺,单慧琳. 基于 ECSMNet 的风力发电机表面缺陷检测研究[J]. 电子测量与仪器学报, 2025, 39(5): 166-176.
- JIANG Y Q, SHAN H L. Research on surface defect detection of wind turbine based on ECSMNet[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 166-176.
- [2] GAO L Y, LIU Y, ZHOU W W, et al. An experimental study on the aerodynamic performance degradation of a wind turbine blade model induced by ice accretion process[J]. Renewable Energy, 2019, 133: 663-675.
- [3] LAI ZH CH, CHENG X, LIU X F, et al. Multiscale wavelet-driven graph convolutional network for blade icing detection of wind turbines[J]. IEEE Sensors Journal, 2022, 22(22): 21974-21985.
- [4] GAO L Y, HONG J R. Wind turbine performance in natural icing environments: A field characterization[J]. Cold Regions Science and Technology, 2021, 181: 103193.
- [5] GÓMEZ MUÑOZ C Q, ARCOS JIMÉNEZ A, GARCÍA MÁRQUEZ F P. Wavelet transforms and pattern recognition on ultrasonic guides waves for frozen surface state diagnosis[J]. Renewable Energy, 2018, 116: 42-54.
- [6] GÓMEZ MUÑOZ C Q, GARCÍA MÁRQUEZ F P, SÁNCHEZ TOMÁS J M. Ice detection using thermal

infrared radiometry on wind turbine blades [J]. Measurement, 2016, 93: 157-163.

- [7] GUO P, INFELD D. Wind turbine blade icing detection with multi-model collaborative monitoring method[J]. Renewable Energy, 2021, 179: 1098-1105.
- [8] 王朋飞,刘长良,徐健,等. 基于图注意力和时间卷积网络的风电齿轮箱故障预警方法[J]. 电子测量与仪器学报, 2023, 37(8): 204-213.
- WANG P F, LIU CH L, XU J, et al. Wind turbine gearbox fault warning method based on graph attention and temporal convolutional network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 204-213.
- [9] 刘珊,李雪利,王洪琦,等. 基于随机森林的风机叶片覆冰自动化监测方法[J]. 自动化应用, 2025, 66(10): 9-11.
- LIU SH, LI X L, WANG H Q, et al. Automated monitoring method for wind turbine blade icing based on random forest [J]. Application of Automation, 2025, 66(10): 9-11.
- [10] TAO T, LIU Y Q, QIAO Y H, et al. Wind turbine blade icing diagnosis using hybrid features and stacked-xgboost algorithm[J]. Renewable Energy, 2021, 180: 1004-1013.
- [11] 吕云龙,胡琴,胡紫园,等. 考虑样本不平衡条件下风机叶片覆冰诊断及可解释性研究[J]. 电工技术学报, 2025, 40(11): 3667-3679.
- LYU Y L, HU Q, HU Z Y, et al. Diagnosis and interpretability study of wind turbine blade icing under consideration of sample imbalance conditions [J]. Transactions of China Electrotechnical Society, 2025, 40(11): 3667-3679.
- [12] BAI X J, TAO T, GAO L Y, et al. Wind turbine blade icing diagnosis using RFECV-TSVM pseudo-sample processing[J]. Renewable Energy, 2023, 211: 412-419.
- [13] TONG R N, LI P, LANG X, et al. A novel adaptive weighted kernel extreme learning machine algorithm and its application in wind turbine blade icing fault detection[J]. Measurement, 2021, 185: 110009.
- [14] 张家安,邓强,马增强,等. 基于 IMHSA-MSCNN-BiLSTM 的风机轴承故障诊断[J]. 电子测量技术, 2024, 47(7): 170-176.
- ZHANG J AN, DENG Q, MA Z Q, et al. Fault

- diagnosis of fan bearings based on IMHSA-MSCNN-BiLSTM[J]. *Electronic Measurement Technology*, 2024, 47(7): 170-176.
- [15] TIAN W W, CHENG X, LI G Y, et al. A multilevel convolutional recurrent neural network for blade icing detection of wind turbine[J]. *IEEE Sensors Journal*, 2021, 21(18): 20311-20323.
- [16] TAO CH, TAO T, HE SH K, et al. Wind turbine blade icing diagnosis using B-SMOTE-Bi-GRU and RFE combined with icing mechanism[J]. *Renewable Energy*, 2024, 221: 119741.
- [17] WANG X, ZHENG ZH, JIANG G Q, et al. Detecting wind turbine blade icing with a multiscale long short-term memory network[J]. *Energies*, 2022, 15(8): 2864.
- [18] HEYDARI A, GARCIA D A, FEKIH A, et al. A hybrid intelligent model for the condition monitoring and diagnostics of wind turbines gearbox[J]. *IEEE Access*, 2021, 9: 89878-89890.
- [19] 罗朗川, 李汝辉, 曾东, 等. 基于 RANSAC-DBSCAN 的风速功率曲线异常数据清洗方法[J]. *太阳能学报*, 2025, 46(4): 445-453.
- LUO L CH, LI R H, ZENG D, et al. Abnormal data cleaning method of wind speed-power curve based on RANSAC-DBSCAN[J]. *Acta Energaie Solaris Sinica*, 2025, 46(4): 445-453.
- [20] 万俊豪, 左建勇, 丁景贤, 等. 基于新息自适应卡尔曼滤波地铁测速定位方法[J]. *仪器仪表学报*, 2025, 46(1): 236-246.
- WAN J H, ZUO J Y, DING J X, et al. A speed measurement and positioning method of metro based on innovation-based adaptive Kalman filter[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(1): 236-246.
- [21] 龙保鑫, 滕召胜, 孙彪, 等. 一种改进平稳小波去噪与扩展卡尔曼系统辨识的动态称量新方法[J]. *仪器仪表学报*, 2025, 46(3): 41-50.
- LONG B X, TENG ZH SH, SUN B, et al. A novel dynamic weighing method integrating improved stationary wavelet denoising and extended Kalman system identification[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(3): 41-50.
- [22] 石欣, 张夏恒, 朱雅亲, 等. 基于 VMD-NARX 的 MOSFET 剩余使用寿命预测方法[J]. *仪器仪表学报*, 2023, 44(9): 275-286.
- SHI X, ZHANG X H, ZHU Y Q, et al. Method for predicting the remaining useful life of MOSFETs based on VMD-NARX[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(9): 275-286.
- [23] LANGARICA S, NÚÑEZ F. Contrastive blind denoising autoencoder for real time denoising of industrial IoT sensor data[J]. *Engineering Applications of Artificial Intelligence*, 2023, 120: 105838.
- [24] 许涛, 南新元, 蔡鑫, 等. 基于 CBDAE 和 TCN-Transformer 的工业传感器时间序列预测[J]. *南京信息工程大学学报*, 2025, 17(4): 455-466.
- XU T, NAN X Y, CAI X, et al. Industrial sensor time series prediction based on CBDAE and TCN-Transformer[J]. *Journal of Nanjing University of Information Science & Technology*, 2025, 17(4): 455-466.
- [25] XIE N, CAO Q Q, ZENG ZH X, et al. Research on the real-time prediction of wind turbine blade icing process based on the MLP neural network model and meteorological parameters[J]. *Processes*, 2025, 13(6): 1910.
- [26] KONG L CH, LIANG H T, LIU G ZH, et al. Research on wind turbine fault detection based on the fusion of ASL-CatBoost and TrRSA[J]. *Sensors*, 2023, 23(15): 6741.
- [27] XING Z X, GUO SH SH, CHEN M Y, et al. Icing diagnosis method of wind turbine blade based on mechanism and data driving[J]. *Renewable Energy*, 2025, 255: 123820.
- [28] DHIMAN H S, PATIL S, WAGLE S, et al. Multi-head attention transformer and Bayesian inference recommendation engine-based blade icing detection framework for wind turbines[J]. *Neural Computing and Applications*, 2025, 37(31): 26157-26176.

作者简介



袁军, 2024 年于长沙理工大学获得学士学位, 现为长沙理工大学电气与信息工程学院硕士研究生, 主要研究方向为风机覆冰故障检测。

E-mail: csldxyuanjun@163.com

Yuan Jun received his B.Sc. degree from Changsha University of Science and Technology in 2024. He is currently a master's student at the School of Electrical and Information Engineering, Changsha University of Science and Technology. His main research interest is wind turbine icing fault detection.



蒙文川,1998 年于武汉水利电力大学获得学士学位,2001 年于武汉大学获得硕士学位,2006 年于浙江大学获得博士学位,现为南方电网高级工程师,主要研究方向为新能源规划。

E-mail:mengwc@csg.cn

Meng Wenchuan received his B.Sc. degree from Wuhan University of Water Resources and Hydropower Engineering in 1998, his M. Sc. degree from Wuhan University in 2001, and his Ph. D. degree from Zhejiang University in 2006. He is currently a senior engineer at China Southern Power Grid. His main research interest is renewable energy planning.



邓韦斯,2013、2017 年于华中科技大学分别获得学士、博士学位,现为南方电网公司高级工程师,研究方向为新能源预测。

E-mail:dengws@csg.cn

Deng Weisi received her B. Sc. and Ph. D. degrees both from Huazhong University of

Science and Technology in 2013 and 2017, respectively. She is currently a senior engineer at China Southern Power Grid Company. Her main research interest is renewable energy forecasting.



李彬(通信作者),2016 年于湖南城市学院获得学士学位,2019、2025 年于长沙理工大学分别获得硕士、博士学位,现为长沙理工大学讲师,主要研究方向为配用电大数据分析 and 电力气象灾害分析。

E-mail:libin2021666@163.com

Li Bin (Corresponding author) received his B.Sc. degree from Hunan City University in 2016, and his M. Sc. and Ph. D. degrees both from Changsha University of Science and Technology in 2019 and 2025, respectively. He is currently a lecturer at Changsha University of Science and Technology. His main research interests include big data analysis in power distribution and meteorological disaster analysis in the electric power sector.