

基于双通道时序特征融合网络的 叶片覆冰检测算法

周求湛¹, 陈 霄¹, 汪 锋², 张 雯², 李 琛², 武慧南¹, 邓琬超¹, 刘萍萍³

(1. 吉林大学 通信工程学院, 长春 130012; 2. 华锐风电科技(江苏)有限公司, 江苏 盐城 224056; 3. 吉林大学 计算机科学与技术学院, 长春 130012)

摘 要: 风能作为一种清洁、可再生能源, 在全球范围内得到了显著推广, 然而风力涡轮机叶片结冰问题严重影响了设备的安全运行和效率提升。现有叶片覆冰检测算法易受数据不平衡或噪声影响, 导致准确率降低, 因此亟需一种准确、高效的叶片覆冰检测算法以降低风机运行风险。本文提出了一种基于双通道时序特征融合网络的叶片覆冰检测算法: 首先, 对采集与监视控制系统数据进行数据预处理, 并将特征工程应用至 SCADA 数据中; 其次, 提出了一种融合长短时记忆网络和注意力机制的检测模型, 利用 LSTM 充分学习风机状态的时间依赖关系, 采用注意力机制动态调整不同时间步的权重。最后, 提出基于双通道时序特征融合网络的叶片覆冰检测算法, 捕捉特征随时间变化的动态趋势, 引入多头注意力机制增强特征交互能力。实验结果表明: 相较其他算法, 本文算法检测准确率提升了 10%~15%, 在风机叶片覆冰检测上具有较好的性能。

关键词: 覆冰检测; 时序特征融合; 长短时记忆网络; 注意力机制

中图分类号: TP274 **文献标志码:** A **文章编号:** 1671-5497(2026)09-2489-13

DOI: 10.13229/j.cnki.jdxbgxb.20250245

Blade ice detection algorithm based on dual channel temporal feature fusion network

ZHOU Qiu-zhan¹, CHEN Xiao¹, WANG Feng², ZHANG Wen², LI Chen²,

WU Hui-nan¹, DENG Wan-chao¹, LIU Ping-ping³

(1. College of Communication Engineering, Jilin University, Changchun 130012, China; 2. Sinovel Wind Power Technology (Jiangsu) Co., Ltd., Yancheng 224056, China; 3. College of Computer Science and Technology, Jilin University, Changchun 130012, China)

Abstract: As a clean and renewable energy source, wind energy has been extensively promoted globally. However, the issue of wind turbine blade icing has severely impacted the safe operation and efficiency of the equipment. Existing blade icing detection algorithms are prone to being affected by data imbalance or noise, leading to reduced accuracy. Consequently, there is an urgent need for a precise and efficient ice

收稿日期: 2025-03-24.

基金项目: 盐城市重点研发计划(工业)项目(BE2023008).

作者简介: 周求湛(1974-), 男, 教授, 博士. 研究方向: 微弱信号检测. E-mail: 13504465154@163.com

通信作者: 武慧南(1999-), 女, 工程师, 硕士. 研究方向: 机器学习算法. E-mail: 466534739@qq.com

detection algorithm to mitigate operational risks. In this paper, we propose an ice detection algorithm for wind turbine blades based on a dual-channel temporal feature fusion network. First, we preprocess Supervisory Control and Data Acquisition (SCADA) data and apply feature engineering to SCADA data. Secondly, a detection model combining Long Short-Term Memory Network (LSTM) and attention mechanism is proposed. LSTM is used to fully learn the time dependence of fan state, and the attention mechanism is used to dynamically adjust the weights of different time steps. Finally, a blade ice detection algorithm based on dual channel temporal feature fusion network is proposed. Dynamic trends of features over time can be captured. Multi-head attention mechanism is introduced to enhance feature interaction. The experimental results show that: compared with other algorithms, the detection accuracy of the proposed algorithm is improved by 10%-15%. It has good performance in the ice detection of fan blades.

Key words: Icing detection; Temporal feature fusion; Long short-term memory network; Attention mechanism

0 引言

在我国能源结构优化和“双碳”目标的推动下,风电产业的发展呈现出高速化、规模化、智能化的趋势^[1]。随着风力发电的广泛应用,风力涡轮机叶片结冰问题已成为影响风机安全性和发电效率的重要因素。叶片结冰不仅降低了风机的气动性能,还可能引发叶片不平衡、结构损坏,甚至导致冰块脱落,带来严重的安全隐患。因此,准确、实时地检测风机叶片结冰状态成为了风电行业亟待解决的技术难题^[2-4]。

对于此问题,学者们也提出了很多检测方法。Jiang 等^[5]提出了时空注意力模型,结合门控循环单元和卷积神经网络提取时空特征;Guo 等^[7]采用卷积长短时记忆网络提取时间特征,并结合 Transformer 网络增强多维时间序列的学习能力,同时使用粒子群优化算法进行超参数优化,以提高模型检测性能^[6]。Tian W 等提出了一个多层卷积递归神经网络,结合了卷积神经网络和长短期记忆,并使用离散小波分解来从时域和频域中提取增强特征;Chen 等^[8]提出了结合时序模式注意力和双向 GRU 的深度学习框架,并采用改进的 Coot 算法优化超参数,用于处理数据不平衡问题;Jiang 等^[9]提出了多任务时空注意力网络,通过时空注意力机制提取采集与监视控制系统(Supervisory control and data acquisition, SCADA)数据中的重要特征,并结合深度度量学习和分类学习任务以增强特征的辨别能力;Wang 等^[10]利用时空注意力 Siamese 网络,结合图注意力网络和门控递归单元,实现高效的少样本学习,解决了

有限标签传感器数据的问题。

上述的风机叶片结冰检测方法未能充分挖掘风机运行状态与环境数据的复杂交互。这导致特模型对多维数据的泛化能力较弱,且常受数据不平衡和噪声影响,影响检测的准确性和实时性。为此,本文提出了基于双通道时序特征融合网络的方法,通过特征选择算法确保模型输入的高相关性,分别对环境特征和风机运行特征进行建模,提升了模型的学习能力。同时,结合多头注意力机制设计了特征融合模块,实现了时间序列层面上不同特征之间的交互与融合,增强了风机叶片覆冰检测的准确性。

1 数据集分析与数据预处理

1.1 风机 SCADA 数据集

SCADA 通过实时采集风机运行的关键数据,为设备健康状态的监测与维护提供了丰富的原始数据支撑。SCADA 系统依托传感器采集外部数据,并通过计算机存储所获取的信息。本文采用的样本数据集来自于华北某风电场机组的 SCADA 系统在运行中的工作数据,该风场位于中国“三北”地区,是风机结冰问题的高发地带。风机 SCADA 数据集数据特征充足,各项特征属性之间存在较强的相关性,数据类型较为单一,使数据的质量较高,有利于挖掘特征间的潜在关系。同时,SCADA 系统作为一种数据自动化监控装置,不仅可以实现全天候的设备运行状态监测,还可以对机组的运行数据进行监控和记录^[11]。

风机 SCADA 系统采集数据包含 26 个特征,

包括时间、风速、风向角、平均风向角、环境温度、机舱温度、有功功率、发电机转速、桨距角、偏航位置、偏航速度、变桨速度、变桨电源温度、变桨电机温度、变桨电源直流电路、加速度等。

在对 SCADA 数据进行整合后,通过分析发现,覆冰故障主要发生在温度较低的时段,而在较高温度时段,覆冰现象较为罕见。因此,依据温度条件,从 SCADA 数据中提取出覆冰时段的数据,并将其分类为正常数据、覆冰数据和无效数据。数据总量为 86 371,其中,正常数据 80 523 条,占比为 93.2%;覆冰数据 4 079 条,占比为 4.7%;无效数据 1 769 条,占比为 2.1%。剔除无效数据后,正常数据与覆冰数据的比例大约为 20:1,这表明该数据集是一个典型的类别不平衡数据集。

1.2 数据预处理

1.2.1 缺失值处理

SCADA 系统采集的数据中包含少量异常数据,主要为缺失数据和噪声数据。缺失数据指在特定时间或时间段内数据丢失,这通常是由于设备停机或数据传输中断引起的。噪声数据则是由于系统故障、传感器故障或操作错误等因素导致的异常数据点。通过对 SCADA 数据集的分析,可以识别出噪声数据点,通常表现为个别数据点与整体数据趋势的偏离,这种偏差可能是由设备故障、传感器问题或外部环境因素的干扰所造成的。

在处理数据集中的缺失值时,常见的缺失值填补技术包括均值插补、同类均值插补和极大似然估计等^[12]。SCADA 数据规模较大,用均值插补方法比较简单,通过用每个特征的均值来替代缺失的值,可以快速完成数据填补,避免了计算复杂度的提升。同时,在 SCADA 数据中,缺失值通常不是特别多,均值插补能有效应对少量缺失值的情况,并不会引入显著的偏差。因此,使用均值插补填补缺失值,可以在不影响数据分布的前提下,保证模型训练的稳定性。

1.2.2 数据不平衡处理

采用滑动窗口欠采样对正常数据进行欠采样,其基本思路是:对于多数类样本,采用固定大小的滑动窗口划分数据集,在每个窗口内统计多数类和少数类样本数量,并对多数类样本进行欠采样,使其比例接近少数类。窗口按照一定的步

长滑动,重复执行该过程,最终形成一个平衡的数据集,同时保留数据的时间依赖性,避免随机删除数据造成的时间信息丢失。

在过采样方法中,采用合成少数类过采样技术(Synthetic minority over-sampling technique, SMOTE)算法^[13],其基本思路是:对于少数类样本,从其最近邻中随机选择一个样本,然后在该样本和随机选的样本之间连线,在该连线上随机选择一个点作为新样本,从而生成新的合成样本并添加到数据集中。通过这种方法,原始数据集中的类别分布得到平衡。

经过滑动窗口欠采样和 SMOTE 算法对故障数据处理后,正常数据和故障数据的比例大约调整为 5:1。其中,正常数据 40 394 条,占比为 83.3%;覆冰数据 8125 条,占比为 16.7%。

1.2.3 数据标准化

本文采用 Z-score 标准化,计算公式如式(1)所示。该方法最大的优点在于其简单、容易计算,Z-score 标准化能够处理不同特征之间的尺度差异,使得每个特征的贡献都能在同一标准下进行评估。Z-score 标准化方法避免了 Min-Max 标准化可能由于数据的极值而导致的过度压缩问题,这对于具有较大波动的工业数据来说尤其重要。此外,Z-score 标准化也更适合用于算法要求数据符合正态分布的场景,如神经网络等模型。因此,通过 Z-score 标准化处理数据集,确保了各特征的均衡性,从而提高了模型训练的效果与稳定性。

$$X' = \frac{X - \mu}{\sigma} \quad (1)$$

式中: X 为原始数据; μ 为数据的均值; σ 为数据的标准差; X' 为标准化后的数据。

2 风机叶片覆冰检测算法

2.1 风机 SCADA 数据集特征工程

2.1.1 共线分析

共线性指的是两个或多个特征之间存在较强的线性相关性,通过共线性分析,可以去除冗余特征。冗余特征不仅可能引入冗余信息,增加模型复杂度,还可能对模型的泛化能力产生负面影响,过多共线性特征会导致模型在训练数据上表现很好,但在测试数据上泛化能力下降,容易过拟合。

本文采用了皮尔森相关系数的方法共线性特

征判断。皮尔森相关系数是一种常见的判断数据间线性相关的系数,记作 ρ ,用来反映两个变量之间的线性相关程度,其中 $-1 \leq \rho \leq 1$, $\rho = 1$ 则表示两变量之间是完全相关的, $\rho = -1$ 则表示两变量之间完全负相关, $\rho = 0$ 则表示两变量之间无关^[14]。

相关系数 ρ 为两个变量 X 、 Y 之间的协方差和标准差乘积的比值,公式如下:

$$\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X \sigma_Y} \quad (2)$$

式中: $\text{cov}(X,Y)$ 分别为 X 和 Y 的协方差; $\sigma_X \sigma_Y$ 分别为 X 和 Y 的标准差; $\rho_{X,Y}$ 为 X 、 Y 之间的皮尔森相关度。

2.1.2 特征筛选

在深度学习任务中,选择对模型检测效果贡献较高的高重要性特征是一项关键步骤,高重要性特征对模型的性能、计算效率和泛化能力都有显著的影响。特别是在风机叶片覆冰检测等应用场景中,合理筛选特征能大幅提高检测准确率,同时降低模型复杂度。本文通过使用轻量级梯度提升机(Light gradient boosting machine, LightGBM)框架计算每个特征的重要性增益,并进一步为每个特征分配一个重要性得分,表征该特征在决策树构建过程中所起的作用。以下是具体的方法和计算流程^[15]。LightGBM根据树模型的分裂结构,使用增益(Gain)作为特征重要性的主要度量指标。某一特征 x_i 的重要性增益定义为:

$$\text{Gain}(x_i) = \sum_{t \in T_i} \left[\frac{G_L(t)^2}{H_L(t) + \lambda} + \frac{G_R(t)^2}{H_R(t) + \lambda} - \frac{G(t)^2}{H(t) + \lambda} \right] \quad (3)$$

式中: T_i 为在模型所有决策树中使用特征 x_i 作为分裂条件的所有分裂节点集合; $G_L(t)$ 和 $G_R(t)$ 分别表示左、右子节点对应样本的梯度累加值; $H_L(t)$ 和 $H_R(t)$ 分别左、右子节点对应样本的二阶梯度累加值; $G(t)$ 和 $H(t)$ 表示当前节点对应样本的梯度与二阶梯度累加值; λ 为正则化系数,用于避免过拟合。

根据重要性增益进一步为每个特征分配一个重要性得分,表征该特征在决策树构建过程中所起的作用。

重要性得分 $\text{Imp}(x_i)$ 的计算式如下:

$$\text{Imp}(x_i) = \sum_{t \in T_i} \text{Gain}_t \quad (4)$$

增益衡量了使用特征 x_i 作为分裂条件后对模型损失函数的优化效果,重要性得分进一步计算特征 x_i 在所有分裂节点上带来的损失减少量(信息增益的总和)。得分越高,说明该特征在提升模型性能方面贡献更大。将所有特征按重要性得分从高到低排序,随后根据需要的特征数量选取重要特征。

SCADA系统记录了风机组在运行过程中产生的大量数据,涵盖了风机的多个运行指标和外部环境条件。数据通常以时间序列的形式存在,因此可以用于时序检测任务。为了准确检测风机叶片的覆冰状态,需要从风机组内外部环境特征中选择与覆冰最相关的特征。根据实际情况和研究需求,选择不同的外部环境特征和风机内部特征。这些特征将作为模型的输入,帮助网络捕捉覆冰发生的时序模式。

2.1.3 特征工程

风力发电机组在运行过程中,叶片结冰会显著改变其物理性能和工作状态,尤其体现在功率和转速等关键特征上,通过分析这些数据特性的变化趋势,能够有效识别结冰状态^[16,17]。但是部分原始特征(如功率)在不同运行状态下的变化较小,难以直接区分正常工况与覆冰工况。若直接使用这些特征,可能导致模型对覆冰状态的敏感度较低,影响检测准确性。因此,为了增强特征的区分能力,需要对原始特征进行转换和构造。首先,观察正常工况下各特征的分布情况,并利用分箱统计法对关键变量之间的关系进行拟合,构建理论基准曲线作为参考标准。随后,计算实际值与基准曲线之间的偏差(残差),并将其作为新特征,以衡量特征的异常程度。通过分析残差的大小及其在时间序列上的波动情况,识别风机运行状态的潜在异常信号,从而为叶片覆冰检测提供有效的数据支撑。

2.2 基于LSTM与注意力机制的叶片覆冰检测算法

2.2.1 LSTM与注意力机制模型搭建

融合长短时记忆网络与注意力机制的故障识别模型如图1所示,该算法充分利用长短时记忆网络(Long short-term memory network, LSTM)在




图1 LSTM-Attention 覆冰检测模型

Fig. 1 LSTM-Attention ice detection model

时间序列分析中的优势,并结合注意力机制增强对关键时间步的关注能力,从而实现对风机叶片覆冰状态的精准检测。模型输入为特征工程后的风机 SCADA 数据,包含风速、功率、发电机转速、温度等多个关键传感器参数,通过 LSTM 有效提取时序特征,并利用注意力机制聚焦于重要时刻,提高覆冰状态的识别精度,从而增强风机运行的安全性和稳定性。

该模型首先通过 LSTM 模块捕获 SCADA 数据的时间序列特征,学习风机叶片在不同时间节点的运行状态。随后,注意力机制自适应地分配不同时间步的权重,增强关键时刻的信息表达能力。最终,这些特征被送入多层感知机(Multi-layer perceptron, MLP)层进行进一步处理,并通过输出层完成叶片覆冰状态的分类。

搭建的风机叶片覆冰检测模型包括特征提取模块、注意力机制模块和检测模块。LSTM 模块由两个 LSTM 层组成,采用堆叠结构,以提取 SCADA 数据的时序信息。LSTM 通过输入门、遗忘门和输出门动态更新时间序列信息。

注意力机制模块对 LSTM 提取的特征进行时间步调整,通过加权分配计算各时间步的重要性,自适应增强关键时间步的表达能力,并抑制无关或冗余信息,以提升模型的判别能力。该模块通过计算 LSTM 输出的注意力权重,引导模型关注对风机叶片覆冰判别更重要的时间信息,从而优化决策能力。

检测模块对 LSTM 和注意力机制处理后的特征进一步提取信息并分类。该模块由 MLP 组成,包含多个全连接层,以学习高维特征表示,并通过非线性激活函数增强模型的表达能力。同时,引入 Dropout 层以减少过拟合,提高泛化能

力。最终,输出层使用 Sigmoid 函数,根据覆冰检测任务的类别数量生成预测结果,实现对风机叶片覆冰状态的准确分类。

2.2.2 模型训练过程

在训练风机叶片覆冰检测模型之前,首先对所有权重进行随机初始化。随后,将预处理后的时间序列数据输入 LSTM 网络,以捕获时间序列数据的长期依赖关系,并提取关键时序特征,生成特征张量。接着,特征张量进入注意力机制模块,该模块通过强化关键特征表达并抑制冗余信息,提高模型的判别能力。经过注意力机制调整后,特征张量被送入检测模块,包括 Flatten 层、Dropout 层和 Dense 层。Flatten 层将高维特征张量展平成一维向量,Dropout 层在训练过程中随机丢弃部分神经元,以增强泛化能力并减少过拟合风险。Dense 层则对提取的特征进行非线性映射,并最终将其输入输出层,实现风机叶片覆冰状态的分类。

覆冰检测模型训练如图 2 所示。

针对于本文的二分类问题,模型所用损失函数为二分类交叉熵损失函数,如下所示^[18]:

$$\text{loss} = -\frac{1}{N} \sum_{i=1}^N \left\{ y_i \log[f(x_i)] + (1 - y_i) \log[1 - f(x_i)] \right\} \quad (5)$$

式中: x_i 为样本输入; y_i 为标签; N 为样本的数量。

针对本文提出的模型,采用 Adam 优化器,其优势在于能自适应调整各参数的学习率,提高收敛速度,并在梯度更新过程中有效抑制振荡,使模型在复杂数据集上表现更加稳定和高效^[19]。此外,为确保模型在合理时间内达到最佳性能,需结合实验结果与数据集特性对学习率及其他超参数




图 2 LSTM-Attention 模型训练过程

Fig. 2 LSTM-Attention model training process

进行动态调整,以平衡训练稳定性和收敛效率,优化风机叶片覆冰检测的准确性和鲁棒性。

2.3 基于双通道时序特征融合网络的叶片覆冰检测算法

为进一步提升覆冰检测的准确度、鲁棒性以及泛化能力,本文提出基于双通道时序特征融合网络的叶片覆冰检测模型(Dual-channel temporal feature fusion network,DTFF-Net)模型。该模型采用两个LSTM结构,分别提取外部环境和风

机内部的时序特征,并结合多头注意力机制,在时间序列层面精准捕捉不同通道之间的依赖关系,实现特征的交互与融合。该方法使模型能够动态识别外部环境 with 内部特征的复杂关联,有效提升覆冰检测性能。模型结构如图 3 所示。

将预处理后的数据进行特征筛选,并将选定的外部环境特征和风机内部特征将分别输入到图 3 中的双通道时序特征融合网络的两个通道。外部环境特征通道将输入 4 个外部环境相关特征数据,内部风机特征通道则输入 4 个风机内部特征数据。每个通道的特征数据将传入 LSTM 层,进行时序建模与特征提取。LSTM 网络能够捕捉这些特征随时间变化的动态模式,学习到特征之间的时序依赖,并提取与风机叶片覆冰状态相关的时序信息。

采用多头注意力机制对来自两个通道的时序特征进行融合。多头注意力机制能够通过多个注意力头对不同的特征子空间进行加权处理,从而使网络能够捕捉到更加丰富的特征信息。在这一阶段,外部环境特征通道和内部风机特征通道的 LSTM 输出将被输入到多头注意力层。通过这种机制,网络能自动识别各个特征的相关性并加权融合,进而提升对风机叶片覆冰状态的检测精度。多头注意力机制的优势在于,它能处理不同特征之间的复杂关系,并使模型在不同特征子空间中学习到不同的关注点,从而为后续的检测任务提供更加全面的特征信息。




图 3 双通道时序特征融合网络检测模型

Fig. 3 Dual channel temporal feature fusion network detection model

经过多头注意力机制融合后的特征通过全连接层进行处理,并最终进行检测。经过特征融合后的数据将被传递至全连接层,进行非线性映射,以进一步提取高层次的特征表示。全连接层的作用是将各通道和注意力机制提取的特征综合考虑,并输出一个最终的检测结果。通过这种方式,模型能综合考虑外部环境因素与内部风机状态之间的复杂关系,精准检测风机叶片是否发生覆冰现象。最终的输出可以是一个二分类或回归值,表示风机叶片覆冰的概率或严重程度,从而为风机的覆冰决策提供依据。

针对于本文的二分类问题,模型所用损失函数为二分类交叉熵损失函数,如下所示:

$$\text{loss} = -\frac{1}{N} \sum_{i=1}^N \left\{ y_i \log \left[f_{\text{DTFF-Net}}(x_i) + (1 - y_i) \log (1 - f_{\text{DTFF-Net}}(x_i)) \right] \right\} \quad (6)$$

3 实验设置与结果分析

3.1 实验设置与评价指标

模型超参数设置如表1所示。

操作系统采用 Ubuntu 20.04.3, 计算设备配备 NVIDIA AGTX 1080Ti GPU, 并使用 CUDA 11.1 版本加速模型训练。深度学习框架选用 TensorFlow 2.2.0, 以提供高效的计算支持。

采用准确率 Accuracy、精确率 Precision、召回率 Recall、F1 分数 F1-score、评价算法性能。其中, Accuracy 评价算法总体正确判断次数占总判断次数的比例, 可以综合评价算法准确区分正常状态和覆冰状态的能力。Precision 可以评价检测的准确程度, Recall 可以评价检测的全面性, F1-score 可以综合评价算法的精确率和召回率。上述指标的计算如下:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (7)$$

表1 模型超参数设置

Table 1 Model hyperparameter Settings

参数	值
Batch size	12
学习率	0.001
Epoch	100
Dropout	0.2
优化器	Adam

$$\text{Recall} = \frac{TP}{TP + FN} \quad (8)$$

$$\text{F1-score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (9)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (10)$$

式中: TP 是准确识别的正类样本; FP 是错误识别的正类样本; TN 是准确识别的负类样本; FN 是错误识别的负类样本。

此外, ROC 曲线是衡量机器学习模型可靠性的重要指标, 曲线下面积 (Area under curve, AUC) 越大, 模型的稳定性和区分能力越强。

3.2 特征工程实验结果

SCADA 数据集中具有 26 个变量, 特征维度为 26 维, 目标为风机是否覆冰, 对 26 个特征变量分别计算皮尔森相关系数, 得到结果如图 4 所示, 当 $\rho_{X,Y} > 0.7$ 时, 认为 X 和 Y 之间存在较强共线性。剔除共线性较高的特征, 降低数据的冗余性。

根据共线性分析, 并进一步根据特征的重要性分数对剩余特征进行排序, 并从中选取最具影响力的特征。具体来说, 首先将所有的环境特征和风机特征按照其重要性分数进行降序排列。然后, 分别选取环境特征和风机特征中的重要特征。这样, 确保输入到模型中的特征具有最高的检测能力, 从而提升模型的准确性和效率。同时, 通过特征选择方法, 有助于减少过拟合, 提高模型的泛化能力。具体选择结果如表 2 所示。

可以看出权重占比最大的前 4 个环境特征为环境温度、风速、对风角、平均风向角; 权重占比最大的前 4 个风机特征为发电机转速、有功功率、变桨电机的温度、x 方向加速度。结果符合本文对风机叶片覆冰机理模型分析。因此, 本文选用这 8 种特征进行后续模型训练。

根据共线性分析, 并进一步根据特征的重要性分数对剩余特征进行排序, 并从中选取最具影响力的特征。具体来说, 首先将所有的环境特征和风机特征按照其重要性分数进行降序排列。然后, 分别选取环境特征和风机特征中的重要特征。这样, 确保输入到模型中的特征具有最高的检测能力, 从而提升模型的准确性和效率。同时, 通过特征选择方法, 有助于减少过拟合, 提高模型的泛化能力。具体选择结果如表 2 所示。

可以看出权重占比最大的前 4 个环境特征为




图 4 共线性特征分析

Fig. 4 Collinear feature analysis

表 2 风机和环境特征选择

Table 2 Fan and environment feature selection			
环境特征	权重	风机特征	权重
环境温度	0.163	发电机转速	0.160
风俗	0.160	有功功率	0.156
风向角	0.156	变桨电机温度 1	0.136
平均风向角	0.136	X 方向加速度	0.070

环境温度、风速、对风角、平均风向角;权重占比最大的前 4 个风机特征为发电机转速、有功功率、变桨电机的温度、x 方向加速度。结果符合本文对风机叶片覆冰机理模型分析。因此,本文选用这 8 种特征进行后续的训练。

风力发电机组的输出功率是其运行状态的关键指标叶片结冰会改变叶片的气动特性,使得能量转换效率降低,从而引起功率的异常波动,但由于叶片结冰导致的气动特性变化通常较为微弱,使得直接使用功率特征难以精准识别覆冰状态。在原始功率数据中,结冰状态下的功率偏离正常工况,但数据之间的差距较小,难以形成明显的区分特征,如图 5 所示。因此,为了增强功率特征的




图 5 风速-功率散点图

Fig. 5 Wind speed - power scatter plot

表征能力,采用分箱统计法对风速-功率关系进行拟合,构建理论功率基准曲线,如图 6 所示,并基于该基准计算功率残差,即实际功率与拟合功率的偏差。与原始功率特征相比,功率残差能够更直观地反映结冰导致的能量转换异常,且在时间序列上的波动更为显著,使其成为识别叶片结冰状态的重要特征。通过引入功率残差特征,模型的区分能力得到了明显提升,提高了风机叶片覆冰检测的准确性。

风力发电机组的转速同样受到结冰的直接影响,与功率的变化趋势类似。叶片结冰导致其气动效率下降,导致机组转速偏离正常工况,且这种偏离幅度通常较小,难以直接通过原始转速特征进行有效识别,如图7所示。因此,为了增强转速特征的区分能力,采用分箱统计法拟合风速—转速关系,构建理论转速基准曲线,如图8所示,并计算转速残差(即实际转速与基准转速的偏差)。与直接使用原始转速相比,转速残差能够更敏感地捕捉因为覆冰导致的异常变化,尤其是在时间序列上的波动更为明显,从而提升叶片覆冰状态




图6 风速-功率拟合曲线

Fig. 6 Wind speed - power fitting curve




图7 风速-发电机转速散点图

Fig. 7 Wind speed - generator speed scatter plot




图8 风速-发电机转速拟合曲线

Fig. 8 Wind speed - generator speed fitting curve

的检测能力,提高模型对微小覆冰特征的感知能力。

结合上述两项关键特性,功率残差和转速残差可以分别代替功率和转速特征作为后续模型的输入。

3.3 覆冰检测模型实验结果

对 LSTM-Attention 覆冰检测模型训练集和验证集的损失情况进行评估,观察损失函数的变化趋势,以分析模型的收敛情况。图9展示了 LSTM-Attention 覆冰检测模型训练过程中训练集和验证集的损失变化曲线。

在前40个轮次内,训练损失下降速度较快,表明模型在早期有效地学习了特征。但是40轮次后波动较大,表明泛化能力较弱。总的来说,随着训练轮次的增加,训练损失逐步下降并趋于稳定,表明模型在训练集上不断优化,成功学习到数据模式。然而,验证损失在初期下降后,随着训练的进行出现较大波动,并未持续降低,说明模型的泛化能力可能受到限制。

图10对比了DTFF-Net分类模型特征数量对模型准确率的影响,可以看出,准确率随着特征




图9 LSTM-Attention训练集和验证集 loss 变化

Fig. 9 LSTM-Attention loss changes in training sets and validation sets




图10 DTFF-Net特征数量对模型准确率影响

Fig. 10 Effect of DTFF-Net feature number on model accuracy

数量的增加先上升后下降,呈现出先提升后衰减的趋势。特征数量小于8时,DTFF-Net分类模型的准确率随着特征的增加而提升;特征数量达到8时,准确度最高,达到89%;特征数量超过8后,准确率随着特征数量增加反而下降。这表明,在有效信息增加时,模型能获取更多分类信息,从而提升性能,而无效信息的增加则可能干扰分类效果。最终,根据DTFF-Net模型的特征重要性排序,选择权重占比最高的4个风机特征和环境特征。

如图11所示,选用8个特征进行特征嵌入,训练损失在训练过程中逐步下降,表现出较好的收敛趋势。在前40个轮次内,损失下降速度较快,模型在早期有效地学习了特征。随着批次的增加,训练损失的下降速度逐渐减缓,并在大约80个批次后趋于稳定,说明模型已基本收敛,进一步训练对损失的改善较为有限。DTFF-Net模型验证损失整体下降趋势较稳定,波动较小,泛化能力有显著提升。

如图12所示,两种模型的准确率都随着训练轮次的增加而上升,表明模型在不断学习数据模

式,并逐步提高检测能力。DTFF-Net的最终准确率高出 LSTM+Attention,说明该模型在学习过程中具有更好的收敛性和特征提取能力表明其在特征提取和学习能力上更优。同时,DTFF-Net训练后期更加稳定,说明该模型在优化过程中具有更好的鲁棒性,避免了过度拟合或梯度震荡。

3.4 算法对比与分析

为了验证所提出的DTFF-Net检测模型的综合性能,将所提出的DTFF-Net检测模型分别与SVM模型^[20]、LSTM模型^[21]、XGBoost模型^[12]以及LSTM+Attention模型进行对比。不同分类模型效果的对比实验结果如表3所示。

表 3 对比实验结果

Table 3 Comparative experimental results				
模型名称	准确率	精确率	召回率	F1值
XGBoost	0.749	0.713	0.702	0.707
LSTM	0.751	0.738	0.748	0.743
SVM	0.758	0.764	0.784	0.774
LSTM+Attention	0.853	0.819	0.829	0.824
DTFF-Net	0.894	0.867	0.864	0.866

LSTM+Attention模型准确率达到85.3%,精确率达到81.9%,召回率达到82.9%,F1值达到了82.4%,相较于其他3个算法准确率提升了10%左右,其他3种指标也提升了5%~10%,说明注意力机制增强了模型对关键特征的关注,提高了检测精度。DTFF-Net模型的准确率达到89.4%,精确率达到86.7%,召回率达到86.4%,F1值达到了86.6%,各指标比LSTM+Attention模型提高了5%左右,说明DTFF-Net模型能分开处理不同类型的数据,提高模型对风机特征和环境特征的理解能力,并用多头注意力提升特征交互与融合能力,将环境特征和风机特征的时间序列信息结合,进一步提升检测效果。

图13为DTFF-Net算法与其他算法的ROC曲线比较。对比不同算法的AUC,LSTM+Attention明显优于3种算法,说明注意力机制提升了LSTM的检测能力,但仍逊色于DTFF-Net。DTFF-Net模型的表现最优,曲线接近左上角,表明在不同阈值下具有最高的TPR和最低的FPR,说明检测能力最强,误报最少。




图 11 DTFF-Net训练集和验证集 loss 变化
Fig. 11 DTFF-Net loss changes in training sets and validation sets




图 12 算法准确度对比
Fig. 12 Comparison of algorithm accuracy




图 13 不同算法的 ROC 曲线比较

Fig. 13 Comparison of ROC curves of different algorithms

3.5 消融实验分析

为进一步验证本文所提出的 DTFF-Net 模型中各关键结构对整体性能的贡献,设计了消融实验,对模型中的核心模块——双通道结构(Dual-channel)、多头注意力机制(Multi-head attention)和特征残差设计进行逐一剔除或替代,评估各模块对叶片覆冰检测性能的影响。

3.5.1 消融模型设计

构建以下模型变体,逐步剔除 DTFF-Net 的

关键模块,如表 4 所示。

3.5.2 消融实验结果

消融实验结果如表 5 所示。

双通道结构的贡献(D2对比D1):移除风机与环境特征分通道建模结构后,准确率下降了 3.9 个百分点,表明分通道处理可以更好地捕捉不同类别特征间的独立动态模式,提高模型表达能力;注意力机制的贡献(D3对比D1):多头注意力机制对特征融合起到重要作用,其移除导致性能下降约 4.6%,说明注意力机制能增强模型对关键特征之间交互的感知能力;残差特征设计的重要性(D4对比D1):不使用风速-功率/转速残差后,模型性能下降最为明显,F1 值下降超过 7 个百分点,验证了残差特征对揭示叶片异常(如覆冰)状态具有重要的增强作用。

DTFF-Net 模型中的双通道建模结构、残差特征设计以及注意力机制三者 in 模型性能中均起到不可替代的作用,缺失任一部分都将导致检测精度下降。整体消融实验充分验证了本文模型结构设计的合理性与有效性,为实际风电场的叶片覆冰监测提供了结构优化依据。

表 4 消融实验模型

Table 4 Models for ablation experiments

模型编号	模型名称	修改内容说明
D1	完整 DTFF-Net	保留双通道、残差特征、多头注意力模块
D2	w/o Dual-Channel	将风机与环境特征合并输入单通道 LSTM,移除通道区分建模结构
D3	w/o Attention	移除多头注意力模块,改为简单连接融合两通道输出特征
D4	w/o Residual Input	不使用风速-功率残差和风速-转速残差,直接使用原始功率和转速特征

表 5 消融实验结果

Table 5 Results of ablation experiments %

模型编号	准确率	精确率	召回率	F1 值
D1	89.4	86.7	86.4	86.6
D2	85.5	82.3	81.6	81.9
D3	84.8	81.9	80.7	81.3
D4	82.9	80.2	78.5	79.3

4 结束语

围绕风机叶片覆冰检测问题,本文构建了高效、精准的覆冰检测框架,提出基于双通道时序特征融合网络的叶片覆冰检测算法,为风机运行状态监测和智能化运维提供了技术支持。

首先,本文对风机 SCADA 数据进行了数据预处理和特征工程,包括缺失值处理、数据不平衡

处理、数据标准化、特征筛选、特征转换等。通过共线性分析与特征重要性评估,筛选出与叶片覆冰状态高度相关的特征,并采用分箱统计法构建理论基准曲线,以计算特征残差,提高对异常状态的识别能力。

在模型构建方面,本文基于 LSTM 和注意力机制构建了一种基本的覆冰检测模型,该模型利用 LSTM 提取风机时序特征,并通过注意力机制增强关键时间步的关注度,以提高模型对覆冰状态变化的感知能力。实验结果表明,该方法在一定程度上提升了检测精度,但在特征建模方面仍存在一定局限,尤其是在处理风机内部状态与外部环境变量的复杂关系时,表现仍有不足。

针对上述问题,本文提出了双通道时序特征

融合网络(DTFF-Net),分别对风机内部运行特征和外部环境特征进行建模。该模型采用双通道LSTM提取不同类别的时序特征,并通过多头注意力机制进行特征融合,以增强模型对关键特征的关注能力。实验结果表明,与单通道LSTM+注意力机制相比,DTFF-Net在检测准确率和稳定性方面均有显著提升,能够更精准地识别叶片覆冰状态,为智能风机运维提供了可靠的技术支持。

然而,当前的模型泛化性不足,对于一些极端天气条件或突发故障情况下的检测能力尚需提升。未来可以通过引入更多的环境参数和多种传感器信息,增强模型在不同气候条件下的适应性。同时,如何提高模型的实时计算效率,使其能适应风电场的实时监控需求,仍是下一步需要解决的关键问题。未来仍需优化算法和硬件加速技术,有助于实现实时、动态的叶片覆冰预警。

参考文献:

- [1] 柯坚. 碳达峰碳中和战略的法治回应[J]. 河北大学学报: 哲学社会科学版, 2025, 50(1): 123-124.
Ke Jian. The rule of law response to the Carbon Peak Carbon neutral strategy[J]. Journal of Hebei University (Philosophy and Social Science), 2025, 50(1): 123-124.
- [2] 安祥飞, 楚延锋. 风力发电机叶片防覆冰涂层研究进展[J]. 河南科技, 2024, 51(15): 76-80.
An Xiang-fei, Chu Yan-feng. Research progress in anti-icing coating for wind turbine blades[J]. Henan Science and Technology, 2024, 51(15): 76-80.
- [3] 余思锐, 宋孟杰, 沈俊, 等. 低温静止与运动表面结冰特性预测技术研究进展[J]. 哈尔滨工业大学学报, 2024, 56(10): 150-168.
Yu Si-rui, Song Meng-jie, Shen Jun, et al. Research progress on icing characteristic prediction technologies for low temperature stationary and moving surfaces[J]. Journal of Harbin Institute of Technology, 2024, 56(10): 150-168.
- [4] Pérez J M P, Márquez F P G, Hernández D R. Economic viability analysis for icing blades detection in wind turbines[J]. Journal of Cleaner Production, 2016, 135: 1150-1160.
- [5] Jiang G Q, Yue R X, He Q, et al. Imbalanced learning for wind turbine blade icing detection via spatio-temporal attention model with a self-adaptive weight loss function[J]. Expert Systems with Applications, 2023, 229: 120428.
- [6] Guo J C, Song X W, Tang S F, et al. Fault diagnosis of wind turbine blade icing based on feature engineering and the PSO-ConvLSTM-transformer[J]. Ocean Engineering, 2024, 302: 117726.
- [7] 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.
- [8] Chen W H, Cheng L S, Chang Z P, et al. Wind turbine blade icing detection using a novel bidirectional gated recurrent unit with temporal pattern attention and improved coot optimization algorithm[J]. Measurement Science and Technology, 2023, 34(1): 014004.
- [9] Jiang G Q, Li W Y, Bai J R, et al. SCADA data-driven blade icing detection for wind turbines: an enhanced spatio-temporal feature learning approach[J]. Measurement Science and Technology, 2023, 34(5): 054004.
- [10] Wang L, He Y G, Zhou Y Z, et al. A novel approach to wind turbine blade icing detection with limited sensor data via spatiotemporal attention Siamese network[J]. IEEE Transactions on Industrial Informatics, 2024, 20(6): 8993-9005.
- [11] 张好雨. 基于SCADA数据的风机叶片覆冰故障检测与预测[D]. 北京: 北京交通大学机械与电子控制工程学院, 2022.
Zhang Hao-yu. Detection and prediction of wind turbine blade icing fault based on SCADA data[D]. Beijing: College of Mechanical and Electronic Control Engineering, Beijing Jiaotong University, 2022.
- [12] 单锐, 杨婧, 朱文元, 等. 不同缺失比例下的缺失值插补方法比较[J]. 信息技术, 2023 (12): 52-56.
Shan Rui, Yang Jing, Zhu Wen-yuan, et al. Comparison of missing value interpolation methods under different missing ratios[J]. Information Technology, 2023 (12): 52-56.
- [13] Chawla N V, Bowyer K W, Hall L O, et al. SMOTE: synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16: 321-357.
- [14] Puth M T, Neuhauser M, Ruxton G D. Effective use of Pearson's product-moment correlation coefficient

- cient[J]. *Animal Behaviour*, 2014, 93: 183-189.
- [15] Ke G L, Meng Q, Finley T, et al. Lightgbm: a highly efficient gradient boosting decision tree[C] // NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems, New Orleans, USA, 2017.
- [16] Parent O, Ilinca A. Anti-icing and de-icing techniques for wind turbines: Critical review[J]. *Cold Regions Science and Technology*, 2011, 65(1): 88-96.
- [17] Skrimpas G A, Kleani K, Mijatovic N, et al. Detection of icing on wind turbine blades by means of vibration and power curve analysis[J]. *Wind Energy*, 2016, 19(10): 1819-1832.
- [18] 胡梦婷, 罗晨. 基于MCNN-LSTM和交叉熵损失函数的轴承故障诊断[J]. *制造技术与机床*, 2024, (9): 16-22.
- Hu Meng-ting, Luo Chen. Bearing fault diagnosis based on MCNN-LSTM and cross entropy loss function[J]. *Manufacturing Technology & Machine Tool*, 2024 (9): 16-22.
- [19] Zhang Y, Xing K S, Bai R X, et al. An enhanced convolutional neural network for bearing fault diagnosis based on time-frequency image[J]. *Measurement*, 2020, 157: 107667.
- [20] Chandra M A, Bedi S S. Survey on SVM and their application in image classification[J]. *International Journal of Information Technology*, 2021, 13(5): 1-11.
- [21] Choe D E, Kim H C, Kim M H. Sequence-based modeling of deep learning with LSTM and GRU networks for structural damage detection of floating offshore wind turbine blades[J]. *Renewable Energy*, 2021, 174: 218-235.
- [22] Lin L J, Liang Y C, Liu L, et al. Estimating PM_{2.5} concentrations using the machine learning RF-XGBoost model in guanzhong urban agglomeration China [J]. *Remote Sensing*, 2022, 14(20): 14205239.