

毫米波雷达风力机叶片覆冰检测方法

张自豪, 王志春

(内蒙古科技大学自动化与电气工程学院, 内蒙古 包头 014010)

摘要: 风能作为可再生能源, 凭借其可靠性和成本优势成为新能源领域的主要竞争者。在气候寒冷的高湿度地区, 叶片结冰对风力机性能和耐久性构成严重威胁。基于雷达的材料检测技术因其具有可穿透非极化材料以及不受光照和天气影响的传感能力, 可以提供表面状态及深入信息, 近年来备受关注。文中提出使用 77 GHz 毫米波雷达实时检测风机叶片覆冰状态的方法, 从原始中频信号提取梅尔频率倒谱系数(Mel-frequency cepstral coefficient, MFCC)融合一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)对叶片覆冰类型进行分类识别。通过实验在可控距离和方向变化中验证文中所提方法的有效性。实验结果表明, 该方法可以精准识别 4 种覆冰类型及不同厚度覆冰, 识别率可达 94%, 且在风力发电机叶片覆光滑薄冰阶段即可识别, 进行预警。

关键词: 风能; 毫米波雷达; 一维卷积神经网络(1D-CNN); 梅尔频率倒谱系数(MFCC); 叶片覆冰; 分类识别

中图分类号: TM614; TP183

文献标志码: A

文章编号: 2096-3203(2025)05-0079-11

0 引言

近年来, 随着清洁能源的需求逐渐增大, 国内风力发电机的装载数量稳步增加^[1]。风力发电机组的设计功率及装机机身高度不断提高, 冬季风力机叶片运行时极易接触到较低的云层, 在低温和高湿度的环境下叶片会出现覆冰覆雪现象^[2-4]。风力发电机叶片上冰的形成和积聚会改变叶片空气动力学特性, 其阻力显著增加而升力减小, 进而产生不必要的性能损失, 且可能损伤风机的整体结构, 减少风机寿命^[5]。其中, 覆冰种类主要分为明冰、混合冰、雾凇^[6], 不同的覆冰类型具有不同的附着能力、湿度及冰层密度。明冰是液滴流动覆冰形成的光滑透明高密度积冰, 含水量高、附着力强; 混合冰是含水量、温度变化形成的高密度不透明白色积冰, 附着力较强; 雾凇是雪花状薄冰, 含水量低, 附着能力弱。

叶片覆冰会导致机组静态与动态载荷不平衡、振动剧烈、疲劳载荷增加, 并可能造成人身危害等^[7]。

对风力发电机结构进行健康监测、表征和评估一直是热门研究方向, 一些最新进展可用于表征其结构健康状况、嵌入式缺陷^[8]。文献[9]基于两台风机运行数据, 利用三重训练和卷积神经网络改进风机叶片结冰检测方法。文献[10]基于图像处理的风力发电机叶片覆冰检测方法, 实现对覆冰区域的估计。文献[11]使用调频连续波雷达区分不同

类型复合材料及检测表面缺陷。文献[12]将超声波传感器用于复合材料结构的结冰检测, 根据导波信号的变化表征冰的严重程度。

过去十年中, 高频雷达成像被尝试用于许多工业现场的故障诊断、安全检测中^[13]。其中, 微波、毫米波频率范围内的雷达得到深入研究, 并被用于纤维复合材料的无损检测^[14-15]。毫米波雷达在生活以及医疗中的应用也极为广泛, 如人体活动识别^[16-17]、生命体征识别^[18-19]、跨环境场景下物体识别^[20-21]及静态材料识别^[22]。

由于风机叶片表面多种覆冰类型具有不同的介电常数、含水量等, 毫米波雷达发射信号照射至叶片表面与回波信号进行混频得到中频信号, 不同覆冰类型的中频信号具有不同的特性, 对中频时序信号进行预处理, 得到丰富的频谱信息, 并提取出梅尔频率倒谱系数(Mel-frequency cepstral coefficient, MFCC)作为特征数据融合一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)执行分类识别任务。

文献[23]基于遗传算法优化支持向量机的铁路隧道衬砌掉块声音检测方法, 提取发生事件的MFCC特征, 验证了声信号技术在铁路隧道衬砌掉块检测中的可行性。文献[24]提出一种基于MFCC和伽马通频率倒谱系数(Gammatone filter cepstral coefficient, GFCC)特征的声纹识别方法, 识别局部放电超声信号, 诊断电力设备缺陷。文献[25]基于MFCC结合隐马尔可夫模型的声音信号机器学习方法, 识别微细铣削过程中的加工状态异常。由此可见, 从不同缺陷状态下的非平稳时域信号中提取

收稿日期: 2025-01-05; 修回日期: 2025-03-12

基金项目: 内蒙古自治区自然科学基金资助项目(2024LHMS 06020); 内蒙古自治区科技计划资助项目(2020GG0157)

MFCC, 结合深度学习方法可以对不同缺陷类型进行检测识别。

文中提出一种使用毫米波雷达中频信号, 提取 MFCC 融合 1D-CNN 实现风机叶片覆冰检测的方法。使用该技术的优点为: (1) 不需要耦合剂且允许穿透大多数非金属和非极化材料; (2) 不受光照天气影响。基于上述优点, 文中采用 77 GHz 调频连续波 (frequency modulated continuous wave, FMCW) 雷达采集不同覆冰类型回波信号, 结合深度学习算法实现对风力发电机叶片的覆冰检测。首先采用 IWR1843 雷达板进行不同叶片覆冰类型的原始数据采集, 并进行数据预处理及可视化; 结合 MFCC 作为数据特征, 采用不同深度学习模型进行对比, 实现叶片覆冰状态的判别及覆冰类型的分类。

1 基于毫米波雷达的风机叶片覆冰检测

1.1 FMCW 雷达覆冰检测原理

77 GHz 毫米波雷达采用线性频率调制产生连续变频电磁信号, 向风机叶片发射。

在 FMCW 信号模式中, 设置起始频率为 f_c , 带宽为 B , 一个啁啾信号周期 T_{chirp} 中的线性调频斜率为 S , 波形发生器生成如图 1 所示的向上锯齿波用于调制信号频率^[26], 其中 $S_{\text{Tx}}(t)$ 、 $S_{\text{Rx}}(t)$ 分别为 t 时刻发射和接收信号; t_d 为时延; F_{If} 为中频信号频率。图 1 中, 一个啁啾信号周期 T_{chirp} 内的发射信号可用式(1)表示。




图 1 FMCW 信号

Fig.1 FMCW signal pattern

$$S_{\text{Tx}}(t) = A_{\text{T}} \cos \left(2\pi f_c t + \pi \frac{B}{T_{\text{chirp}}} t^2 \right) \quad (1)$$

式中: A_{T} 为发射信号幅度。

假设目标物体与雷达的距离为 d , 光速为 c , 则时延为:

$$t_d = \frac{2d}{c} \quad (2)$$

回波信号传播时间 t_d 后被接收天线捕获, 与发射信号相比, 其幅度会衰减, 并与距离 d 及物体的雷达横截面成正比。接收信号表示为:

$$S_{\text{Rx}}(t) = A_{\text{R}} \cos \left(2\pi f_c (t - t_d) + \pi \frac{B}{T_{\text{chirp}}} (t - t_d)^2 \right) \quad (3)$$

式中: A_{R} 为接收信号幅度。

接收信号与发射信号混频后, 经低通滤波器处理得到中频信号, 中频信号可表示为:

$$S_{\text{IF}}(t) = A_{\text{T}} A_{\text{R}} e^{j(2\pi F_{\text{If}} t + \phi(t))} \quad (4)$$

式中: $\phi(t)$ 为中频信号相位, 表达式见式(5)。

$$\phi(t) = 2\pi f_c t_d + \pi S t_d^2 \approx 2\pi f_c t_d \quad (5)$$

其中 t_d^2 无穷小, 故忽略不计。

中频信号频率 F_{If} 表达式为:

$$F_{\text{If}} = \frac{2Bd}{T_{\text{chirp}} c} \quad (6)$$

中频时域信号可以表征被测目标的表面散射特性, 以及被测目标的距离与速度。

当被测物体的材质、大小、厚度、形状不同时, 电磁波的散射系数不同, 回波强度具有差异^[27]。同时毫米波雷达的接收信号是雷达信号照射范围内被测物体产生回波信号的总和。将雷达照射范围划分成 $I \times J$ 个小区域, 雷达中频信号可以看作若干离散小区域的中频信号加和。对于不同的被测对象, 每个小区域中雷达信号的入射角不同, 其回波分量的幅度也不同。图 2 为雷达照射范围内中频信息示意图, 其中 R 为传感器与目标的距离。




图 2 雷达照射范围

Fig.2 Radar exposure range

雷达接收到的所有离散小区域加和的中频信号为:

$$X(n) = \sum_{i=1}^I \sum_{j=1}^J A_{ij} X_{ij}(t) \quad (7)$$

式中: n 为信号采样点序号; A_{ij} 为第 $i \times j$ 个小区域的回波强度; $X_{ij}(t)$ 第 $i \times j$ 个小区域的时域回波信号。

对于不同的被测对象, 每个小区域的形状、粗糙度和位置差异会造成雷达信号的入射角不同, 从而导致回波分量的幅度不同。因此, 回波信号的时域信号因被测物体的信息不同而千差万别。

叶片干表面回波幅度大, 覆雪表面回波幅度小, 从而产生不同程度的幅度差别和频率偏移。接收天线同时接收发射参考信号和表面反射回来的目标信号。利用数字互相关技术进行混频, 提取两个信号之间的微小频率差信号, 形成中频信号, 其幅度与表面特征相关。

中频信号经过模数转换, 以数字数据的形式保存回波信息。由于多帧毫米波雷达数据量大, 直接送入模型训练会带来大量的噪声干扰, 且占用大量内存, 因此可以先进行特征提取, 再使用深度学习方法对数据进行分类。目前, 在利用雷达数据实现分类的研究中, 大多通过处理雷达数据得到雷达特征图, 如多普勒图、快速傅里叶变换(fast Fourier transform, FFT)频谱图等, 并采用图像深度学习模型进行图像训练进而实现分类。文中提出采用中频信号时域数据进行 MFCC 特征提取, 并采用深度学习模型实现风机叶片不同覆冰类型的分类识别, 系统流程如图 3 所示。




图 3 风机叶片覆冰检测系统流程
Fig.3 Flow chart of wind turbine blade icing detection system

1.2 实验平台搭建及信号采集

实验平台包含数据采集平台与被采集对象。由于实验条件受限, 实验采用模拟环境条件下的风力机叶片覆冰采集数据。硬件采用 IWR1843 雷达板件搭配 DCA1000 数据采集板进行数据采集存储。该雷达板具有 3 个发射天线和 4 个接收天线, 最多支持 12 通道的数据采集, 具有复杂的基带混

频器、模数转换器(analog-to-digital converter, ADC)及数字信号处理器(digital signal processor, DSP)^[28]。通过数据采集板可以将大批量的原始中频回波信号以二进制的形式实时存储至用户端。

基于德州仪器公司 RttNetClientAPI.dll 动态链接库进行二次开发, 实现毫米波雷达板参数的自主设置和自动化大批量原始数据采集, 并基于此功能创建面向用户的界面, 设计出数据采集功能模块、数据解析模块、分类及数据集补充模块。二次开发具体流程如图 4 所示。采用此方法对雷达板进行初始化设置、雷达参数配置及连续数据采集, 实现庞大样本数据的自动循环采集及实时存储功能, 以便于后续的数据处理及分析。雷达具体参数配置见表 1。




图 4 动态链接库二次开发流程
Fig.4 Dynamic link library secondary development process

表 1 雷达参数
Table 1 Radar parameters

参数名称	数值
起始频率/GHz	77
采样率/kHz	10 000
调频斜率/(MHz · μs ⁻¹)	30.030
带宽/MHz	3 903.9
脉冲持续时间/μs	130
啁啾采样点数	512
帧数	8
每帧啁啾数	128
发射天线根数	1
接收天线根数	4

使用可遥控四轮驱动车负载风力发电机截断

叶片作为采集对象,进行不同角度、速度、位置的往返相对运动;被测对象为1 m×1.5 m尺寸且具有一定弯曲的非平板风力发电机截断叶片。在-15 ℃的自然环境中,小车运动范围为3~6 m。整体模拟实验场景中包含抖动及背景噪声,还原了真实无人机飞行器搭载检测过程中存在的影响因素。图5为实验模拟环境。

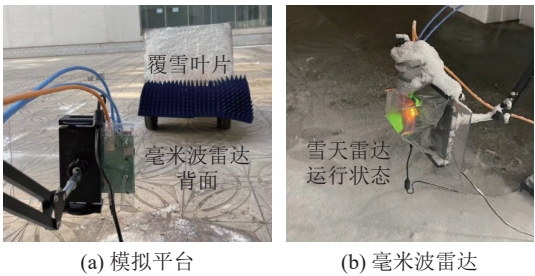


图5 实验模拟环境
Fig.5 Experimental simulation environment

2 叶片覆冰类型分类识别系统

2.1 雷达信号分析

采用 MATLAB 对毫米波雷达采集的二进制编码数据进行解析。由于采用单发四收结构,会获得4条接收通道的数据。根据雷达系统参数配置可知,每个信号发射-采集循环中会获取8帧回波信号,且每帧包含128个调频脉冲,每个脉冲中的数字信号取样点数为512。此次实验提取四通道均值数据,包含的数字信号总量为 $8 \times 128 \times 512$,单样本数据格式可见图6。




图6 原始数据格式
Fig.6 Raw data format

针对上文提出的几种类型覆冰在自然环境下进行模拟结冰实验。实验数据集构建于内蒙古包头市12月下雪季,受条件限制,实验缺乏大型风洞实验平台,因此在-15 ℃的条件下采用人工喷水雾重复结冰方法,形成不同含水量、密度、光滑度的冰雪类型,分为明冰、雪凇冰及混合冰。分别在不同位置、时间、倾斜角度和光照条件下,为每一种覆冰类型采集600组原始样本。

覆冰类型包含:干表面、2 mm 光滑明冰表面、3 cm 混合冰表面、1 cm 雪凇表面以及3 cm 雪凇表面。为增强数据泛化能力,在构建叶片覆冰数据集时,训练集采用小车运动过程的数据,而测试集则混合小车运动过程与小车静止过程的数据。小车静态叶片覆冰状态如图7所示,动态叶片覆冰状态如图8所示。




图7 静态风电机组叶片覆冰
Fig.7 Static wind turbine blade icing




图8 动态风电机组叶片覆冰
Fig.8 Dynamic wind turbine blade icing

图9为5类覆冰样本原始数据可视化。读取二进制数据文件样本时,将原始数字信号解析并分割为4条接收通道对应的多帧数据。对其进行均值处理后提取单接收通道数据,并导出为csv文件,作为数据集的单样本以用于后续分类任务。

2.2 特征提取

文中采用 MFCC 进行特征提取。尽管 MFCC 通常用于语音信号分类,但由于语音信号和毫米波




图9 原始数据可视化

Fig.9 Raw data visualization

雷达信号同为调频信号,二者具有相似特性。

MFCC 通过梅尔滤波模拟人耳对频率的敏感性,从而提取出更具代表性的频谱特征,这些特征在后续分类任务中更容易被分辨和处理^[29-30]。此外, MFCC 特征专注于描述信号质量特性,具有一定的鲁棒性;相比直接使用时域或频域信号, MFCC 特征可以更好地体现目标物体的频率反射特性,有利于后续识别和分类任务^[31-32]。MFCC 在毫米波雷达特征提取方面的应用在国内暂无报道,而在此次实验研究中利用该方法对风力机叶片覆冰进行检测得到了较好的准确率。计算 MFCC 的步骤如下。

(1) 预加重。反向散射信号通过滤波器增强高频信号,这个过程将增加更高频率信号的能量,从而降低信号传输中高频损失的影响,其本质为一阶差分:

$$X(n) = X_s[n] - \alpha X_s[n-1] \quad 0.9 \leq \alpha \leq 1.0 \quad (8)$$

式中: $X_s[n]$ 为预加重信号; α 为预加重因子,取值通常在 0.9~1.0 之间,这是基于经验和大量实验结果确定的, α 越趋近于 1, 预加重效果越强,同时会引入更多高频噪声,故常取 0.95 以达到合适效果。

(2) 加窗。加重后的信号与窗函数相乘,以保持信号的连续性,减小频谱泄露。加窗后的输出结果为:

$$Y(n) = X(n)W(n) \quad (9)$$

其中窗函数默认选择汉宁窗函数 $W(n)$:

$$W(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad 0 \leq n \leq N-1 \quad (10)$$

式中: N 为每帧中的样本数; $2\pi n$ 为角频率。

(3) FFT。将每一帧的 N 个样本从时域转换到频域,以得到其在频谱上的能量分布,从而更好地观察和分析信号的特性。其表达式为:

$$X(k) = \sum_{n=0}^{N-1} x(n)w_e(n)e^{-j\frac{2\pi nk}{L}} \quad (11)$$

式中: $X(k)$ 为频谱; k 为频率索引; $x(n)$ 为时域采样数

据; $w_e(n)$ 为窗口函数; L 为傅里叶长度。

(4) 梅尔滤波器组。其由 100 个非均匀带通三角滤波器组成,完整的滤波器组如图 10 所示。将频谱与梅尔滤波器组相乘并对每帧中的能量求和。




图10 梅尔滤波器组

Fig.10 Mel-spaced filterbank

(5) 离散余弦变换 (discrete cosine transform, DCT)。使用 DCT 将对数梅尔频谱转换到时域,所得结果称为 MFCC。对抽样样本提取的 MFCC 进行可视化,每个样本提取 100 个特征系数。图 11 为部分实验数据展示。




图11 MFCC 特征

Fig.11 MFCC spectrogram

在 MFCC 特征图中,由于各特征之间数据差异不明显,难以观察到不同覆冰类型特征数据的特点及区别。对所有样本提取的 MFCC 特征系数中第一个系数绘制小提琴图,如图 12 所示,可以看到不同覆冰类型样本的第一个 MFCC 的数据分布和概率密度情况。图 12 中,小提琴的宽度表示数据在不同值上的密度,宽度较大表示数据在这些值附近较为集中。

3 分类网络模型构建

随着 1D-CNN 的不断发展,其在分类任务中的应用已被证明具有显著优势。利用 1D-CNN 的强大功能,研究人员在时间序列数据的分析中取得了




图 12 MFCC 第一系数小提琴图

Fig.12 MFCC first factor violin plot

突破,并在复杂信号处理、语音识别、生物医学等领域都获得了令人满意的结果^[33-35]。这一进展为处理复杂序列数据提供了一种高效、准确且不依赖领域专业知识的方法。

文中实验构建了 1D-CNN 模型,并与其他多种网络模型进行分类对比实验。数据集中包含 5 种覆冰类型:干表面、2 mm 光滑明冰表面、3 cm 混合冰表面、1 cm 雪凇表面、3 cm 雪凇表面,原始样本总共 3 000 组,每个原始信号样本包含提取的 100 个 MFCC 特征。将数据集划分为训练集、验证集及测试集,其中训练集占 60%,验证集占 15%,测试集占 25%。

1D-CNN 模型的输入层为一组由接收数据批量大小决定的神经元,并传递经过特征提取的雷达原始数据;卷积层通过预设的内核大小在输入数据上滑动,提取特征并构建特征向量;两个最大池化层用于特征下采样,分别处理卷积层 1 和卷积层 2 的输出,以增强鲁棒性,减少过拟风险。

展开层作为卷积池化模块和全连接网络的桥梁,可将多维特征转换为一维特征向量。转换后的特征输入至三层全连接神经网络,其中包括两个隐藏层,分别有 120、40 个神经元,均采用线性整流激活函数。最终层使用归一化指数函数进行多分类概率预测。模型通过误差反向传播和自适应矩估计优化器(adaptive moment estimation optimizer, ADAM)进行训练,不断更新神经元权重以获得最小化预测误差。

4 实验结果及分析

4.1 特征选择


在使用 MFCC 作为分类模型输入的训练过程中,为确保 MFCC 非特殊性,在中频信号预加重前进行统计特征提取,即分别在时域、频域及小波域上对每一个样本进行不同的特征计算提取。在中频信号时域中,提取特征包括峰值、标准差、峭度、偏度、脉冲因子、裕度因子、波形因子、余隙因子、

峰值因子^[36];在中频信号频域中,提取特征包括平均频率、重心频率、频率均方根、频率标准差;在中频信号小波域中,提取特征包括小波带能量比、小波能量熵、小波尺度熵、小波奇异谱熵^[37]。在这些特征的提取过程中涉及到信号处理、时频域的变换及统计特征分析,每种特征均包含信号的隐藏特性,故提取这些特征进行分类识别,并与前文所提 MFCC 特征进行分类性能优劣对比。

图 13 为所有覆冰类型样本的统计特征可视化,共 3 000 组样本,前 600 组为明冰样本,600~1 200 组为干表面样本,1 200~1 800 组为混合冰样本,1 800~2 400 组为 1 cm 雪凇样本,2 400~3 000 组为 3 cm 雪凇样本。从图中可得出,不同的覆冰类型对应的时域、频域、小波域特征不同,但仍难以人工分类。

4.2 识别效果分析

为证明模型的评估性能和拟合效果,图 14 展



(a) 时域特征




图 13 统计特征可视化

Fig.13 Visualization of statistical features

示了 MFCC 作为特征数据在 1D-CNN 及深度神经网络(deep neural network, DNN)模型训练下的准确度、损失曲线,图 15 为对应的混淆矩阵。为进行特征效果对比,采用统计特征进行训练,结果如图 16 所示,图 17 为对应的混淆矩阵。可以发现,1D-CNN 模型采用 MFCC 作为特征的精度更好,拟合曲线更加平滑。




图 14 基于 MFCC 的训练和验证过程拟合曲线

Fig.14 Fitting curves for training and validation processes based on MFCC




图 15 MFCC 混淆矩阵

Fig.15 MFCC confusion matrix

混淆矩阵提供了详细的分类结果,包括真阳性、假阳性、真阴性和假阴性指标,从而更全面地评估模型的性能。混淆矩阵对角线代表正确分类样本个数,剩余部分属于错误样本。通过对比图 15、图 17 可以得出,基于 MFCC 特征的 1D-CNN 模型在正确分类样本数量上表现最佳,模型所得的分类效果最优。

真阳性 T_P 为模型正确预测出正样本;假阳性




图 16 基于统计特征的训练和验证过程拟合曲线
Fig.16 Fitting curves for training and validation processes based on statistical characteristic

F_P 为模型错误地将负样本预测为正样本;真阴性 T_N 为模型正确预测负样本;假阴性 F_N 为模型错误地将正样本预测为负样本。通过这 4 个指标可以计算出以下性能指标:

$$\begin{cases} A = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \\ P = \frac{T_P}{T_P + F_P} \\ R = \frac{T_P}{T_P + F_N} \\ F_1 = \frac{2PR}{A + R} \end{cases} \quad (12)$$

式中: A 为准确率, 用于衡量模型分类正确的比例; P 为精确率, 用于衡量模型预测出的正、负样本中正确的比例; R 为召回率, 反映模型查全能力, 关注少数类别的检出率; F_1 为 F1 分数, 当类别分布不均衡时, 计算各类别的指标后取平均值, 可以更公平地评估不同类别的分类效果。

文中采用 5 种分类模型进行对比分析, 分别为




图 17 统计特征混淆矩阵

Fig.17 Statistical characteristic confusion matrix

1D-CNN、DNN、长短期记忆(long short-term memory, LSTM)网络、随机森林(random forest, RF)、径向基函数网络(radial basis function network, RBF), 具体的分类性能如表 2 所示。通过观察实验数据的结果, 可以得出 MFCC 特征融合 1D-CNN 模型的识别准确率最高的结论。

表 2 5 种分类模型评价指标值
Table 2 Evaluation metric values of five classification models

模型	准确率/%		精确率/%	
	MFCC	统计特征	MFCC	统计特征
1D-CNN	94.16	88.18	94.20	88.27
DNN	92.83	81.81	92.85	81.91
LSTM	90.97	78.09	91.16	78.50
RF	89.76	86.19	89.70	85.97
RBF	84.86	82.60	85.34	82.92

模型	召回率/%		F1 分数/%	
	MFCC	统计特征	MFCC	统计特征
1D-CNN	94.15	88.15	94.16	88.17
DNN	92.83	81.74	92.80	81.08
LSTM	90.97	78.02	90.89	76.97
RF	89.83	85.95	89.67	85.82
RBF	84.87	82.55	84.84	81.90

5 结论

文中提出一种基于毫米波雷达对风力发电机叶片覆冰检测的新方法。分析毫米波雷达回波信号与被测对象表面覆冰的关系,从原理上说明该方法的可行性。然后进行实验系统搭建,给出基于IWR1843雷达板二次开发进行数据自动采集与数据解析的详细过程。将MFCC算法应用于雷达中频信号特征提取,从而挖掘出被测物体的表面特征及材质信息。构建深度学习分类模型并融合MFCC作为特征输入实现覆冰分类识别。文中完成了冬天雪季风力机截断叶片多种覆冰类型的数据采集与识别。实验结果表明,所提方法可以很好地实现风力机叶片覆冰分类识别任务。

研究采用5种分类模型和2种特征数据进行分类识别的对比实验,并得到以下结论:

(1) 基于MFCC特征的1D-CNN模型在分类任务中表现出较高的准确性,使用毫米波雷达对动态风机叶片表面覆冰情况进行识别具有良好的分类性能。

(2) 与传统机器学习相比,1D-CNN模型更适用于雷达时域信号特征分类任务。

(3) 使用中频信号的原始数据进行MFCC特征提取,识别效果好且速度快。训练曲线显示,训练时间仅需50 s,且拟合效果好,精度高。该方法在覆光滑薄冰阶段便可识别,提前发出预警。

参考文献:

[1] 张雷,刘琦,赵晓丽,等. 电力需求增长和负荷灵活性提升视角下的风光资源密集地区可再生能源消纳研究[J]. 全球能源互联网, 2024, 7(4): 454-462.

ZHANG Lei, LIU Qi, ZHAO Xiaoli, et al. Research on renewable energy penetration in wind and solar resource-intensive areas from the perspective of power demand growth and load flexibility enhancement[J]. *Journal of Global Energy Interconnection*, 2024, 7(4): 454-462.

[2] 郑若楠. 数据驱动的风电机组叶片结冰在线检测方法[J]. 分布式能源, 2019, 4(1): 1-7.

ZHENG Ruonan. On-line detection method of ice on wind turbine blade driven by data[J]. *Distributed Energy*, 2019, 4(1): 1-7.

[3] 秦志鹏,魏高升,崔柳,等. 基于微波加热的风力机叶片除冰性能数值模拟研究[J]. 电力科学与技术学报, 2024, 39(1): 57-64.

QIN Zhipeng, WEI Gaosheng, CUI Liu, et al. Numerical investigation of de-icing performance of wind turbine blades based on microwave heating technology[J]. *Journal of Electric Power Science and Technology*, 2024, 39(1): 57-64.

[4] 刘忠德,周强,雷和林,等. 基于多传热模型数值仿真的风电机组叶片气热防除冰性能强化[J]. 电力科学与技术学报, 2024, 39(4): 160-168.

LIU Zhongde, ZHOU Qiang, LEI Helin, et al. Performance enhancement of gas heat prevention and deicing of wind turbine blades based on numerical simulation of multi-heat transfer model[J]. *Journal of Electric Power Science and Technology*, 2024, 39(4): 160-168.

[5] 于东玮,司广全,孔祥逸,等. 风机叶片覆冰机理与预测分析[J]. 计算力学学报, 2021, 38(3): 327-336.

YU Dongwei, SI Guangquan, KONG Xiangyi, et al. Icing mechanism and prediction analysis for wind turbine blades[J]. *Chinese Journal of Computational Mechanics*, 2021, 38(3): 327-336.

[6] 赵斌,廖静,任延杰,等. 风力机叶片覆冰机理与防除冰技术研究进展[J]. 排灌机械工程学报, 2023, 41(12): 1237-1245.

ZHAO Bin, LIAO Jing, REN Yanjie, et al. Research progress on icing mechanism and anti-icing technology of wind turbine blades[J]. *Journal of Drainage and Irrigation Machinery Engineering*, 2023, 41(12): 1237-1245.

[7] 成和祥,行九晖,刘杰,等. 风电机组叶片覆冰形成原因及覆冰防治概述[J]. 电力设备管理, 2021(6): 104-107.

CHENG Hexiang, XING Jiuhui, LIU Jie, et al. An overview of the causes of icing on wind turbine blades and the prevention and control of icing[J]. *Electric Power Equipment Management*, 2021(6): 104-107.

[8] MOLL J, ARNOLD P, MÄLZER M, et al. Radar-based structural health monitoring of wind turbine blades: the case of damage detection[J]. *Structural Health Monitoring*, 2018, 17(4): 815-822.

[9] 孙坚,杨宇兵. 基于Tri-SE-CNN的风电机组叶片结冰检测研究[J]. 太阳能学报, 2024, 45(12): 360-369.

SUN Jian, YANG Yubing. Research on icing detection of wind turbine blades based on Tri-SE-CNN[J]. *Acta Energiae Solaris Sinica*, 2024, 45(12): 360-369.

[10] HACİFENDİOĞLU K, BAŞAĞA H B, YAVUZ Z, et al. Intelligent ice detection on wind turbine blades using semantic segmentation and class activation map approaches based on deep learning method[J]. *Renewable Energy*, 2022, 182: 1-16.

[11] TANG W S, BLANCHE J, MITCHELL D, et al. Characterisation of composite materials for wind turbines using frequency modulated continuous wave sensing[J]. *Journal of Composites Science*, 2023, 7(2): 75.

[12] YOUSUF A, KHAWAJA H, VIRK M S. Conceptual design of cost-effective ice detection system based on infrared thermography[J]. *Cold Regions Science and Technology*, 2023, 215: 103941.

[13] AYHAN S, SCHERR S, PAHL P, et al. High-accuracy range detection radar sensor for hydraulic cylinders[J]. *IEEE Sensors Journal*, 2014, 14(3): 734-746.

[14] 樊轶伦,陈蕾,张本科,等. 基于多传感器的无人机配电网架

- 空线路自主巡检和姿态控制[J]. 电测与仪表, 2024, 61(8): 186-194.
- FAN Yilun, CHEN Lei, ZHANG Benke, et al. Autonomous inspection technology of overhead lines of distribution network and attitude control of UAVs based on multi-sensor fusion[J]. *Electrical Measurement & Instrumentation*, 2024, 61(8): 186-194.
- [15] ABOU-KHOUSA M A, RAHMAN M S U, DONNELL K M, et al. Detection of surface cracks in metals using microwave and millimeter-wave nondestructive testing techniques: a review[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 8000918.
- [16] REZAEI A, MASCHERONI A, STEVENS M C, et al. Unobtrusive human fall detection system using mmWave radar and data driven methods[J]. *IEEE Sensors Journal*, 2023, 23(7): 7968-7976.
- [17] 郭剑, 张姝, 王书轩, 等. 基于 Vision Transformer 的毫米波雷达手势识别算法[J]. 现代雷达, 2023, 45(12): 79-86.
- GUO Jian, ZHANG Shu, WANG Shuxuan, et al. Millimeter wave radar gesture recognition algorithm based on vision transformer[J]. *Modern Radar*, 2023, 45(12): 79-86.
- [18] AHMED S, CHO S H. Machine learning for healthcare radars: recent progresses in human vital sign measurement and activity recognition[J]. *IEEE Communications Surveys & Tutorials*, 2024, 26(1): 461-495.
- [19] ZHAO Y F, WANG K, GAO J. Accurate 77-GHz millimeter-wave radar noncontact vital sign detection using the optimized variational mode decomposition algorithm[J]. *Journal of Signal Processing Systems*, 2023, 95(11): 1297-1310.
- [20] GUPTA S, RAI P K, KUMAR A, et al. Target classification by mmWave FMCW radars using machine learning on range-angle images[J]. *IEEE Sensors Journal*, 2021, 21(18): 19993-20001.
- [21] HUANG X, PATEL N, TSOI K P. Application of mmWave radar sensor for people identification and classification[J]. *Sensors*, 2023, 23(8): 3873.
- [22] SKARIA S, HENDY N, AL-HOURANI A. Machine-learning methods for material identification using mmWave radar sensor[J]. *IEEE Sensors Journal*, 2023, 23(2): 1471-1478.
- [23] 陈子正, 行鸿彦, 王瑞, 等. 一种铁路隧道衬砌掉块声音检测方法[J]. 电子测量与仪器学报, 2022, 36(1): 134-140.
- CHEN Zizheng, XING Hongyan, WANG Rui, et al. Sound detection method for lining falling block in railway tunnels[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(1): 134-140.
- [24] 周梦茜, 唐志国, 王泽瑞, 等. 基于声纹识别系统的局部放电超声信号识别研究[J]. 高压电器, 2022, 58(9): 127-133.
- ZHOU Mengxi, TANG Zhiguo, WANG Zerui, et al. Study on ultrasonic signal recognition of partial discharge based on voiceprint recognition system[J]. *High Voltage Apparatus*, 2022, 58(9): 127-133.
- [25] 宋吉超, 赵国龙, 李亮, 等. 基于梅尔倒谱系数的微细铣削颤振监测研究[J]. 工具技术, 2023, 57(12): 135-139.
- SONG Jichao, ZHAO Guolong, LI Liang, et al. Study on chatter prediction method during micro milling based on MFCC[J]. *Tool Engineering*, 2023, 57(12): 135-139.
- [26] WANG Y, WANG W, ZHOU M, et al. Remote monitoring of human vital signs based on 77-GHz mm-wave FMCW radar[J]. *Sensors*, 2020, 20(10): 2999.
- [27] KHUSHABA R N, HILL A J. Radar-based materials classification using deep wavelet scattering transform: a comparison of centimeter vs. millimeter wave units[J]. *IEEE Robotics and Automation Letters*, 2022, 7(2): 2016-2022.
- [28] DARLIS A R, IBRAHIM N, KUSUMOPUTRO B. Performance analysis of 77 GHz mmWave radar based object behavior[J]. *Journal of Communications*, 2021: 576-582.
- [29] YANG Z Y, HUANG Y. Algorithm for speech emotion recognition classification based on Mel-frequency Cepstral coefficients and broad learning system[J]. *Evolutionary Intelligence*, 2022, 15(4): 2485-2494.
- [30] 曹力潭, 魏华兵, 黄智, 等. 基于 LSTM 神经网络的电抗器故障声纹识别方法[J]. 浙江电力, 2023, 42(4): 114-120.
- CAO Litan, WEI Huabing, HUANG Zhi, et al. Research on voiceprint recognition of reactor fault based on LSTM neural network[J]. *Zhejiang Electric Power*, 2023, 42(4): 114-120.
- [31] MUDA Lindasalwa, BEGAM Mumtaj, ELAMVAZUTHI I. Voice recognition algorithms using mel frequency cepstral coefficient (MFCC) and dynamic time warping (DTW) techniques[J]. *Journal of Computing*, 2010, 3(2): 138-143.
- [32] 胡锦根, 石明垒, 焦晨骅, 等. 基于 CNN 的平波电抗器声纹模式识别方法[J]. 浙江电力, 2023, 42(3): 88-94.
- HU Jinggen, SHI Minglei, JIAO Chenhua, et al. A voiceprint pattern recognition method of smoothing reactor based on CNN[J]. *Zhejiang Electric Power*, 2023, 42(3): 88-94.
- [33] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: a survey[J]. *Mechanical Systems and Signal Processing*, 2021, 151: 107398.
- [34] 何小龙, 高红均, 黄媛, 等. 基于一维卷积和图神经网络的配电网故障区段定位方法[J]. 电力系统保护与控制, 2024, 52(17): 27-39.
- HE Xiaolong, GAO Hongjun, HUANG Yuan, et al. Fault section location for a distribution network based on one-dimensional convolution and graph neural networks[J]. *Power System Protection and Control*, 2024, 52(17): 27-39.
- [35] 王挺韶, 季天瑶, 姜雨滋, 等. 基于降噪自动编码器与一维卷积网络的风机故障诊断方法[J]. 电测与仪表, 2023, 60(1): 87-93, 173.
- WANG Tingshao, JI Tianyao, JIANG Yuzi, et al. Fault diagnosis method for wind turbines based on de-noise auto-encoder and one-dimensional convolution network[J]. *Electrical Measurement & Instrumentation*, 2023, 60(1): 87-93, 173.
- [36] 魏文军, 李政, 武晓春. 基于功率曲线时域特征和变分模态分

- 解的 S700K 转辙机运行状态诊断算法[J]. *中国铁道科学*, 2022, 43(3): 144-154.
- WEI Wenjun, LI Zheng, WU Xiaochun. Running state diagnosis algorithm of S700K switch machine based on time-domain characteristics of power curve and variational modal decomposition[J]. *China Railway Science*, 2022, 43(3): 144-154.
- [37] 李园园, 周明章, 孙海信, 等. 水声 JANUS 信号的分数低阶时频谱迁移学习识别方法[J]. *声学学报*, 2022, 47(4): 461-470.
- LI Yuanyuan, ZHOU Mingzhang, SUN Haixin, et al. Fractional lower order time-frequency spectrum and transfer learn-

ing method for underwater JANUS signal recognition[J]. *Acta Acustica*, 2022, 47(4): 461-470.

作者简介:



张自豪

张自豪(1999), 男, 硕士, 研究方向为基于毫米波雷达的无损检测技术(E-mail: 3439166175@qq.com);

王志春(1972), 女, 硕士, 教授, 通信作者, 研究方向为电磁无损检测、基于毫米波雷达的无损检测技术。

Millimeter-wave radar implementation scheme for wind turbine blade icing detection

ZHANG Zihao, WANG Zhichun

(School of Automation and Electrical Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China)

Abstract: Wind energy is recognized as a renewable source due to its reliability and low cost. However, under cold and humid conditions, blade icing poses a serious hazard to the performance and durability of wind turbines. Millimeter-wave radar-based inspection techniques have gained attention for their ability to penetrate non-polarized materials and provide surface conditions and in-depth information independently of light and weather conditions. A real-time detection method for wind turbine blade icing using 77 GHz millimeter-wave radar is proposed. Mel-frequency cepstral coefficients (MFCCs) are extracted from mixed-frequency time-domain signals and fused with one-dimensional convolutional neural network (1D-CNN) for classification and identification of blade icing types. The effectiveness of the proposed method is verified through experiments with varying distances and directions. Four icing types and different thicknesses are accurately recognized, achieving a recognition rate of 94%. Thin ice coverage on wind turbine blades can be recognized and warned against.

Keywords: wind energy; millimeter-wave radar; one-dimensional convolutional neural network (1D-CNN); Mel-frequency cepstral coefficient (MFCC); blade icing; classification and identification

(编辑 陆海霞)