

DOI:10.19650/j.cnki.cjsi.J2413145

# 基于无人机航拍的风力发电机叶片表面缺陷检测综述\*

宋 晔, 吴一全

(南京航空航天大学电子信息工程学院 南京 211106)

**摘要:** 风力发电在能源转型中占重要地位。风力发电机叶片是接收风能的关键部件,其缺陷检测是维持发电机运行的基本保障。无人机航拍与机器视觉的结合能有效检测叶片表面缺陷。本文综述了近年来基于无人机航拍的风力发电机叶片表面缺陷检测方法。首先概述了风力发电机叶片特点与缺陷分类。其次对比了4类风力发电机叶片表面缺陷检测方法,阐明了无人机航拍结合视觉检测方法的优势及技术流程。然后概述了基于传统图像处理与机器学习的航拍叶片表面缺陷检测方法,包括表面图像拼接、缺陷的分割和特征提取与分类方法。综述了基于深度学习的航拍叶片表面缺陷检测方法,包含缺陷分类、识别与分割的深度学习网络。随后梳理了叶片表面缺陷数据集以及性能评价指标。最后指出该领域面临的挑战并对其解决方法进行了展望。

**关键词:** 无人机航拍; 风力发电机叶片; 缺陷检测; 机器视觉; 深度学习; 数据集

**中图分类号:** TP391.41 TH89 TK83 **文献标识码:** A **国家标准学科分类代码:** 510.4050 520.20

## Review of wind turbine blade surface defect detection based on UAV aerial photography

Song Ye, Wu Yiquan

(College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

**Abstract:** Wind power is crucial for the energy transition. Wind turbine blades, which capture wind energy, require effective defect detection to ensure reliable operation. The integration of drone aerial photography and machine vision can efficiently detect surface defects on these blades. This paper reviews recent developments in drone-based wind turbine blade defect detection. It begins with an overview of blade characteristics and defect types. Four detection methods are compared, highlighting the advantages and technical processes of drone-visual inspection. Traditional image processing and machine learning methods for image stitching, defect segmentation, and feature extraction are summarized, alongside deep learning approaches for defect classification, recognition, and segmentation. Relevant datasets and performance metrics are organized, and the paper concludes by identifying challenges and discussing potential solutions.

**Keywords:** UAV aerial photography; wind power blades; defect detection; machine vision; deep learning; datasets

## 0 引 言

当前,全球新能源和科技革命深度演变、方兴未艾。新能源主要包括太阳能、风能、地热能、海洋能、潮汐能、核能等。其中,风能相较于地热能、潮汐能等,具有更大资源储量。风力发电(下文简称风电)相较于太阳能发电成本更低,而与核能发电相比安全系数更高。风能通

过风力发电机(下文简称风机)转换为电能。我国十分重视风能开发,从2012至2023年,我国风电累计装机容量从 $9.141 \times 10^7$  kW升至 $4.41 \times 10^8$  kW,复合年增长率为13.2%。我国风电产业具有分布区域广、装机型号多、单机容量差距大、制作工艺不同等特点,因此较难形成统一的检测标准。此外,不同地区运行环境的差异会使风机叶片表面产生不同类型的缺陷并影响风机发电效率。若检测与修复不及时将会导致风机故障或叶片断裂等财

收稿日期:2024-08-07 Received Date: 2024-08-07

\* 基金项目:国家自然科学基金(61573183)项目资助

产损失情况。故有必要研究具有高适用性、准确性、实时性的风机叶片表面缺陷检测方法。

据统计,现风机叶片的运维成本约占总成本的15%~35%<sup>[1]</sup>。当前风机叶片表面缺陷检测方法中,由人工进行观测的目视法是较为常见的方法,但该方法效率低且仅适用于表面开口类缺陷<sup>[2]</sup>。而分别采用基于振动信号、机械波、数据采集与监视控制系统(supervisory control and data acquisition, SCADA)、电磁波的检测方法可以解决这些问题。然而,风机叶片表面需检测的缺陷类型较多,且随着风电场规模增大以及风机叶片长度增加,一些方法存在检测耗时长、成本高或部分缺陷检测效果不佳等情况,故不适用于大规模检测<sup>[3]</sup>。随着机器视觉与无人机技术发展,各类搭载高精度图像采集装备的无人机可精准、快速地执行多种风机叶片表面图像采集任务,并通过数字图像处理、传统机器学习或深度学习快速识别和定位叶片表面缺陷,从而有效提升检测效率并降低成本。学者们研究了这种无人机结合视觉检测的方法。

如何更快速、准确地检测风机叶片表面缺陷受到相关研究者的普遍关注并发表了相关综述,其可分为两个阶段。第1阶段为分别基于声发射、超声波、传感器等技术检测风机叶片表面缺陷的技术探索与发展阶段,如文

献[4-7]对这些技术发展进行了说明与对比。第2阶段为基于机器视觉方法及其他方法检测风机叶片表面缺陷的应用与发展阶段。自2018年以来,通过无人机航拍图像,学者们分析与总结了基于机器视觉方法检测风机叶片表面缺陷的研究进展,但仍存在一些问题。文献[8-12]对于风机叶片表面缺陷的多种方法进行了广泛的说明,但对基于视觉的检测方法说明较为简单。文献[13-14]说明了各类机器学习检测方法,但采用的文献年份较早且没有对无人机航拍的检测方法进行单独说明。文献[15-16]未详细介绍风机叶片的特点与表面缺陷,易使读者理解不充分。文献[17]综述了风机与光伏的缺陷检测方法,但并未对风机叶片表面缺陷检测方法进行集中说明,导致读者难以进行方法对比。文献[18]较为详细地介绍了检测风机叶片表面缺陷的视觉方法,但未根据方法特点进行分类与对比,易使读者难以进行分析并获取有效信息。此外,文献[19]综合介绍了采用无人机对风机叶片表面的可见光、红外、振动、声学、超声波等检测方法,其中对基于航拍图像检测的文献没有详细性能对比。当前综述类文献中并未给出航拍叶片表面图像数据集及评价指标作为参考。国内尚未有一篇对基于无人机航拍的风机叶片表面缺陷检测方法进行全面分析与总结的综述性文献。相关综述文章对比如表1所示。

表1 无人机航拍的风机叶片表面缺陷检测相关综述文章对比

Table 1 Comparison of review articles on surface defect detection of wind turbine blades using UAV aerial photography

文献	说明
[8-12]	对基于视觉的检测方法说明较为简单,且没有给出数据集
[13-14]	采用的文献年份较早且没有对无人机航拍的检测方法进行单独说明,且没有给出数据集
[15-16]	未详细介绍风机叶片的特点与表面缺陷,易使读者理解不充分,且没有给出数据集
[17]	未对风机叶片表面缺陷检测方法进行集中说明,导致读者难以进行方法对比,且没有给出数据集
[18]	未根据方法特点进行分类与对比,易使读者难以进行分析并获取有效信息,且没有给出数据集
[19]	未对基于航拍图像检测的文献进行详细性能对比
本文	详细介绍风机叶片特性、缺陷分类并系统分类与连贯说明基于无人机航拍的风机叶片表面缺陷检测技术,给出相关数据集及评价指标,快速为读者提供有效信息

鉴于此,本文将详细介绍风机叶片特性、缺陷分类并系统分类与连贯说明基于无人机航拍的风机叶片表面缺陷检测技术,且给出相关数据集及评价指标,快速为读者提供有效信息,为相关研究人员提供参考。主要安排如下:第1部分全面概述风机叶片特点及其表面缺陷分类。第2部分分别简述与对比了基于振动信号、基于机械波、基于SCADA、基于电磁波4类风机叶片表面缺陷检测方法的发展历程。第3部分介绍了无人机航拍方法的技术流程及其优势。第4部分从图像拼接、分割以及特征提取与分类3方面概述了基于传统图像处理与机器学习的无人机航拍风机叶片表面缺陷检测方法。第5部分从目

标分类、目标检测以及目标分割3个方面全面阐述了基于深度学习的无人机航拍风机叶片表面缺陷检测方法。第6部分介绍了无人机航拍风机叶片表面缺陷数据集以及性能评价指标。最后,第7部分指出了无人机航拍风机叶片表面缺陷检测方法面临的挑战并进行展望。

## 1 风机叶片特点及表面缺陷类别

叶片作为风机接收风能的重要部件,其由最早木制、钢制,变为由高强度、高刚度、耐疲劳的聚合物复合材料制作<sup>[20]</sup>。

### 1.1 风机叶片材料与结构特点

制作风机叶片的复合材料由纤维与基体组成。纤维决定叶片刚度。玻璃纤维是一种价格低、抗压强度高的常见纤维。然而,该纤维耐磨性差且易被腐蚀。碳纤维作为替代品,刚度更高、密度更低,但价格高且对纤维错向敏感,故多用于大型风机。基体用于粘合纤维,其通常由粘度低、低温固化的热固性树脂构成,如环氧树脂、聚酯等<sup>[21]</sup>。此外,也可使用其他材料制作叶片<sup>[22-23]</sup>。风机叶片结构如图 1 所示,风机叶片各结构的材料与作用如表 2 所示。

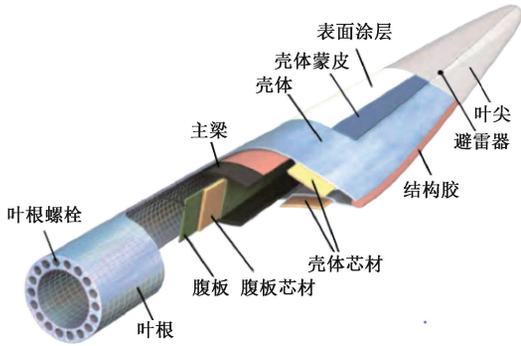


图 1 风机叶片结构

Fig. 1 Wind turbine blade structure

表 2 风机叶片各结构的材料与作用

Table 2 The material and function of each structure of wind turbine blade

结构	材料	作用
主梁	纤维织物	承受叶片弯曲载荷
壳体	纤维织物	形成叶片上下表面的夹层
壳体芯材	巴沙轻木、PVC 泡沫、PET 泡沫	填充和增强叶片结构
表面蒙皮	聚酯、聚氨酯、环氧树脂	保护叶片表面,增加应力
表面涂层	聚氨酯	保护与美化外观,提高叶片寿命
腹板	环氧树脂、聚酯等类热固性树脂材料	支撑截面部
腹板芯材	巴沙轻木、PVC 泡沫、PET 泡沫	加强内部结构
结构胶	环氧树脂、聚酯	粘合上下壳体
叶根	纤维织物	链接叶片与机舱的圆柱形根部
叶根螺栓	T 型金属螺栓	用于固定叶片根部
叶尖	纤维织物	减少空气动力噪声
避雷器	避雷传感器	接收雷电

风机叶片也可依据运行功能分为上表面(吸力面或迎风面)、下表面(压力面或背风面)、前缘、后缘 4 种结

构,如图 2 所示,其功能分析如表 3 所示。

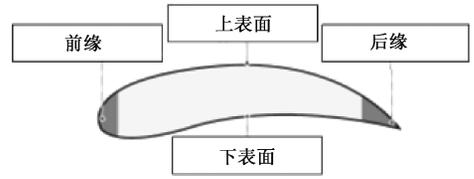


图 2 叶片运行结构

Fig. 2 Wind turbine blade operation structure

表 3 风机叶片运行结构分析

Table 3 Analysis of wind turbine blade operation structure

结构	位置	作用
上表面	叶片的上侧	影响风能转化效率和噪声
下表面	叶片的下侧	
前缘	叶片面对风向的前端	减少空气动力噪声
后缘	叶片对风向的后端	

### 1.2 风机叶片的长度与型号特点

受太阳加热不均匀、地理差异、Coriolis 效应<sup>[24]</sup>等因素影响,风由高压区流向低压区形成风能。风机将风能转换为电能,其简易转换公式为:

$$P = 0.5 \alpha \rho A v^3 \quad (1)$$

式中:  $P$  为接收的风能;  $\alpha$  为气动效率常数(根据 Betz 极限,  $\leq 0.593$ );  $\rho$  为空气密度;  $A$  为叶片面积大小;  $v$  为空气流动速度。由式(1)可得,单机容量正比于叶片面积。由于叶片面积正比于叶长,故为使单机容量增大,叶长也会相应增加。不同型号风机参数如表 4 所示。

表 4 不同型号风机参数

Table 4 Parameters of different types of wind turbines

型号	公司	容量/MW	叶片材料	叶长/m
V-90	Vestas	3.0	玻璃纤维	44
SWT-6.0	西门子	6.0	玻璃纤维	75
S7-171	三星	7.0	玻璃纤维	85
GWH252	金风科技	16.0	碳纤维	123
H260	中船海装	18.0	碳纤维	130

由此可见,不同风机的型号、叶长、材料等均可能存在差异,故开展检测任务前需了解这些信息。此外,还需对风机叶片表面缺陷类别进行详细划分。

### 1.3 风机叶片表面缺陷类别

目前,国内外并未统一规范基于无人机航拍的风机叶片表面缺陷类别。故根据风机叶片结构与特点,可将其表面缺陷分为以下 6 种。

### 1) 叶片结构性缺陷

外壳、叶根等部位的表面与结构上出现分层和纤维破损等缺陷。分层会降低叶片刚度与强度<sup>[25]</sup>。近表面分层可引发局部屈曲,严重时使叶片断裂<sup>[26]</sup>。纤维破损表现为开裂、壳体撕裂、开放性撕裂等纤维损伤类缺陷。大面积纤维破损会影响风机运行,甚至使风机叶片局部失效、断裂。

### 2) 前、后缘侵蚀

前缘是风机叶片上最易受侵蚀的部位<sup>[27]</sup>。受雨滴等液体撞击而形成的压力波、冰雹、风沙、灰尘以及风压、温湿度等因素的侵蚀影响<sup>[11]</sup>,前缘会出现裂纹、表面粗糙化、砂眼、脱胶或涂层破损等因腐蚀而形成的缺陷。据统计,运行4年以上的叶片受该类缺陷影响发电量可最高下降20%<sup>[28-29]</sup>。后缘侵蚀形成原因与前缘类似,主要由叶根或叶尖区域因疲劳载荷引起的横向裂纹与因高负荷产生的纵向裂纹组成。该类缺陷需及时修复以防增加叶片负载。前、后缘侵蚀常见于海上或降雨、风沙、冰雹多发的地区。

### 3) 上、下表面侵蚀

叶片上、下表面侵蚀种类较多,如因环境产生的胶衣损伤、划痕、起泡、油漆磨损、斑点;因机舱漏油形成的油污;因动物活动留下的泥浆与污垢<sup>[30]</sup>;因排水孔生锈产生的锈蚀等。该类缺陷多发于海上或降雨、风沙多发的

地区并会影响叶片气动效率或美观。

### 4) 叶片结冰

根据《ISO 12494—2001》标准,高海拔、冷空气密度高地区的风机会出现叶片结冰现象。结冰通常从前缘由水滴通过撞击叶片表面形成冰层或湿冷空气凝结形成霜层,然后覆盖整个叶片,从而对叶片空气动力学性能造成严重影响,最高可使输出功率损失高达80%<sup>[31]</sup>。结冰严重时将导致风机控制失效、超速、甚至叶片断裂<sup>[32]</sup>。

### 5) 雷击类

复合材料耐雷能力低。雷击会使叶片内部产生高温电弧导致纤维碳化而破损甚至诱发火灾<sup>[33]</sup>。通常山脊的高阻抗岩石或土壤使闪电电流难以接地<sup>[34]</sup>,故该地风机叶片更易被雷击损坏。根据 IEC《IEC61400—24》国际标准,风机叶尖部署有避雷器降低雷击风险。故检测避雷器缺损对预防雷击十分必要。

### 6) 螺栓断裂

固定叶片与叶轮的螺栓在运行过程中受周期性交变载荷影响可能出现松动或变形使叶片移位或掉落。尽管该缺陷出现较少,但后果严重<sup>[35]</sup>。

风机叶片表面缺陷分类如表5所示。此外,应检测风机叶片表面本身的标识类图案、修复补丁、涂漆、水痕等非缺陷图案,防止误判而造成计算资源浪费。

表5 风机叶片表面缺陷分类

Table 5 Wind turbine blade defect classification

损伤类型	具体损伤	具体危害	易发地区
叶片结构性缺陷	分层、屈曲、开裂、壳体撕裂、开放性撕裂等	影响风机运行、严重时使风机局部失效、断裂	-
前、后缘侵蚀	横、纵向裂纹、表面粗糙化,砂眼、脱胶、涂层破损	影响叶片气动效率、增加叶片载荷	海上或降雨、风沙多发
上、下表层侵蚀	胶衣损伤、油漆磨损、划痕、斑点、油污、污垢、锈蚀	影响叶片气动效率或美观	海上或降雨、风沙多发
叶片结冰	冰层或冰冻	降低风机运行效率、严重时使叶片断裂	高海拔、冷空气密度高
雷击类	雷击破损,避雷器缺损	引发结构性损伤甚至火灾	山脊或多雷雨
螺栓断裂	叶片根部螺栓松动、断裂	风机运行过程中叶片掉落	-

受风机型号、运行环境影响,缺陷评级无单一标准,故仅对缺陷类型、具体危害以及易发情况进行总结以供参考。在实际检测时,可结合检测要求对缺陷进行分级处理以实现高效检测。

## 2 风机叶片表面缺陷检测技术发展对比

自20世纪70年代第1台由复合材料制作的风机投入运行以来,通常由人眼通过地面望远镜或架设吊篮检测叶片表面缺陷,但该方法效率较低<sup>[8]</sup>。为解决该问题,研究人员进行了大量探索。风机叶片表面缺陷检测技术

可分为基于振动信号、基于机械波、基于SCADA和基于电磁波4类。当前风机叶片表面缺陷主要检测技术如图3所示。

### 2.1 基于振动信号

该方法通过处理叶片的时域或频域振动信号获取模态参数变化以识别缺陷,可按传感器类型分为以下4种:

1) 基于应变传感器:由应变片针对叶片重要位置获取形变信号。该方法易于部署。

2) 基于加速度计传感器:由加速度计嵌入叶片获取叶片动态响应信号,从而实时检测叶片结构。

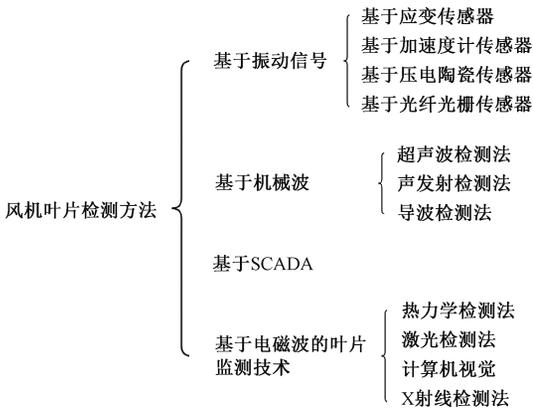


图 3 风机叶片表面缺陷检测技术

Fig. 3 Wind turbine blade surface defect detection technology

3) 基于压电陶瓷传感器:由压电陶瓷获取叶片电荷变化信号。此方法检测灵敏度高,便于成型。

4) 基于光纤光栅传感器:由光纤光栅嵌入叶片获取叶片应变变化或应力集中时的光学特征变化信号,可检测微小缺陷。

尽管以上 4 种方法能进行有效检测,但需部署或嵌入传感器从而限制了适用性。且传感器对雷击防护较弱,故维护成本高。

## 2.2 基于机械波

该类方法通过探测弹性波的应变能量来识别缺陷,可分为超声波检测法、声发射检测法、导波检测法 3 种。

1) 超声波检测法:由超声波在叶片表面的反射波的传输时间、振幅等信息检测缺陷位置、程度与类型。然而不同缺陷需采用不同探头,故该方法成本高、效率低,多用于出厂检测。

2) 声发射检测法:通过分析叶片表面出现早期缺陷时产生的高频声发射信号发现缺陷。由于缺陷应力波区分度不高,故该方法难以判别缺陷类型。需在损伤源部署大量传感器与采集系统。

3) 导波检测法:类似远程超声波检测。通过分析导波与叶片表面缺陷发生反射或折射特性实现检测,但该方法信号处理复杂。

## 2.3 基于 SCADA

大多数兆级风机都配备了 SCADA 系统监控 150 多种运行指标。叶片表面缺陷会使能源转换效率和输出特性相关的数据下降。该方法多用于风机叶片缺陷监测与预防,文献[36]通过分析 SCADA 数据实现叶片表面覆冰的检测与预测。文献[37-38]分别通过不同方法分析 SCADA 数据实现潜在故障的提前检测。

尽管该方法易获取数据,但需分析的数据量较大,并且该方法仅能实现缺陷类型判别而较难定位缺陷位置,故仍需搭配其他方法使用。

## 2.4 基于电磁波

根据电磁波波段,该方法可分为如下 4 类:

1) X 射线检测法:随着 X 射线技术发展,文献[39]介绍了该方法在检测结构性缺陷和厚度变化方面非常有效,但成本较高且存在健康问题。

2) 激光检测法:文献[40]通过检测叶片经过激光传感器时叶尖和叶根处的时间信号检测故障。可实现非接触式检测,但由于需对叶尖与叶根检测,在对实际不同类型风机检测时,设备搭建难度较大。此外,可以采用激光多普勒测速仪通过激光粒子散射的光频率变化与入射光频率差获取结构运动速度,进而实现叶片表面监测。该方法灵敏度高,但需额外增加反射标记从而减少叶片材料反射性不足与激光源距离等因素影响。

3) 机器视觉检测法:通过摄像头获取叶片表面图像并通过处理实现缺陷检测。随着与机器学习的结合,其效率得到进一步提升。该方法易操作、成本低,但效果受图像质量影响较大。

4) 热力学检测法:通过检测由缺陷导致的热量变化实现缺陷的检测与分类。尽管该方法效率高、成本低,但对热力学特征不明显的微小缺陷效果较差。

上述方法中,机器视觉方法不需要额外进行设备安装,且灵活性高、易于操作,但由于风机高度高、叶片长度使得在地面通过相机难以获取高质量图像,而无人机航拍技术的发展使该问题得以解决。风机叶片表面缺陷检测方法如表 6 所示。

## 3 无人机航拍结合视觉检测方法的优势及技术流程

无人机(unmanned aerial vehicle, UAV)具有轻便性、易操作、低成本、高机动性<sup>[41]</sup>。文献[42]论证了使用无人机可显著降低风机叶片表面缺陷检测成本并大大提高安全性与效率。随着无人机的发展以及各类巡检算法的研究与实现<sup>[43-44]</sup>,无人机能通过搭载不同传感器高效检测风机叶片缺陷。文献[45]通过在无人机嵌入声学状态监测系统捕获叶片噪声从而识别与分析叶片表面缺陷。文献[46]提出在无人机安装 X 射线设备的检测方案。除上述方法外,由无人机搭载高精度摄像头结合视觉检测方案最为常见。该方法极大弥补了对图像或视频要求高的缺点,从而实现了风机叶片表面缺陷的快速、准确检测。

无人机可以分为多旋翼、固定翼、直升类等,其特点如表 7 所示。

多旋翼无人机体积小、可悬停而适合风机叶片表面拍摄。四旋翼与六旋翼类无人机较为常用。目前暂无仅针对风机叶片检测研发的专业商用无人机。大疆

表6 风机叶片表面缺陷检测方法

Table 6 Wind turbine blade surface defect detection method

方法分类	检测方法	优势	缺点	检测成本
基于振动信号	应变传感器	部署方便	需部署传感器、检测区域小、雷击防护弱	高
	加速度计传感器	实时检测	需部署传感器嵌入叶片、雷击防护弱	高
	压电陶瓷传感器	灵敏度高	需部署传感器、雷击防护弱	高
	光纤光栅传感器	灵敏度高	需部署传感器嵌入叶片、雷击防护弱	高
基于机械波	超声波	内部损伤检测率高	需更换探头、效率低	高
	声发射	灵敏度高	环境要求高	高
	导波	有一定检测能力	信号处理复杂	高
基于 SCADA	SCADA 数据	可检测与预测缺陷	需分析的数据量较大	低
基于电磁波	X 射线	信息获取更全面	存在健康安全问题	高
	激光检测	灵敏度高	需要放置标记、检测跨度大,设备搭建难度大	低
	机器视觉	灵活度高、易操作	效果受图像质量影响较大	低
	热力学	检测方便	微小缺陷检测不明显	低

表7 多旋翼、固定翼、直升类无人机特点

Table 7 Multi-rotor, fixed-wing, helicopter UAV features

性能	固定翼	直升类	多旋翼
能否悬停	否	是	是
操作难易	难	较难	易
可靠性	高	一般	高
维护成本	高	一般	低
续航时间	长	一般	短
起飞方式	需要跑道	垂直起降	垂直起降
载荷	大	一般	小

Matrice 系列无人机因其续航长、抗风强、稳定性强等优点被许多团队采用,其常用型号参数如表8所示。

在进行风机叶片表面缺陷检测时,无人机需配备电机、电池、导航系统、通信系统、摄像头以及各类传感器<sup>[42]</sup>。当前,基于无人机航拍的风机叶片表面缺陷检测方法主要流程可分为图像采集、图像传输与管理、图像预处理以及图像分析4大步骤,基于无人机航拍的缺陷检测流程如图4所示。

首先,为确保对风机叶片进行全面拍摄,需对无人机航迹与航点进行规划。然后,无人机通过机载拍摄设备对叶片表面进行拍摄。拍摄完成后由网络传输至计

表8 大疆 Matrice 系列无人机常用类型及参数

Table 8 Common types and parameters of DJI Matrice series UAVs

系列	类型	起飞重量 /kg	飞行时间 /min	摄像设备	最大像素	发布时间	抗风等级	特点
Matrice 100	四旋翼	2.35	40	Zenmuse X3, X5, XT	1 600 万	2015 年	4 级	灵活、适合精细检测
Matrice 600/600 Pro	六旋翼	9.1/9.5	35/38	Ronin-MX, Zenmuse X3, X5, XT	1 600 万	2016 年	5 级	稳定性高,支持高性能摄像设备,适合精细检测
Matrice 300 RTK	六旋翼	6.3	55	Zenmuse H20, H20T, P1	4 500 万	2020 年	5 级	适合大面积、长时间的叶片检测
Matrice 350 RTK	六旋翼	6.4	55	Zenmuse H20, H20T, P1	4 500 万	2023 年	6 级	更强的抗风能力和智能飞行模式

算机,并通过图像采集卡进行数字化、去噪、增强、分割等预处理。接着,对处理后的图像进行特征提取并通过分类器进行缺陷识别与分类。值得注意的是,也可将图像预处理和分析部分部署在无人机上从而省去传输过程。

文献[47]对运行中的风机采用无人机航拍方法进

行检测,提出了一套无人机视频测量技术用于检测运行中的风机叶片表面缺陷。然而,由于运行过程中转动的叶片易使拍摄的图像模糊导致误检漏检现象,且存在安全隐患。故本文所述方法均为对停机状态的风机叶片表面进行检测。

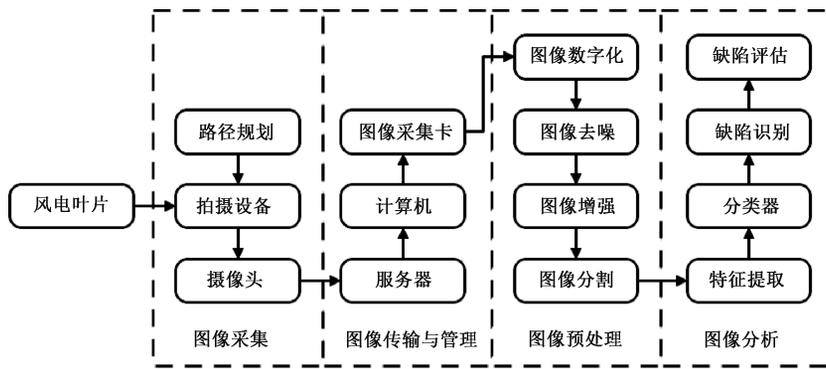


图 4 基于无人机航拍的缺陷检测流程

Fig. 4 Defect detection process based on UAV aerial photography

## 4 基于传统图像处理与机器学习的航拍叶片表面缺陷检测方法

无人机在拍摄不同叶面时可能存在模糊、亮度不均、背景不同等情况。故需对图像进行灰度化、去噪、拼接等预处理,再进行图像分割、缺陷特征提取与识别。其中,边缘检测、阈值分割等图像分割方法较为常用,而传统机器学习方法基于局部二值模式(local binary pattern, LBP)、灰度共生矩阵(grey level co-occurrence matrix, GLCM)、方向梯度直方图(histogram of oriented gradient, HOG)、哈尔(Haar)等特征,通过支持向量机(support vector machine, SVM)等分类器进行风机叶片表面缺陷识别。

### 4.1 航拍风机叶片表面图像拼接

由于无人机在巡检过程中,需要在多个航点进行拍摄从而实现对风机叶片表面的覆盖,故风机叶片表面图像拼接在缺陷检测中起着重要辅助作用,通过拼接实现整个叶片的全面覆盖可以减少同一缺陷在多张图像中被检测的情况,从而减少数据冗余,此外,拼接后的叶片可以帮助更加直观的定位与分析缺陷,进而提升缺陷检测的准确性与效率。文献[48]采用叶片边缘与无人机到叶片的距离进行粗粒度拼接,并通过纹理和形状损失对细粒度进行优化调整。文献[49]采用扭曲图像的方式使图像看似从统一的高度、俯仰和偏航角拍摄,并使拼接后的图像生成的地图是准确的。文献[50]提出一种基于形态学的角点拼接方法,但是拼接耗时较长。文献[51]提出一种基于边界搜索的改进归一化互相关(normalized cross-correlation, NCC)算法,通过叶片边界为中心进行搜索匹配并加入图像金字塔的多尺度匹配从而简化搜索路径并提升匹配精度。文献[52]先对图像进行平移、旋转等配准操作后再通过图像多波段信息进行拼接,实现无人机拍摄的红外叶片图像高准确率拼接。

### 4.2 风机叶片表面缺陷图像分割

#### 1) 边缘检测

边缘检测是一种常见的图像处理技术,其通过检测算子识别图像中亮度或颜色变化以提取叶片表面的边缘特征进行识别与分类。文献[53]通过 Canny 算子获取叶片表面冰层轮廓、厚度分布等信息,但在叶尖部分有误差。文献[54]采用自适应 Canny 算子分割裂纹、砂眼、斑点、划痕类缺陷轮廓并结合颜色特征识别与分类缺陷,其中砂眼、斑点识别准确率高,但长条型缺陷识别率低。

文献[55]对比了 Canny、Sobel 等算子检测不同颜色风机叶片表面缺陷的效果,其中, Sobel 算子效果最佳。文献[56]采用 Sobel 算子提取叶片表面裂纹并实现在无人机上部署,但易受环境影响。

小波变换具有良好的多尺度分析能力,可对不同分辨率图像进行边缘检测。文献[57]对比了 Canny、Sobel 以及多尺度小波变换方法检测叶片结冰的效果,结果表明多尺度小波变换方法细节丢失更少,但易误检伪边缘。文献[58]通过多尺度小波变换提取跨图像大型裂纹边缘,并由其投影特征分为纵向、横向与网状 3 类,但易受拍摄角度影响横向裂纹识别。

#### 2) 阈值分割

阈值分割是一种流程简洁、效率较高的图像分割方法,其通过对特定色彩空间图像设定阈值以分割缺陷区域并由区域特征实现分类。然而,阈值过高或过低会导致缺陷信息遗漏。故合适的阈值十分关键。

文献[59]将采用彩色阈值变换方法分割出的叶片实际与未受损区域相减得到实际缺陷区域,但由于形态学处理使该方法无法检测微小缺陷。文献[60]采用改进鲁棒主成分分析(robust principal component analysis, RPCA)方法获取图像显著图提升缺陷特征,再由自适应阈值分割方法检测缺陷,但算法计算复杂。文献[61]对前景分割的叶片图像结合自定义阈值与迭代阈值方法提取裂纹、砂眼、胶衣损伤类缺陷区域,尽管裂纹识别率高,

但存在错检、漏检情况。文献[62]结合 Gabor 变换与梯度阈值分割方法提升了非均匀光照下裂纹、划痕、凹坑类缺陷检测精度,但无法分辨污染物、划痕等灰度值相似的缺陷。

为探索更适合叶片缺陷检测的阈值分割方法,文献[63]对比了局部自适应阈值分割法、迭代阈值分割法与 Otsu 算法分割叶片表面裂纹的效果,其中, Otsu 算法速度最快且不会出现裂纹断续情况。Otsu 算法是一种自动的非参数非监督的阈值分割法,其计算简单且受亮度和对比度影响小。文献[64]在 Otsu 算法基础上加入双三次插值计算和裁剪处理,提升了划痕的检测率,但形状

误判较多。之后,文献[65]引入边缘密度函数定量计算 Otsu 算法的最佳阈值,进一步提升裂纹、划痕、砂眼的检测精度,但斑点类缺陷检测准确度较低。为避免图像杂点影响,文献[66]结合 K-means 与 Otsu 算法使裂纹、砂眼、涂层破损、油污、脱胶类缺陷的边缘轮廓更加平整,但识别准确率有待提升。

综上所述,边缘检测方法多用于检测裂纹等边缘特征明显的缺陷,但易受拍摄角度和背景影响。阈值分割方法可检测更多缺陷类型,但效果依赖阈值。故实际检测中,应依据具体需求综合运用各方法。叶片缺陷图像分割方法时间线如图 5 所示,各方法总结如表 9 所示。

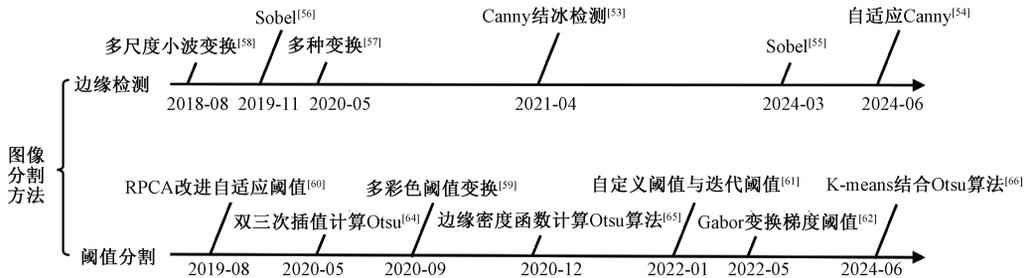


图 5 风机叶片缺陷图像分割方法时间线

Fig. 5 Time line of wind turbine blade defect image segmentation method

表 9 常用的叶片缺陷图像分割方法

Table 9 Comparison of commonly used digital image processing methods

类别	文献	方法	缺陷分类	优点	局限性
边缘检测	[53]	Canny	叶片结冰	可提取冰层厚度分布信息	叶尖部分检测存在误差
	[54]	自适应 Canny	裂纹、砂眼、斑点、划痕	砂眼、斑点识别率高	长条型缺陷识别率略低
	[55]	Sobel	裂缝、划痕	可针对不同颜色叶片	图像拍摄环境单一
	[56]	Sobel	表面裂纹	实现在无人机部署	受环境影响大,检测准确度低
	[57]	Sobel, Canny, 多尺度小波变换等	叶片结冰	信噪比更低,细节丢失更少	存在误检伪边缘的情况
阈值分割	[58]	多尺度小波变换	大型裂纹	可提取跨图像大型裂纹边缘	受拍摄角度的影响使得横向裂纹识别误差大
	[59]	彩色阈值变换分割	未分类	实现简单	无法检测微小缺陷
	[60]	改进的 RPCA 结合自适应阈值分割	未分类	提升特征不明显缺陷检测效果	算法计算复杂
	[61]	自定义阈值与迭代阈值分割	裂纹、砂眼、胶衣损伤	裂纹识别率较高	存在错检、漏检情况
	[62]	Gabor 变换梯度阈值分割	裂纹、划痕、凹坑	减少非均匀光照影响并提升裂纹、划痕、凹坑检测精度	无法分辨灰度值类似缺陷
	[64]	双三次插值计算结合 Otsu 算法	划痕	提升划痕的检测效果	形状判别错误较多
[65]	边缘密度函数计算 Otsu 算法最佳阈值	裂纹、砂眼、划痕、斑点	划痕、裂纹、砂眼检测准确度较高	斑点类缺陷检测准确度较低	
[66]	K-means 结合 Otsu 算法	裂纹、砂眼、涂层破损、油污、脱胶	使缺陷边缘轮廓更加平整	识别准确率有待提升	

### 4.3 基于传统机器学习的风机叶片表面缺陷特征提取与分类

传统机器学习方法通过选择与提取图像不同特征并由分类器进行缺陷分类, SVM 是一种常用的分类和回归分析的监督模型, 学者们对 SVM 进行了多种改进用于检测无人机航拍风机叶片表面缺陷。文献[67]采用多种方法调整 SVM 模型的正则化参数、核系数等超参数, 其中 Hyperband 方法对模型准确度和速度提升最高, 但相较于原方法检测时间提升了 111%。

提取图像更多特征能够提升 SVM 分类效果。文献[68]采用宽高比、圆度、锐度特征对裂纹进行分类并评估发展趋势, 但预处理复杂。为减少图像复杂背景影响, 文献[69]提取微小裂纹 LBP 和 GLCM 特征并引入萤火虫算法 (glowworm swarm optimization, GSO) 提升检测精确率与召回率, 但特征向量可能与无裂纹图像重叠导致错检。

HOG 特征由计算与统计图像局部区域的梯度方向直方图构成。该特征可保留局部细节并减少光照影响。文献[70]、文献[71]均采用了 HOG 特征对裂纹、砂眼、划痕与斑点类缺陷特征进行描述并采用 Log-Gabor 滤波器以及粒子群优化算法 (particle swarm optimization, PSO) 进行优化, 并提升了检测准确率, 但检测数量多、密度高的缺陷如砂眼、划痕时易产生特征堆叠而误检。

哈尔 (Haar) 特征是一种由计算检测窗口指定位置相邻矩形像素差来反映图像灰度变化的特征。根据该特征进行分类具有样本要求低, 鲁棒性强等优势。文献[72]

设计了由 LogitBoost、决策树 (decision tree, DT) 和 SVM 构成的级联分类器对裂纹图像 Haar 特征进行分类, 但误检较多。随后 2019 年, 为进一步提升检测效率, 文献[73]基于原方法加入并行 Jaya K-means 算法对裂纹窗口像素进行轮廓定位与提取并实现无人机部署, 但采用的图片较少, 仅为 82 张。

此外, 国内外学者对采用神经网络提取特征展开了研究。文献[74]采用深度卷积神经网络 (deep convolutional Neural Networks, DCNN) 提取裂纹、划痕、油漆磨损、凹坑特征并由 SVM 分类, 从而提升检测准确率, 但未讨论模型分类速度。为降低叶片弧度、光照的影响, 文献[75]融合串行降维的 LBP 特征与卷积神经网络 (convolutional neural networks, CNN) 特征, 并通过麻雀搜索算法 (sparrow search algorithm, SSA) 优化基于核极限学习机 (kernel based extreme learning machine, KELM) 分类器检测裂纹与腐蚀类缺陷, 但表面缺陷识别率不高。文献[76]采用 VGG16 网络提取裂纹、胶衣损伤与涂层破损特征并结合 PSO 与 K-means 算法提高模型全局搜索能力, 但可调参数较多, 无法实现系统的实时性。

综上, 传统机器学习方法检测航拍风机叶片表面图像缺陷时, 特征的选择与提取以及分类器的选用与调整是决定检测结果的重要因素。相比传统数字图像处理方式, 该方法可有效减少环境影响并满足更多缺陷的检测需求, 但仍存在错检漏检率高、检测缺陷种类较少、模型复杂等情况。特征提取与分类方法时间线如图 6 所示, 各方法总结如表 10 所示。

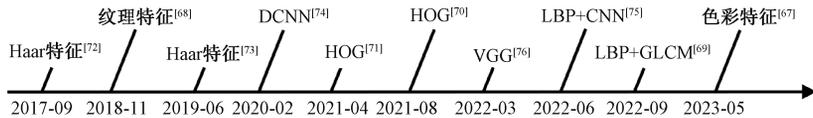


图 6 风机叶片缺陷图像特征提取与分类方法时间线

Fig. 6 Timeline of wind turbine blade defect image feature extraction and classification methods

## 5 基于深度学习的航拍叶片表面缺陷检测方法

深度学习是机器学习领域中的一个分支, 其通过深度神经网络 (deep neural network, DNN) 模拟人类学习与分析从而实现自动特征提取与分类。在检测航拍风机叶片表面缺陷时, 该方法可分为分类、检测以及分割 3 类网络。

### 5.1 分类网络

分类网络能对图像进行识别与分类, 其中, CNN 是一种常用的由卷积核与图像卷积的非线性特征提取与分类网络。文献[77]对比证明了 CNN 对无人机航拍叶片

表面缺陷分类的泛化能力与精准度相较 SVM 模型有巨大优势, 其准确率高于 SVM 方法 62.01%。文献[78]使用 CNN 对裂纹、雷击破损、边缘侵蚀、屈曲进行训练并实现部署, 但大型与微小缺陷检测效果差。为提升分类效果。文献[79]在 CNN 前加入 Haar-AdaBoost 方法进行区域提议从而提升裂纹、砂眼、涂层破损、边缘侵蚀类缺陷检测速度与精度, 但分类时间较长且精确率仅为 49%。

此外, 学者们讨论了基于 CNN 框架提出了著名的 AlexNet<sup>[80]</sup>、VGG<sup>[81]</sup>、ResNet<sup>[82]</sup> 等分类网络对叶片表面缺陷的分类效果。文献[83]对比证明了 VGG 网络相较 AlexNet 网络对胶衣损伤、油污等缺陷的分类精度、F1 分数更高。注意力模块能够提升模型获取多维度缺陷特征信息能力, 进而提升分类准确度。文献[84]在 VGG 网络

表 10 常用的风机叶片缺陷图像特征提取与分类方法

Table 10 Common methods for feature extraction and classification of defect images of wind turbine blades

文献	特征	分类器	缺陷分类	优点	局限性
[67]	彩色与灰度值图像	Hyperband 优化 SVM	未分类	准确率 79.04% (4.94% ↑)	需要较长检测时间
[68]	宽高比、圆度、锐度	SVM	细小裂纹	有效识别裂纹细节并评估裂纹发展趋势	预处理复杂
[69]	LBP+GLCM	GSO 改进 SVM	微小裂纹	准确率(复杂背景):95.4%(7.5% ↑) 召回率(复杂背景):93.9%(2.8% ↑)	特征向量可能与无裂纹图像重叠导致错检
[70-71]	HOG 特征	SVM	裂纹、砂眼、划痕、斑点	提升检测准确率	易误检数量多、密度高的缺陷
[72]	Haar 特征	级联 LogitBoost、DT、SVM	裂纹	准确率 98.6% 检测时间:0.083 s (0.014 s ↓)	误检较多
[73]	Haar 特征	级联 LogitBoost、DT、SVM+Jaya K-means	裂纹	准确率 95.83% 检测时间:0.012 s (0.086 s ↓)	采用的图片数量较少
[74]	DCNN 特征	SVM	裂纹、划痕、油漆磨损、凹坑	提升检测准确率	未讨论模型分类速度
[75]	降维 LBP+CNN	SSA 改进 KELM	裂纹、腐蚀	准确率 97.5% (1.9% ↑)	表面缺陷识别率不高
[76]	VGG-16 特征	PSO 结合 K-means	裂纹、涂层破损	提高算法的全局搜索能力	可调参数较多

中引入轻量级的卷积注意力模块(convolutional block attention module,CBAM)对裂纹、砂眼、胶衣损伤进行分类。文献[85]在 VGG 网络特征提取块后加入通道注意力机制(channel attention mechanism,CAM)与空间注意力机制(spatial attention mechanism,SAM)以提升对裂纹、砂眼、胶衣损伤的分类能力,并消除固有结构(排水孔等)干扰,但以上方法胶衣损伤检测准确率较低。

文献[86-87]分别对比了 VGG 网络与 ResNet 网络对裂纹、前缘侵蚀、脱胶、雷击破损以及叶片结冰的分类效果。结果表明 ResNet 网络分类精度更高。为获取更多特征,文献[88]在 ResNet 基础上提出多特征融合分类

网络 ResNet\_3F 对脱胶、表面侵蚀、油漆磨损和油污进行分类并结合迁移学习有效降低训练时间且精度更高,但特征的增多会导致模型分类速度降低。

为降低模型训练成本,文献[89]结合 CNN 与元学习(meta-learning)算法提出 DMnet 模型,该模型可在 MVTec 数据集上训练后由 20 张包含裂纹、胶衣损伤和涂层破损的图像完成微调,但精度稍低,为 78.8%。

综上,深度学习分类网络效果优于传统机器学习方法,但存在模型训练速度慢、特定类型缺陷分类效果差等情况。

常用的叶片缺陷图像分类网络如表 11 所示。

表 11 常用的风机叶片缺陷图像分类网络

Table 11 Comparison of commonly used classification network methods of wind turbine blades

文献	分类方法	缺陷分类	效果	局限性
[78]	CNN	裂纹、雷击破损、边缘侵蚀、屈曲	二分类准确率:94.94% 多分类准确率:91%	大型与微小缺陷效果差
[79]	Haar-AdaBoost 改进 CNN	裂纹、砂眼、涂层破损、边缘侵蚀	分类时间:1 s;召回率:90%	分类时间仍较长、精度较低
[84]	VGG+CBAM	裂纹、砂眼、胶衣损伤	多分类准确率:92.85%(6.7% ↑) 砂眼准确率:91.53%(23.8% ↑)	胶衣损伤检测准确率较低
[85]	VGG+CAM,SAM	裂纹、砂眼、胶衣损伤	二分类准确率:95.56%(4.17% ↑) 多分类准确率:92.86%(5.36% ↑)	
[88]	多特征融合 ResNet	脱胶、表面侵蚀、油漆磨损、油污	准确率:93% 脱胶 F1-Score:91.8%(22.9% ↑)	特征增多降低模型分类速度
[89]	DMnet	裂纹、胶衣损伤、涂层破损	可由小数据集快速训练	准确度较低

## 5.2 检测网络

目标检测网络是一种可识别多种目标并由外接矩形框确定目标位置并分类的深度学习网络。该方法可分为单阶段与双阶段。这 2 类检测网络被广泛用于无人机航拍的风机叶片表面缺陷检测中。

### 1) 单阶段目标检测方法

单阶段方法直接通过端到端的方式从输入图像中输出目标框和分类结果,可简化流程并减少运算量。常用模型有 SSD 算法<sup>[90]</sup>与 YOLO 系列<sup>[91-97]</sup>算法等。

#### (1) 基于 SSD 算法

SSD 算法采用 VGGNet 作为主干网络,并使用多尺度多长宽比的密集锚点设计和特征金字塔提升小目标检测能力,可以通过优化主干网络、特征提取方法提升缺陷检测效率与准确率。文献[98]采用 ResNext101 网络作为主干网络检测胶衣损伤、涂层破损、油漆磨损、油污,但油污的检测准确率低。文献[99]提出的 EADD 模型采用由分比式深度可分离瓶颈(factorized depth-wise separable bottleneck, FDSB)和特征聚合模块(feature aggregation module, FAM)改进的 ResNet 作为主干网络,并在颈部引入双向特征金字塔网络(bidirectional feature pyramid network, BiFPN)获得更多特征表达,但算法速度低于 YOLOv4 模型,随着 YOLOv4 与后续版本出现,SSD 逐渐被替代。

#### (2) 基于 YOLO 系列算法

YOLO 系列算法通过回归空间分离的边界框和相关类别概率检测目标,具有速度快、架构简单等特点。当前该系列算法快速发展并成为无人机航拍的风机叶片表面缺陷检测首选检测网络。

YOLOv3<sup>[92]</sup>引入了特征金字塔网络(feature pyramid network, FPN)级联特征并引入预测框机制提升检测精度与速度,该模型的研究主要为提升多类缺陷检测效率,其改进集中于增加模型对特征的关注。

为提升微小缺陷的检测效果,文献[100]提出了加入多尺度特征金字塔的 YSODA 模型以提升裂纹、砂眼和油污的检测精度,但漏检率较高。为加强低分辨率图像特征提取能力,文献[101]结合超分辨率卷积神经网络(super-resolution convolutional neural network, SRCNN)提升缺陷的检测效果,但缺少具体缺陷效果对比。文献[102]在 YOLOv3 连接层后加入挤压与激励网络(squeeze-and-excitation networks, SENet)使网络更关注缺陷相关特征通道,并由缺陷特点调整锚框比例,从而有效提升雷击破损、划痕检测准确率,但胶衣损伤与污垢的准确率较低。

YOLOv4<sup>[93]</sup>优化了数据增强,网络正则化办法与损失函数并加入空间金字塔池化网络(spatial pyramid pooling, SPP)、交叉阶段部分网络(cross stage partial network, CSPNet)等结构提升模型检测精度。该模型的研究主要为实现模型轻量化并提升检测实时性,其改进

主要集中于对主干网络、锚框的调整。

文献[103]降低了主干网络宽度并在 SPP 中采用空洞卷积以降低模型的内存占用,但微小裂纹检测召回率较低,易导致漏检。文献[104]采用轻量级网络 MobileNetv1 作为主干网络并引入 SENet、CBAM 等注意力机制提升缺陷检测效率,但会使模型召回率降低导致漏检。文献[105]提出并采用降低 GHostNet<sup>[106]</sup>网络权重的 Tiny-GhostNet 作为主干网络并降低预定义锚框覆盖密度,在略微损失准确率的情况下有效降低参数量,但未讨论各类缺陷检测效果。

YOLOv5 相较于前几个版本,在图像增强、损失函数与正则化方法等方面进行了改进并引入 C3 模块提高模型多尺度特征融合与跨通道信息传递能力。YOLOX<sup>[94]</sup>在网络结构与解耦头部分进行了优化,其参数更少,速度更快。针对以上两种模型的研究主要为提升模型对小目标、浅色、低分辨率、低清晰度缺陷的检测能力,其改进主要集中于提升模型对缺陷特征的提取与融合能力。

为提升小目标和长条类缺陷检测准确度,文献[107]提出了 SOD-YOLO 模型,该模型在 YOLOv5 中增加了 4 种微尺度检测层并结合 K-means 进行聚类,在特征融合层引入 CBAM 以突出复杂背景下叶片表面缺陷特征,有效提升了检测效果,但模型较大。为提升对砂眼和污垢等小目标的检测能力,文献[108]提出了 AFB-YOLO 模型,该模型在 YOLOv5s 中改进了特征金字塔并引入坐标注意力机制(coordinate attention, CA)以及采用高效交并比(enhanced intersection over union, EIou)损失函数进行检测,但数据集采用的实际图片仅为 559 张。为提升浅色与低清晰度的裂纹检测能力,文献[109]基于 YOLOv5 提出了 MI-YOLO 模型。该模型将 C3 模块替换为采用 TransformerBlock Calss 的 C3TR 模块并引入 Alpha-IOU 损失函数,但未对模型检测速度与模型参量讨论。为提升复杂背景图像检测能力与检测速度,文献[110]基于 YOLOv5s 提出 YOLOv5s\_MCB 模型,该模型采用 MobileNetv3 作为主干网络并引入 CBAM、BiFPN 增强对裂纹、砂眼、污垢等缺陷的检测能力,同时采用高效交并比(enhanced intersection over union, EIou)损失函数,但图像颜色区分度不大时,该模型会出现误判,如颜色较亮的锈迹会被误判为裂纹。文献[111]提出一种通过人工复检对 YOLOv5l 模型进行迭代调整的模型训练策略从而可使模型检测更准确,但会增加训练复杂度且错检时面积计算误差大。为改善浅色和低分辨率图像的特征提取,文献[112]提出一种具备尺度、空间以及任务感知注意力的动态头部模块 DyHead 从而提高 YOLOv5s 缺陷检测的精度,但缺少缺陷对比。随着 Transformer<sup>[113]</sup>的提出,为提升对裂纹、砂眼等小尺寸缺陷的检测速度与精度,文献[114]在 YOLOv5s 中引入 Transformer、CA 以及轻量级

卷积技术提出 YOLOv5s\_TGW 模型并采用 WIoU 损失函数,其参数量有所降低,但检测会受图像角度影响。

为提升小目标缺陷检测召回率和检测速度,文献[115]提出了一种轻量级模型 WT-YOLOX,该模型引入 RepVGG 作为主干网络,并在颈部加入级联特征融合模块(cascade feature fusion module, CFFM)融合多尺度输入特征,但数据集采用的实际图片仅为 725 张。文献[116]在 YOLOX 基础上加入双向特征融合网络和注意力机制模块从而提出 RBi-YOLOX 模型,该模型对裂纹、砂眼、油污等缺陷的检测精度与速度显著提升,但数据集采用的实际图片仅为 560 张,可考虑采用更多不同的风机图像提升模型鲁棒性与泛化能力。

YOLOv7<sup>[96]</sup>模型引入了 bag-of-freebies 理念并丰富了各阶段特征图大小和通道,使模型在不增加检测成本的前提下提高检测准确性。YOLOv8<sup>[97]</sup>在主干网络、检测头和损失函数等方面进行了创新。针对以上两种模型的研究主要为提升模型对多尺度目标等缺陷的检测能力,其改进主要集中于提升模型对缺陷特征融合能力以及应用可见光与红外图像融合方法。

为提升对涂层破损、油漆磨损以及雷击破损等多尺度目标检测精度,文献[117]通过在 YOLOv7-Tiny 中引入 CBAM 以及额外 YOLO 头,提出了 YOLO-Tiny-attention 模型,但使模型大小增加并降低了模型检测速度。文献[118]在 YOLOv8 主干网络中加入 C2f-FocalNextBlock 模块并在颈部网络中引入细颈结构与 ResNet-EMA 模块从而更好地跨纬度融合目标特征。但仅将数据划分为污垢和损伤,缺陷分类较为简单。此外,随着红外检测的发展,通过融合红外图像可为模型提供更多特征。文献[119]设计了一个即插即用的自适应 RGB 和红外图像特征融合模块,并通过与 YOLOv7 模型结合达到了 99% 的检测精确率,但未进行缺陷分类,仅实现二分类检测。

### (3) 其他算法

EfficientNet<sup>[120]</sup>目标检测方法具有参数数量少、计算效率高等优点,文献[121]通过减少其主干网络的下采样次数并加入 BiFPN 增加特征融合路径。在不减慢算法速度的情况下,对斑点与裂纹的检测精确率提到了提升,但检测速度慢于 YOLOv4 模型。

DINO<sup>[122]</sup>模型是一种基于 DETR<sup>[123]</sup>的改进模型,该模型通过引入改进的去噪锚框机制提高了小物体检测的性能并降低训练数据量,文献[124]在其基础上加入下采样并在残差块间添加增强通道注意力(efficient channel attention, ECA)模块从而提出 WTB-DINO 模型,该模型可实现较高平均准确率的裂纹、胶衣损伤、脱胶与雷击破损的实时视频检测。尽管模型参数量有所下降,但仍然较大。

上述单阶段目标检测方法总结如表 12 所示。

综上,在当前采用的各种单阶段模型检测无人机航

拍的风机叶片表面缺陷的研究侧重各有差异,在面对实际应用时,应需根据要求选用模型。

### 2) 双阶段目标检测方法

双阶段目标检测方法可分为生成候选区域以及对区域进行分类与定位两个阶段,其相对于单阶段方法具有更高的检测精度,但运算复杂度和处理时间也相应增加。

Faster R-CNN<sup>[125]</sup>模型是双阶段检测方法的经典代表,其可分为提取特征的特征提取网络模块、生成候选框的区域候选网络模块、用于筛选的兴趣域池化模块以及获取最终缺陷候选框与精确位置的分类与回归模块。为提升检测准确率,文献[126]采用 Inception-ResNet-V2 作为主干网络检测,但小目标缺陷检测效果较差并且计算成本较高。为解决这些问题,文献[127]在模型中加入反向注意力探索模块(reverse-attention exploration module, REM)和区域特定上下文学习模块(region-specific context learning module, RCLM)提升了对污垢、损伤类小目标的检测平均准确率,但严重减低模型识别速度,FPS 由 25 降为 8。

Cascade R-CNN<sup>[128]</sup>通过级联多个 R-CNN 阶段并采用不同的 IoU 阈值计算正负样本逐步提高检测框的质量。文献[129]通过结合可变形卷积和可变形 RoI Align 提出 CAD Cascade R-CNN 模型。模型引入 3 个附加的 RoI 对齐层解决因层数多而导致的特征丢失问题,并采用 PreLU 激活函数从而有效提升裂纹、胶衣损伤和油污的检测精度,但未对模型参数以及检测速度进行讨论。

综上,双阶段目标检测方法模型参数较多,检测速度慢,导致其并不适合部署在无人机进行识别,故相关研究相比单阶段较少。上述叶片缺陷图像双阶段目标检测方法对比如表 13 所示。

## 5.3 分割网络

分割网络通过对图像每个像素点进行分类实现缺陷的分割并提供缺陷面积、轮廓等几何信息用于进一步分析,其可根据是否区分个体分为实例分割与语义分割,针对该类网络的研究主要集中于对大面积、不规则缺陷进行分割与识别。

Mask R-CNN<sup>[130]</sup>是一种可同时分割物体与检测的分割算法。文献[131]比较了 Mask R-CNN、YOLOv3 和 YOLOv4 对裂纹、边缘侵蚀、砂眼等缺陷的分割检测效果,结果表明 Mask R-CNN 在所有评价指标上效果最好。

为提升对面积大且形状不规则缺陷的分割效果,文献[132]提出了 Mask R-CNN-512 算法。该算法将特征提取网络从 ResNet101 改为 ResNet50 并将网络头部神经元个数减半,但未实现缺陷具体分类。文献[133]针对脱胶、边缘侵蚀、油漆磨损和油污中的大目标检测,提出了 Mask-MRNet 分割网络,该网络由 Mask R-CNN 提取缺陷掩膜,并使用 MRNet 修正故障掩膜角度,再通过 MinReact 方法来裁剪出低噪声的特定缺陷图像,但是

表 12 风机叶片缺陷图像单阶段目标检测方法

Table 12 Comparison of common single-stage detection network methods of wind turbine blades

文献	具体方法	创新点	缺陷分类	改进效果	局限性
[98]	SSD	ResNext101 作为主干网络	胶衣损伤、涂层破损、油漆磨损、油污	检测时间:192 ms(156 ms ↓) AP:87.8%(7.2% ↑)	油污检测准确率仅 76%
[99]	EADD	含 FDSB 与 FAM 的 ResNet 作为主干网络,引入 BiFPN	开裂、胶衣损伤、涂层破损	mAP:81.2%(6.2% ↑) 参数量:8.3 M(15.6 M ↓)	检测速度低于 YOLOv4
[100]	YSODA	加入新卷积层以及多尺度特征金字塔	裂纹、砂眼、油污	整体准确率:91.3%(2.6% ↑)	漏检率 3.5%
[101]	YOLOv3	结合 SRCNN	裂纹、砂眼、油污、避雷器缺损	平均精度:95.6%	缺少缺陷对比
[102]	YOLOv3	引入 SENet 并调整锚框比例	裂纹、划痕、胶衣损伤、雷击破损、污垢	雷击 AP:95.11%(10.54% ↑) 划伤 AP:93.08%(12.65% ↑)	胶衣损伤 AP 仅 61.23%
[103]	YOLOv4	改进主干网络宽度,采用空洞卷积	裂纹、砂眼、胶衣损伤、开放式撕裂	内存占用降低 14.7% AP:87.7%(6% ↑)	微小裂纹召回率仅 61.1%
[104]	YOLOv4	MobileNetV1 作为主干网络、SENet、CBAM 等多种注意力机制	裂纹、胶衣损伤、表面粗糙化、油漆磨损、修复痕迹	mAP:93.44% 模型大小:48.92 MB(197.11 MB ↓)	召回率下降 28.83%
[105]	YOLOv4	提出并采用 Tiny-GhostNet 主干网络并降低预定义的锚框覆盖密度	裂纹、胶衣破损、涂层破损、修复痕迹、风痕	mAP:77.80%(3.4% ↓) 模型大小:27 MB(63 MB ↓)	缺少缺陷对比
[107]	SOD-YOLO	4 种微尺度检测层并在特征融合层增加 CBAM	斑点、胶衣损伤、油漆磨损、油污	召回率:94.80%(15.24% ↑) mAP:95.15%(7.82% ↑) 模型大小:37.8 MB	参数量较大
[108]	AFB-YOLO	改进特征金字塔,引入 CA 并采用 EIoU	砂眼、污垢	mAP@0.5:83.7%(2.8% ↑) F1-Score:82.7%(1.8% ↑) 模型大小:11.6 MB	数据集采用的实际图片较少
[109]	MI-YOLO	引入 C3TR 与 Alpha-IOU	裂纹	mAP:93.2%(2.2% ↑)	未讨论速度与模型参数量
[110]	YOLOv5s_MCB	MobileNetV3 作为主干网络并引入 CBAM、BiFPN 以及 WIoU	裂纹、砂眼、污垢、雷击、边缘侵蚀	mAP:90.15%(5.51% ↑) FPS:71.15(10.79 ↑) 参数量:8.41 M(5.28 M ↓)	易误判颜色区分不大的图像
[111]	YOLOv5l	引入人员反馈	涂层破损、凹坑、油污、避雷器缺损、风痕	mAP@0.5:93.53%	增加训练复杂度且错检时面积计算误差大
[112]	改进 YOLOv5s	提出并采用 DyHead 头部模块	裂纹、胶衣破损、边缘侵蚀、避雷器缺损	mAP@0.5:79.2%(2.9% ↑)	缺少缺陷对比
[114]	YOLOv5s_TGW	采用 Transformer、CA、轻量级卷积与 WIoU	裂纹、砂眼、污垢、油污、油漆磨损	mAP:86.81%(4.14% ↑) FPS:75.51(19.88 ↑) 参数量:12.07 M(2.29 M ↓)	检测时会受图像角度影响
[115]	WT-YOLOX	RepVGG 作为主干网络,在颈部加入 CFFM	裂纹、开裂、污垢、维修	mAP@0.5:94.29%(2.95% ↑)	数据集采用的实际图片较少
[116]	RBi-YOLOX	引入多种注意力模块	裂纹、砂眼、油污、边缘侵蚀	mAP@0.5:95.03%(4.41% ↑) FPS:54.56(7.28 ↑)	数据集采用的实际图片较少
[117]	YOLO-Tiny-attention	引入 CBAM 并增加额外 YOLO 头	涂层破损、边缘侵蚀、叶尖破损	边缘侵蚀 mAP:88.03%(27.9% ↑) 涂层破损 mAP:92.31%(15.06% ↑)	模型大小提升并使速度下降
[118]	YOLOv8	主干网络中引入 C2f-Focal-NextBlock 模块,颈部引入细颈结构与 ResNet-EMA 模块	污垢、损伤	mAP@0.5:79.9%(4.8% ↑)	缺陷分类较为简单
[119]	YOLOv7	自适应 RGB 和红外图像特征融合模块	未分类	AP:98.5%(25.5% ↑)	未缺陷分类
[121]	EfficientNet	减少了主干网络的下采样次数并加入 BiFPN	裂纹、斑点、油污	斑点 AP:91.87(6.08% ↑) 裂纹 AP:96.77(5.42% ↑)	检测速度慢于 YOLOv4
[124]	WTB-DINO	加入下采样与 ECA	裂纹、胶衣损伤、脱胶、雷击破损	AP:93.2%(2.86% ↑) 参数量:31 M(16 M ↓)	模型参数量大

表 13 风机叶片缺陷图像双阶段目标检测方法

Table 13 Comparison of common two-stage detection network methods of wind turbine blades

文献	方法	创新点	缺陷分类	改进效果	局限性
[126]	Faster R-CNN	采用 Inception-ResNet-V2 作为主干网络	裂纹、边缘侵蚀、避雷器缺损	mAP:81.1% 检测时间:2.11 s	对小目标缺陷检测效果较差并且计算成本较高
[127]	Faster R-CNN	引入 REM 与 RCLM	污垢、损伤	AP:90.2% (4.8% ↑)	模型识别速度降低,且检测的缺陷种类少
[129]	CAD Cascade R-CNN	引入 RoI Align 并采用 PreLU 激活函数	裂纹、胶衣损伤、油污	mAP@0.5:92.1% (11.2% ↑)	未讨论模型参数与检测速度

采用两次特征提取的方式会导致计算冗余。

文献[134]在 Cascade R-CNN 基础上提出了一种分割模型 Cascade Mask R-CNN 用于检测裂纹、胶衣损伤、边缘侵蚀、雷击破损、锈蚀等缺陷。该模型引入 FPN 和 ResNet50 作为主干网络,并将普通卷积替换为深度可分离卷积(depthwise separable convolution, DSC)。模型在减少参数的同时有效提高了边缘侵蚀平均精度均值,但对锈蚀类缺陷检测平均精度较低,仅为 74.34%。

U-Net<sup>[135]</sup>是一种采用多尺度特征融合的轻量级分割网络,文献[136]将其与 VGG 的网络 VGG16Unet 结合。通过迁移学习实现小数据集训练条件下裂纹、砂眼、脱胶和边缘侵蚀的分割和检测,但未对模型参数数量与分割时间进行讨论。

SegFormer<sup>[137]</sup>是一种基于 Transformer 结构的语义分

割模型,文献[138]将该模型与在线难例挖掘(online hard example mining, OHEM)算法结合从而提出 SegFormer-OHEM 模型,模型能够减少环境影响并能提升砂眼、裂纹的检测平均精度,但未对模型分割速度与参数数量进行讨论。

综上,相较分类与检测网络,分割网络在无人机航拍的风机叶片表面缺陷检测中主要针对叶片表面的大面积不规则缺陷进行分割与检测。此外,该方法也存在样本标注要求高、模型训练时间长等问题。上述叶片缺陷图像分割网络方法对比如表 14 所示,基于深度学习的航拍叶片表面缺陷检测方法时间线如图 7 所示。可以看出,近年来检测与分割算法研究较多,其中,YOLOv5、YOLOv8、DINO 等单阶段模型、SegFormer 等分割模型采用较多,读者可以在相关方面进行探索。

表 14 风机叶片缺陷图像分割网络方法

Table 14 Comparison of commonly used segmentation network methods of wind turbine blades

文献	具体方法	创新点	缺陷分类	改进效果	局限性
[132]	Mask R-CNN-512	使用 ResNet50 特征提取网络并减少网络头部神经元个数	面积大、形状不规则缺陷	检测时间:139 ms (161 ms ↓) 边界框 AP:89.8% (2.2% ↑) 掩膜 AP:60.8% (10.7% ↑)	未对缺陷分类
[133]	Mask-MRNet	引入 MRNet 与 MinReact 方法	脱胶、边缘侵蚀、油漆磨损、油污	大目标掩膜 AP:62.8% (9.2% ↑)	两次特征提取的方式会导致计算冗余
[134]	Cascade Mask R-CNN	引入 FPN 和 ResNet50 作为主干网络,并采用 DSC 代替普通卷积	裂纹、胶衣损伤、边缘侵蚀、雷击破损、锈蚀	模型大小:128.9 MB (60.4 MB ↓) 边缘侵蚀 mAP:93.27% (6.48% ↑)	对锈蚀类缺陷检测平均精度较低
[136]	VGG16Unet	结合 U-Net 与 VGG 并采用迁移学习方法	裂纹、砂眼、脱胶、边缘侵蚀	IoU:89.2% (19.12% ↑) mPA:95.33% (13.55% ↑)	未讨论模型参数数量与分割时间
[138]	SegFormer-OHEM	结合 SegFormer 与 OHEM	裂纹、砂眼、边缘侵蚀、胶衣损伤	砂眼 IoU:96.63% (2.98% ↑) 裂纹 IoU:93.53% (1.55% ↑)	未讨论模型参数数量与分割时间

## 6 无人机航拍的风力发电机叶片表面缺陷数据集及评估指标

### 6.1 数据集

数据集是进行缺陷识别的基础。由于风机分布存在

很大的地域性差异且缺陷类型繁多,所以选择一个符合目标风机环境以及缺陷检测类别的数据集非常关键。目前互联网上有着一些公开数据集,并有一些作者在论文中公开了数据集。数据集内容如表 15 所示,其中 DTU-Drone 数据集为最早公开的无人机风机叶片表面缺陷数据集,因此对于该数据集进行的研究最多,该数据集的各

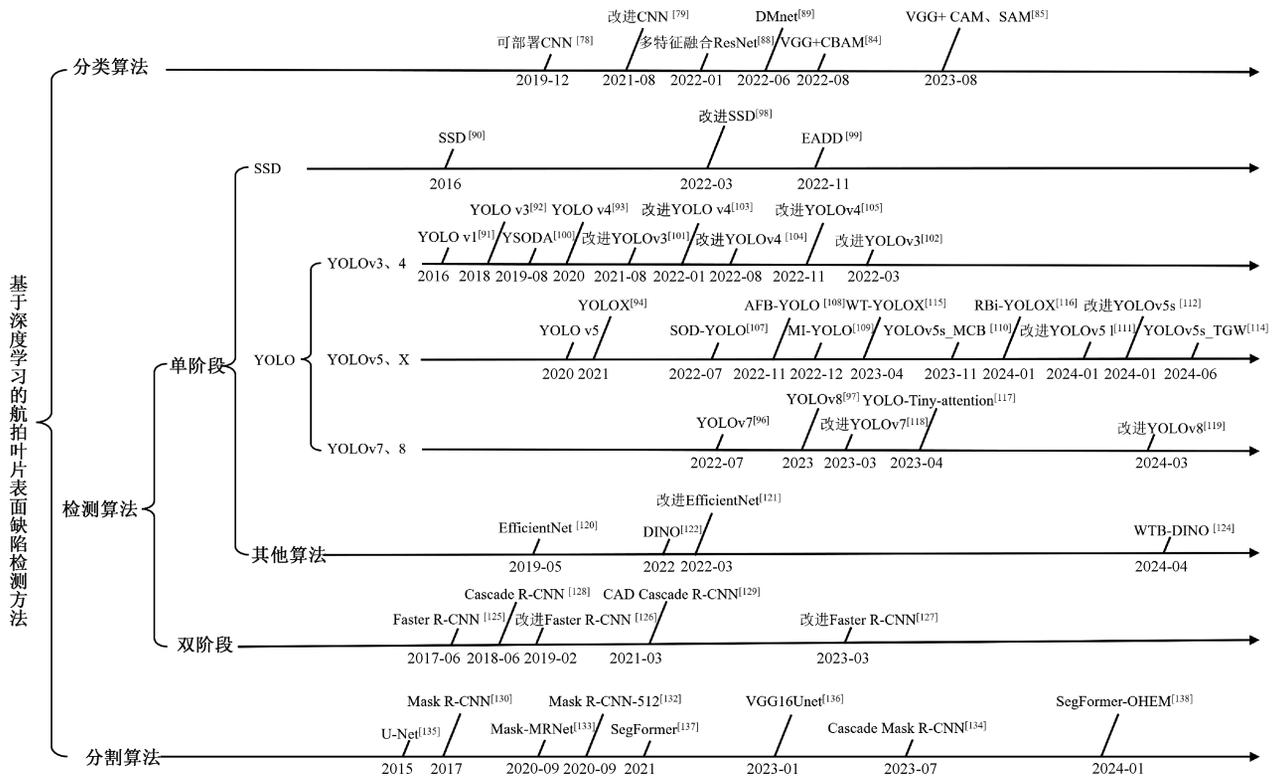


图 7 风机叶片缺陷图像深度学习方法时间线

Fig. 7 Timeline of deep learning methods for wind turbine blade defect images

表 15 无人机风机叶片表面缺陷数据集  
Table 15 Drone wind turbine blade surface defect data set

名称	来源	年份	缺陷类别	样本数	分辨率	标注格式	获取地址
DTU-Drone	Mendeley Data	2018	裂纹、胶衣损伤、边缘侵蚀、避雷器缺损等	559	5 280×2 970	未标注	<a href="https://data.mendeley.com/datasets/hd96pm3nc/1">https://data.mendeley.com/datasets/hd96pm3nc/1</a>
YOLO Annotated Wind Turbine Surface Damage	Kaggle	2019	裂纹、涂层破损、边缘侵蚀、避雷器缺损、污垢等	13 000	586×371	YOLO	<a href="https://www.kaggle.com/datasets/ajifoster3/yolo-annotated-wind-turbines-586x371">https://www.kaggle.com/datasets/ajifoster3/yolo-annotated-wind-turbines-586x371</a>
WTBDI	论文	2019	胶衣损伤、边缘侵蚀、油漆磨损、油污	25 773	5 472×3 684	矩形框标签	<a href="https://pubs.aip.org/aip/jrse/article/11/5/053305/148817/Wind-turbine-blade-surface-inspection-based-on">https://pubs.aip.org/aip/jrse/article/11/5/053305/148817/Wind-turbine-blade-surface-inspection-based-on</a> [83]
航拍数据集	论文	2020	裂纹、前缘侵蚀、避雷器缺损	746	416×416	VOC	<a href="https://link.springer.com/article/10.1007/s12652-020-02587-7">https://link.springer.com/article/10.1007/s12652-020-02587-7</a> [101]
结冰数据集	论文	2022	叶片结冰	278	128×128	未说明	<a href="https://www.sciencedirect.com/science/article/pii/S0960148121014828#sec3">https://www.sciencedirect.com/science/article/pii/S0960148121014828#sec3</a> [87]
裂纹数据集	论文	2022	裂纹	1 023	640×640	YOLO	<a href="https://www.sciencedirect.com/science/article/pii/S0306261922014982">https://www.sciencedirect.com/science/article/pii/S0306261922014982</a> [109]
Wind Turbine-Damage new	Roboflow	2023	裂纹、涂层破损、雷击破损	2 248	640×640	YOLO、VOC	<a href="https://universe.roboflow.com/sakethhxv7uo/windturbine-damage-new-auklj">https://universe.roboflow.com/sakethhxv7uo/windturbine-damage-new-auklj</a>
航拍数据集	论文	2023	裂纹、涂层破损	2 577	未说明	矩形框标签	<a href="https://pubs.aip.org/aip/jrse/article-abstract/15/4/043305/2904888/Early-stage-damage-detection-of-wind-turbine">https://pubs.aip.org/aip/jrse/article-abstract/15/4/043305/2904888/Early-stage-damage-detection-of-wind-turbine</a> [124]
Blade30	GitHub	2023	裂纹、砂眼、边缘侵蚀	1 302	未说明	矩形框标签	<a href="https://github.com/cong-yang/Blade30">https://github.com/cong-yang/Blade30</a>
Small-WTB-Thermal1	GitHub	2024	裂纹、砂眼、边缘侵蚀	1 000	320×320	矩形框标签	<a href="https://github.com/MoShekaramiz/Small-WTB-Thermal1">https://github.com/MoShekaramiz/Small-WTB-Thermal1</a>

表 16 DTU-Drone 数据集算法结果比较  
Table 16 DTU-Drone dataset algorithm comparison (%)

方法	Backbone	mAP	AP	Recall	Precision	F1-Score	IoU
SSD	VGG-16	61.4	-	49.6	85.2	62.7	-
YOLOv3	Darknet-53	75.6	-	66.1	80.8	72.7	-
YOLOv4	CSPDarknet53	69.1	-	63.1	76.2	69.0	-
YOLOv5s	CSPDarknet	80.5	-	79.0	82.9	80.9	-
AFB-YOLO[108]	CSPDarknet	83.7	-	82.0	83.4	82.7	-
改进 YOLOv5s[112]	CSPDarknet	79.2	-	-	-	-	-
YOLOv7	E-ELAN	75.7	-	71.4	81.9	-	-
YOLOv8n	CSP-Darknet	76.9	-	71.7	82.3	-	-
改进 YOLOv8[118]	CSP-Darknet	79.9	71.1	73.8	84.8	-	-
Faster R-CNN	ResNet-50	58.3	-	70.0	41.1	51.8	-
改进 Faster R-CNN[126]	Inception-ResNet-V2	81.1%	-	-	81.10	-	-
改进 Faster R-CNN[127]	ResNet-50	-	83.0	-	-	-	-
Mask R-CNN	ResNet-50	62.0	-	66.0	59.7	62.7	-
Cascade Mask R-DSCNN[134]	ResNet-50-FPN	84.36	-	-	-	-	89.37

算法结果比较如表 16 所示。

由于不同的检测任务针对的缺陷、风机型号以及环境存在较大差异,可能对模型训练效果存在巨大影响,因此表 15 数据集仅供研究参考,请读者根据实际需求进行选取或组合。

## 6.2 评估指标

### 1) 分类任务评估指标

分类任务中需要对样本进行二分类或多分类。在针对风机叶片进行缺陷分类的主要目的是将实际为缺陷的样本分类为缺陷,将实际不是缺陷的样本分类为正常。然而,由于分类器不能完全做到准确分类,会出现以下 4 种情况:实际正样本预测为正样本(true positive, TP)、实际正样本预测为负样本(false negative, FN)、实际负样本预测为正样本(false positive, FP)、实际负样本预测为负样本(true negative, TN)。在本文中,将含有缺陷的样本设为正样本,将不含缺陷的正常样本设为负样本,如表 17 所示。

表 17 分类评估符号

Table 17 Binary evaluation notation

类别	实际为缺陷	实际为正常
分类为缺陷	TP	FP
分类为正常	FN	TN

结合分类任务以及本文采用的分类方法,具体的评价指标如表 18 所示。

在本文所综述的方法中,通常采用准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1 值(F1-Score)、时间(Times)评估分类效果。

### 2) 缺陷目标检测任务评估指标

在目标检测任务中,不仅需要对样本进行分类,还需对缺陷进行框选,因此评价指标更为复杂。故在分类的评估指标的基础上,引入了交并比(IoU),其含义为检测模型输出图像的缺陷矩形框与数据集标注的缺陷矩形框的交集与并集的比值。公式如下:

$$IoU = \frac{A \cap B}{A \cup B} \quad (2)$$

为评估生成的矩形框是否满足检测要求,通常设置 IoU 阈值。例如, IoU 阈值为 0.5 时,大于该阈值的检测框被识别为真正例(TP),小于该阈值的被识别为假正例(FP)。在单类或多类缺陷检测时,采用  $AP@ a$ 、 $mAP@ a$  进行评估,其中  $a$  为 IoU 阈值且  $0 < a < 1$ 。

### 3) 图像分割检测任务评估指标

在对图像进行分割时相对于目标检测要求更加严苛,因此需要额外的评价指标,如表 19 所示。

## 7 面临的挑战与展望

### 7.1 面临的挑战

目前,基于无人机航拍的风机叶片表面缺陷检测方面仍存在很多问题:

#### 1) 机器学习训练样本匮乏且不平衡

表 18 目标分类评估指标  
Table 18 Evaluation index of image classification

指标	含义	公式
准确率 (Accuracy)	分类正确的样本占所有样本的比例	$Acc = \frac{TP + TN}{TP + FP + FN + TN}$
精确率 (Precision)	分类为缺陷的样本中实际为缺陷的样本所占的比例	$Precision = \frac{TP}{TP + FP}$
召回率 (Recall)	实际缺陷样本中分类为缺陷的样本所占的比例	$Recall = \frac{TP}{TP + FN}$
F1 值 (F1-Score)	精确率与召回率的调和平均, 值越大越好	$F1 = 2 \frac{precision \times recall}{precision + recall}$
误报率 (FPR)	实际正常样本中分类为缺陷样本所占比例	$FPR = \frac{FP}{FP + TN}$
误检率 (FNR)	分类为正常样本中实际正常样本所占比例	$FNR = \frac{FN}{FN + TP}$
平均准确率 (AP)	每个类别不同召回率点上的准确率的均值	$AP = \sum_{i=1}^{n-1} (r_{i+1} - r_i) P_{inter}(r_i + 1)$
平均精度均值 (mAP)	进行多类别分类时各类 AP 的均值, 值越大越好	$mAP = \frac{\sum_{i=1}^k AP_i}{k}$
时间 (Times)	完成一次分类需要的时间	-
帧率 (FPS)	每秒内分类完成的次数	-

表 19 图像分割任务评估指标

Table 19 Evaluation index of image segmentation

指标	含义	公式
像素 准确率	分割后类别正确像素数占总像素数的比例	$PA = \frac{\sum_{i=0}^k P_{ii}}{\sum_{i=0}^k \sum_{j=0}^k P_{ij}}$
平均像素 准确率	分割后每个类被正确分类像素数的比例	$mPA = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{i=0}^k P_{ij}}$
Dice 系数	计算分割后样本与标准样本的相似度	$Dice = \frac{\frac{2}{k+1} \sum_{i=1}^{k+1} P_i \times \frac{1}{k+1} \sum_{i=1}^{k+1} R_i}{\frac{1}{k+1} \sum_{i=1}^{k+1} P_i + \frac{1}{k+1} \sum_{i=1}^{k+1} R_i}$

良好的缺陷检测模型需要大量的样本数据, 而目前公开无人机航拍数据集较少且针对风机叶片表面缺陷类型不同, 其中多为针对裂纹、边缘侵蚀等。而可能导致严重后果的结构性缺陷、螺栓断裂等缺陷数据量较少, 使得各类缺陷的数量不平衡, 导致检测模型效果达不到实际部署需求。

## 2) 天气、地区环境、缺陷类型差异大

由于受气候影响, 同一地区风机在不同季节、不同天

气下获取的图像背景差异大。如阴天使得缺陷特征更难被提取, 雪天白色的背景使得叶片更难被识别。除此之外, 由于运行地区环境不同, 风机叶片需重点检测的表面缺陷类型也不同。如沙漠地区的风机叶片磨损较为严重, 而海上或山区则为涂层破损较为严重。目前国内还没有能够针对全部天气、地区环境、缺陷类型的视觉检测模型。

## 3) 风机型号差异大

风机型号差异巨大, 其单机容量可小到几千瓦, 大到数十兆瓦。叶片长度可从 10 m 到超过 150 m。不同型号风机的叶片结构、材料可能不同, 这使得采用无人机进行拍摄时需设计不同巡检方案, 并且需要检测的缺陷类型可能不同。

## 4) 无人机叶片拍摄问题

由于风机部署的地区风速较大。受风的影响, 无人机可能无法在空中完全停稳使得机载相机无法进行完全的聚焦, 从而导致拍摄的图像存在模糊的情况, 这将对缺陷分析带来一定的影响。若风速较大, 无人机可能撞到叶片或失控而产生财产损失。同时, 无人机拍摄叶片的角度等因素也会对缺陷检测带来影响。

## 5) 海上风机研究较少

由于海上风力资源丰富, 国内外都在积极发展海上风机。然而海上风机叶片在运行中易受海水侵蚀而产生

缺陷,但其检测需要在相较陆地更恶劣的环境下使用特殊船只与设备,因此难度较大,相关研究较少。

## 7.2 技术展望

针对存在的问题,可以从以下方面进行改进:

### 1) 扩充数据集或减少数据依赖

针对风机叶片表面缺陷数据集匮乏的问题,可以采用数据增强技术或生成对抗网络(generative adversarial networks, GAN)扩充数据集或通过整合公开数据集和个人数据集,提升数据量与多样性,也可通过在 COCO 等公开大型数据集上进行预训练并由少量数据对模型进行微调,能够显著提高识别效果。此外,通过加入多种注意力机制与特征融合模块增强模型的特征提取与学习能力也可以减少模型对于数据的依赖。

### 2) 开展多环境、多型号风机、多种缺陷类型的缺陷检测研究

目前的研究多针对单一环境或风机类型。随着公开数据集的增加,可以开展针对不同环境、不同类型风机的叶片缺陷检测研究,并通过更细致的缺陷分类,提升识别的精确度和适用性。

### 3) 针对风机专用检测无人机进行开发与研究

当前缺乏专用于风机巡检的无人机,建议研发抗风能力强、续航时间长、具备拍摄和测量功能的专用无人机。同时,开发相应快速图像处理 and 实时识别算法并部署在无人机上,从而避免拍摄过程中出现的模糊和雾气等问题影响,提升检测效率。

### 4) 优化无人机巡检路径

随着风机塔筒高度和叶片长度增加,无人机巡检时长不断增加。无人机巡检路径优化已成为研究热点,可以研究单架次、多架次无人机对单风机、多风机及多地区风机的巡检路径优化,以及多无人机协同检测策略。同时通过巡检策略的调整,避免无人机拍摄的图像受拍摄角度、背景的影响。

### 5) 开展海上风机研究

海上风机检测环境较为恶劣。建议开发适用于海上风机的无人机或遥控潜水器,并研究针对恶劣环境的图像处理办法。此外,也可研究海上风机叶片的巡检策略,降低维护成本。

## 8 结 论

风力发电作为未来新能源转型的重要组成部分,叶片是直接影响风机发电效率的关键组件。因此,对风机叶片表面进行全面的缺陷检测至关重要。本文对风机叶片材料、结构、长度与型号特点以及可能出现的表面缺陷类别进行了详细综述。并对风机叶片表面缺陷检测技术进展进行讨论,每次技术的进步都有效提高了缺陷检

测效果。同时,越来越多的研究人员正在探索更多检测方法,推动风电产业向高效、高水平、高质量方向发展。

本文综述了近几年来国内外关于无人机航拍的风机叶片表面缺陷检测的主要方法。以航拍图像作为数据来源,首先阐述了传统图像处理与机器学习方法在风机叶片表面缺陷检测中有关叶片表面图像拼接、分割以及特征提取与分类方面的发展情况,然后总结了基于深度学习的分类、检测、分割方法进行叶片表面缺陷识别的进展。接着,提供了相关数据集与评价指标并从数据、无人机、海上风机检测等方面出发,指出当前存在的问题并给出相应解决方案。希望本文能够为读者带来关于无人机风机叶片表面缺陷检测的相关知识,并为在此领域开展相关工作的研究者们提供启迪。

## 参考文献

- [1] DIMITROVA M, AMINZADEH A, MELABADI M S, et al. A survey on non-destructive smart inspection of wind turbine blades based on industry 4.0 strategy[J]. *Applied Mechanics*, 2022, 3(4):1299-1326.
- [2] CAWLEY P. Structural health monitoring: Closing the gap between research and industrial deployment[J]. *Structural Health Monitoring*, 2018, 17(5):1225-1244.
- [3] 何赞泽,李响,王洪金,等. 基于可见光和热成像的风机叶片全周期无损检测综述[J]. *机械工程学报*, 2023,59(6):32-45.  
HE Y Z, LI X, WANG H J, et al. A review: Full-cycle nondestructive testing based on visible light and thermography of wind turbine blade[J]. *Journal of Mechanical Engineering*, 2023,59(6):32-45.
- [4] AMENABAR I, MENDIKUTE A, LÓPEZ-ARRAIZA A, et al. Comparison and analysis of non-destructive testing techniques suitable for delamination inspection in wind turbine blades[J]. *Composites Part B: Engineering*, 2011, 42(5):1298-1305.
- [5] YANG B, SUN D B. Testing, inspecting and monitoring technologies for wind turbine blades: A survey[J]. *Renewable and Sustainable Energy Reviews*, 2013, 22: 515-526.
- [6] SCHUBEL P J, CROSSLEY R J, BOATENG E K G, et al. Review of structural health and cure monitoring techniques for large wind turbine blades[J]. *Renewable Energy*, 2013, 51:113-123.
- [7] ZHOU H F, DOU H Y, QIN L Z, et al. A review of full-scale structural testing of wind turbine blades[J]. *Renewable and Sustainable Energy Reviews*, 2014, 33: 177-187.
- [8] CIVERA M, SURACE C. Non-destructive techniques for the condition and structural health monitoring of wind

- turbines: A literature review of the last 20 years [J]. *Sensors*, 2022, 22(4):1627.
- [ 9 ] DU Y, ZHOU SH X, JING X J, et al. Damage detection techniques for wind turbine blades: A review [J]. *Mechanical Systems and Signal Processing*, 2020, 141: 106445.
- [ 10 ] 胡蓓,吴永康,郭子君,等. 风力发电叶片裂缝监测技术综述[J]. *高压电器*,2022,58(7):93-100.  
HU B, WU Y K, GUO Z J, et al. Review of wind turbine blade crack monitoring technology [J]. *High Voltage Apparatus*, 2022,58(7):93-100.
- [ 11 ] 王道累,肖佳威,刘易腾,等. 风电机组叶片损伤检测技术研究进展[J]. *中国电机工程学报*,2023, 43(12): 4614-4631.  
WANG D L, XIAO J W, LIU Y T, et al. Research and development of wind turbine blade damage detection technology [J]. *Proceedings of the CSEE*, 2023, 43(12):4614-4631.
- [ 12 ] SUN SH L, WANG T Y, CHU F L. In-situ condition monitoring of wind turbine blades: A critical and systematic review of techniques, challenges, and futures[J]. *Renewable and Sustainable Energy Reviews*, 2022, 160:112326.
- [ 13 ] STETCO A, DINMOHAMMADI F, ZHAO X Y, et al. Machine learning methods for wind turbine condition monitoring: A review [J]. *Renewable Energy*, 2019, 133:620-635.
- [ 14 ] HELBING G, RITTER M. Deep learning for fault detection in wind turbines [J]. *Renewable and Sustainable Energy Reviews*, 2018, 98:189-198.
- [ 15 ] 李孟珠,刘纲,黎华,等. 大型风力机叶片状态监测方法研究进展[J]. *热力发电*,2022,51(12):18-29.  
LI M ZH, LIU G, LI H, et al. Research progress on condition monitoring methods of large scale wind turbine blades[J]. *Thermal Power Generation*, 2022,51(12): 18-29.
- [ 16 ] 金晓航,孙毅,单继宏,等. 风力发电机组故障诊断与预测技术研究综述 [J]. *仪器仪表学报*, 2017, 38(5): 1041-1053.  
JIN X H, SUN Y, SHAN J H, et al. Fault diagnosis and prognosis for wind turbines: An overview [J]. *Chinese Journal of Scientific Instrument*, 2017, 38(5): 1041-1053.
- [ 17 ] REN B, CHI Y, ZHOU N CH, et al. Machine learning applications in health monitoring of renewable energy systems [J]. *Renewable and Sustainable Energy Reviews*, 2024, 189:114039.
- [ 18 ] MEMARI M, SHAKYA P, SHEKARAMIZ M, et al. Review on the advancements in wind turbine blade inspection: Integrating drone and deep learning technologies for enhanced defect detection [J]. *IEEE Access*, 2024, 12:33236-33282.
- [ 19 ] ZHANG SH CH, HE Y Z, GU Y F, et al. UAV based defect detection and fault diagnosis for static and rotating wind turbine blade: A review[J]. *Nondestructive Testing and Evaluation*, 2024: 1-39.
- [ 20 ] BRØNDSTED P, LILHOLT H, LYSTRUP A. Composite materials for wind turbine blades[J]. *Annual Review of Materials Research*, 2005, 35(1): 505-538.
- [ 21 ] MISHNAEVSKY L J, BRANNER K, PETERSEN H N, et al. Materials for wind turbine blades: An overview[J]. *Materials*, 2017, 10(11):1285.
- [ 22 ] MURRAY R E, BEACH R, BARNES D, et al. Structural validation of a thermoplastic composite wind turbine blade with comparison to a thermoset composite blade[J]. *Renewable Energy*, 2021, 164:1100-1107.
- [ 23 ] O'LEARY K, PAKRASHI V, KELLIHER D. Optimization of composite material tower for offshore wind turbine structures[J]. *Renewable Energy*, 2019, 140:928-942.
- [ 24 ] STEPHENS F S. Coriolis effects and rotation alignment in nuclei [J]. *Reviews of Modern Physics*, 1975, 47(1):43-65.
- [ 25 ] HASELBACH P U, BITSCHKE R D, BRANNER K. The effect of delaminations on local buckling in wind turbine blades[J]. *Renewable Energy*, 2016, 85:295-305.
- [ 26 ] WANG W J, XUE Y, HE CH K, et al. Review of the typical damage and damage-detection methods of large wind turbine blades [J]. *Energies*, 2022, 15(15): 5672.
- [ 27 ] MISHNAEVSKY L, TEMPELIS A, KUTHE N, et al. Recent developments in the protection of wind turbine blades against leading edge erosion: Materials solutions and predictive modelling[J]. *Renewable Energy*, 2023, 215:118966.
- [ 28 ] HERRING R, DYER K, MARTIN F, et al. The increasing importance of leading edge erosion and a review of existing protection solutions [J]. *Renewable and Sustainable Energy Reviews*, 2019, 115:109382.
- [ 29 ] MISHNAEVSKY L J, HASAGER C B, BAK C, et al. Leading edge erosion of wind turbine blades: Understanding, prevention and protection [J]. *Renewable Energy*, 2021, 169:953-969.
- [ 30 ] ARCOS JIMÉNEZ A, GÓMEZ MUÑOZ C Q, GARCÍA MÁRQUEZ F P. Dirt and mud detection and diagnosis on a wind turbine blade employing guided waves and supervised learning classifiers [J]. *Reliability Eng-*

- ineering & System Safety, 2019,184: 2-12.
- [31] GAO L Y, HU H. Wind turbine icing characteristics and icing-induced power losses to utility-scale wind turbines[J]. Proceedings of the National Academy of Sciences, 2021, 118(42):e2111461118.
- [32] GUO P, INFIELD D. Wind turbine blade icing detection with multi-model collaborative monitoring method [J]. Renewable Energy, 2021, 179:1098-1105.
- [33] 杨仲江,刘健,肖扬,等. 风力机叶片雷击暂态特性分析[J]. 太阳能学报, 2019,40(1):199-205.  
YANG ZH J, LIU J, XIAO Y, et al. Study on transient characteristics of wind turbine blades under lightning stroke[J]. Acta Energiæ Solaris Sinica, 2019,40(1): 199-205.
- [34] ZHOU Q B, LIU C X, BIAN X Y, et al. Numerical analysis of lightning attachment to wind turbine blade[J]. Renewable Energy, 2018, 116:584-593.
- [35] LEE H G, KANG M G, PARK J. Fatigue failure of a composite wind turbine blade at its root end [J]. Composite Structures, 2015,133: 878-885.
- [36] 吕游,封烁,郑茜,等. 基于 LeNet5like 的迁移学习风电机组叶片覆冰故障诊断研究[J]. 仪器仪表学报, 2024,45(3):128-143.  
LYU Y, FENG SH, ZHENG X, et al. Research on fault diagnosis of wind turbine icing characteristics based on LeNet5like transfer learning [J]. Chinese Journal of Scientific Instrument, 2024,45(3):128-143.
- [37] 金晓航,许壮伟,孙毅,等. 基于生成对抗网络的风电机组在线状态监测[J]. 仪器仪表学报, 2020,41(4): 68-76.  
JIN X H, XU ZH W, SUN Y, et al. Online condition monitoring of wind turbine based on generative adversarial network[J]. Chinese Journal of Scientific Instrument, 2020,41(4):68-76.
- [38] 刘帅,刘长良,甄成刚. 基于数据分类重建的风电机组故障预警方法[J]. 仪器仪表学报, 2019,40(8): 1-11.  
LIU SH, LIU CH L, ZHEN CH G. Fault warning method for wind turbine based on classified data reconstruction[J]. Chinese Journal of Scientific Instrument, 2019, 40(8):1-11.
- [39] MARTIN R W, SABATO A, SCHOENBERG A, et al. Comparison of nondestructive testing techniques for the inspection of wind turbine blades' spar caps[J]. Wind Energy, 2018, 21(11):980-996.
- [40] 盛昌文,姜永正,黄磊,等. 基于叶尖定时的风机叶片裂纹故障识别研究[J]. 仪器仪表学报, 2024, 45(4): 57-65.  
SHENG CH W, JIANG Y ZH, HUANG L, et al. Research on fan blade crack fault identification based on tip timing[J]. Chinese Journal of Scientific Instrument, 2024,45(4):57-65.
- [41] 苑玉彬,吴一全,赵朗月,等. 基于深度学习的无人机航拍视频多目标检测与跟踪研究进展[J]. 航空学报,2023,44(18):6-36.  
YUAN Y B, WU Y Q, ZHAO L Y, et al. Research progress of UAV aerial video multi-object detection and tracking based on deep learning[J]. Acta Aeronautica et Astronautica Sinica, 2023,44(18):6-36.
- [42] LIU Y, HAJJ M, BAO Y. Review of robot-based damage assessment for offshore wind turbines[J]. Renewable and Sustainable Energy Reviews, 2022, 158:112187.
- [43] CLARO R M, PEREIRA M I, NEVES F S, et al. Energy efficient path planning for 3D aerial inspections[J]. IEEE Access, 2023, 11:32152-32166.
- [44] CAR M, MARKOVIC L, IVANOVIC A, et al. Autonomous wind-turbine blade inspection using LiDAR-equipped unmanned aerial vehicle [J]. IEEE Access, 2020, 8:131380-131387.
- [45] GARCÍA MÁRQUEZ F P, BERNALTE SÁNCHEZ P J, SEGOVIA RAMÍREZ I. Acoustic inspection system with unmanned aerial vehicles for wind turbines structure health monitoring [J]. Structural Health Monitoring, 2022, 21(2):485-500.
- [46] LEE H, HWANG Y M, LEE J, et al. A drone-driven X-ray image-based diagnosis of wind turbine blades for reliable operation of wind turbine [J]. IEEE Access, 2024, 12:56141-56158.
- [47] GUAN B L, SU ZH L, YU Q F, et al. Monitoring the blades of a wind turbine by using videogrammetry [J]. Optics and Lasers in Engineering, 2022, 152:106901.
- [48] YANG C, LIU X, ZHOU H, et al. Towards accurate image stitching for drone-based wind turbine blade inspection[J]. Renewable Energy, 2023, 203:267-279.
- [49] LI W R, PAN Z H, HONG N, et al. Defect detection of large wind turbine blades based on image stitching and improved Unet network [J]. Journal of Renewable and Sustainable Energy, 2023, 15(1):013302.
- [50] 周登科,郭星辰,史凯特,等. 风电场无人机巡检红外叶片图像拼接算法[J]. 红外技术,2023,45(11): 1161-1168.  
ZHOU D K, GUO X CH, SHI K T, et al. Infrared blade image stitching algorithm for wind farm UAV inspection[J]. Infrared Technology, 2023, 45(11): 1161-1168.
- [51] 王洪金,刘香怡,何赞泽,等. 基于改进 NCC 算法的大

- 尺寸原位风机叶片可见光图像拼接[J]. 电子测量与仪器学报, 2024, 38(7): 1-12.
- WANG H J, LIU X Y, HE Y Z, et al. Visible image stitching of large in-situ wind turbine blade based on improved NCC[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(7): 1-12.
- [52] 何赞泽,张帆,刘昊,等. 风机叶片无人机红外热图像拼接方法[J]. 电子测量与仪器学报, 2022, 36(7): 44-53.
- HE Y Z, ZHANG F, LIU H, et al. Infrared image stitch method of wind turbine blade based on UAV[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(7): 44-53.
- [53] GAO L Y, TAO T, LIU Y Q, et al. A field study of ice accretion and its effects on the power production of utility-scale wind turbines[J]. *Renewable Energy*, 2021, 167: 917-928.
- [54] 张森,杨苹,刘泽健,等. 大型海上风电机组叶片故障图像识别方法[J]. 可再生能源, 2024, 42(6): 767-773.
- ZHANG M, YANG P, LIU Z J, et al. Image recognition method for blade fault of large offshore wind turbine[J]. *Renewable Energy Resources*, 2024, 42(6): 767-773.
- [55] 严海领,刘雄飞,李密兰. 不同颜色风力机叶片缺陷检测系统研究与验证[J]. 传感技术学报, 2024, 37(3): 513-518.
- YAN H L, LIU X F, LI M L. Research and verification of the defect detection system of wind turbine blade in different color [J]. *Chinese Journal of Sensors and Actuators*, 2024, 37(3): 513-518.
- [56] RAO Y ZH, XIANG B J, HUANG B X, et al. Wind turbine blade inspection based on unmanned aerial vehicle (UAV) visual systems [C]. 2019 IEEE 3rd Conference on Energy Internet and Energy System Integration (EI2). Changsha, China: IEEE, 2019: 708-713.
- [57] 冷冻冰. 基于图像处理的风力发电机叶片覆冰监测方法[D]. 重庆大学, 2022.
- LENG D B, Method for monitoring icing of wind turbine blades based on image processing [D]. Chongqing University, 2022.
- [58] 胡世创,魏莹玉,周唯逸,等. 基于图像处理的风电叶片裂纹检测系统设计[J]. 可再生能源, 2018, 36(8): 1231-1237.
- HU SH CH, WEI Y Y, ZHOU W Y, et al. Design of crack detection system based on image processing for power wind blades [J]. *Renewable Energy Resources*, 2018, 36(8): 1231-1237.
- [59] 毛希玮,徐莹莹. 基于无人机的风机叶片缺陷自动检测技术[J]. 复合材料科学与工程, 2020(9): 85-89.
- MAO X W, XU Y Y. Automatic defects detection of wind blade surface via UAV[J]. *Composite Science and Engineering*, 2020(9): 85-89.
- [60] 曹锦纲,杨国田,杨锡运. 基于RPCA和视觉显著性的风机叶片表面缺陷检测[J]. 图学学报, 2019, 40(4): 704-710.
- CAO J G, YANG G T, YANG X Y. Surface defect detection of wind turbine blades based on RPCA and visual saliency[J]. *Journal of Graphics*, 2019, 40(4): 704-710.
- [61] 谭兴国,张高明. 基于无人机巡检的风机叶片表面缺陷检测技术[J/OL]. 电测与仪表, 1-10[2024-10-10].
- TAN X G, ZHANG G M. UAV-based inspection of wind turbine blade surface defects detection technology[J/OL]. *Electrical Measurement & Instrumentation*, 1-10[2024-10-10].
- [62] PENG Y, WANG W, TANG Z, et al. Non-uniform illumination image enhancement for surface damage detection of wind turbine blades[J]. *Mechanical Systems and Signal Processing*, 2022, 170: 108797.
- [63] 石腾,许波峰,李振,等. 基于数字图像处理的风电机组叶片裂纹损伤识别方法研究[J]. 太阳能学报, 2024, 45(2): 86-94.
- SHI T, XU B F, LI ZH, et al. Research on crack damage identification method of wind turbine blade based on digital image processing [J]. *Acta Energetica Solaris Sinica*, 2024, 45(2): 86-94.
- [64] 王雪平,张建斐,李万润,等. 基于机器视觉的风电叶片风沙侵蚀程度检测方法研究[J]. 太阳能学报, 2020, 41(5): 166-173.
- WANG X P, ZHANG J F, LI W R, et al. Study on monitoring method of wind power blades erosion severity under wind-sand storm based on machine vision technology [J]. *Acta Energetica Solaris Sinica*, 2020, 41(5): 166-173.
- [65] 李万润,张建斐,王雪平,等. 基于图像处理技术的风电叶片表面划痕特征提取方法研究[J]. 太阳能学报, 2020, 41(12): 278-287.
- LI W R, ZHANG J F, WANG X P, et al. Feature extraction method of wind turbine blade surface scratches based on image processing [J]. *Acta Energetica Solaris Sinica*, 2020, 41(12): 278-287.
- [66] 石腾,许波峰,陈鹏,等. 基于机器视觉的风电机组叶片多类型损伤检测方法研究[J]. 太阳能学报, 2024, 45(6): 487-494.
- SHI T, XU B F, CHEN P, et al. Study on multi-type

- damage detection methods for wind turbine blades based on machine vision technology[J]. *Acta Energiæ Solaris Sinica*, 2024,45(6):487-494.
- [67] MILLER J, SEEGMILLER C, MASOUM M A S, et al. Hyperparameter tuning of support vector machines for wind turbine detection using drones [C]. 2023 Intermountain Engineering, Technology and Computing (IETC). Provo, UT, USA: IEEE, 2023:55-60.
- [68] PENG L, LIU J. Detection and analysis of large-scale WT blade surface cracks based on UAV-taken images[J]. *IET Image Processing*, 2018, 12(11): 2059-2064.
- [69] 汤占军,孙栋钦,李英娜,等. 改进 FA 优化 SVM 的风机叶片裂纹检测模型[J]. *可再生能源*,2022,40(9): 1189-1194.  
TANG ZH J, SUN D Q, LI Y N, et al. Improved FA optimized SVM based crack detection model for fan blades[J]. *Renewable Energy Resources*, 2022,40(9): 1189-1194.
- [70] DENG L W, GUO Y G, CHAI B R. Defect detection on a wind turbine blade based on digital image processing[J]. *Processes*, 2021, 9(8):1452.
- [71] 柴博容. 基于数字图像处理的风力发电机叶片表面缺陷检测研究[D]. 哈尔滨理工大学,2021.  
CHAI B R. Research on defect detection of wind turbine blade based on digital image processing [D]. Harbin University of Science and Technology, 2021.
- [72] WANG L, ZHANG Z J. Automatic detection of wind turbine blade surface cracks based on UAV-taken Images[J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(9):7293-7303.
- [73] WANG L, ZHANG Z J, LUO X. A two-stage data-driven approach for image-based wind turbine blade crack inspections [J]. *IEEE/ASME Transactions on Mechatronics*, 2019, 24(3):1271-1281.
- [74] YU Y J, CAO H, YAN X Y, et al. Defect identification of wind turbine blades based on defect semantic features with transfer feature extractor [J]. *Neurocomputing*, 2020, 376:1-9.
- [75] 汤占军,孙栋钦,李英娜,等. 基于特征融合的风机叶片表面缺陷检测模型[J]. *电子测量技术*,2022, 45(11):161-166.  
TANG ZH J, SUN D Q, LI Y N, et al. Defect detection model of wind turbine blade based on feature fusion[J]. *Electronic Measurement Technology*, 2022,45(11):161-166.
- [76] 时伟. 海上风机叶片缺陷检测及分类[D]. 哈尔滨理工大学,2022.
- SHI W. Defect detection and classification of offshore wind turbine blades [D]. Harbin University of Science and Technology, 2022.
- [77] WANG Y, ZOU L. Research on surface damage detection of wind turbinebladebased on machine vision[J]. *Journal of Physics: Conference Series*, 2022, 2184(1):012018.
- [78] REDDY A, INDRAGANDHI V, RAVI L, et al. Detection of cracks and damage in wind turbine blades using artificial intelligence-based image analytics [J]. *Measurement*, 2019, 147:106823.
- [79] GUO J H, LIU CH, CAO J F, et al. Damage identification of wind turbine blades with deep convolutional neural networks [J]. *Renewable Energy*, 2021, 174: 122-133.
- [80] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6):84-90.
- [81] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. *ArXiv preprint arXiv:1409.1556*, 2014.
- [82] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016:770-778.
- [83] XU D H, WEN CH B, LIU J H. Wind turbine blade surface inspection based on deep learning and UAV-taken images [J]. *Journal of Renewable and Sustainable Energy*, 2019, 11(5):053305.
- [84] CHEN Q, LIU ZH H, LYU M Y. Attention mechanism-based CNN for surface damage detection of wind turbine blades [C]. 2022 International Conference on Machine Learning, Cloud Computing and Intelligent Mining (MLCCIM). Xiamen, China: IEEE, 2022:313-319.
- [85] LIU Z H, CHEN Q, WEI H L, et al. Channel-Spatial attention convolutional neural networks trained with adaptive learning rates for surface damage detection of wind turbine blades [J]. *Measurement*, 2023, 217: 113097.
- [86] 姜喜耀. 风力机叶片损伤图像快速分类识别技术研究[D]. 沈阳工业大学,2021.  
JIANG X Y. Research on fast classification and recognition technology of wind turbine blade damage image [D]. Shenyang University of Technology, 2021.
- [87] HACIEFENDIOĞLU K, BAŞA ĞA 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.
- [ 88 ] ZHU J W, WEN CH B, LIU J H. Defect identification of wind turbine blade based on multi-feature fusion residual network and transfer learning [ J ]. *Energy Science & Engineering*, 2022, 10(1):219-229.
- [ 89 ] YU J Y, LIU K P, QIN L, et al. DMnet: A new few-shot framework for wind turbine surface defect detection [ J ]. *Machines*, 2022, 10(6):487.
- [ 90 ] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [ C ]. 2016 European Conference on Computer Vision (ECCV), 2016:21-37.
- [ 91 ] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [ C ]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:779-788.
- [ 92 ] REDMON J, FARHADI A. Yolov3: An incremental improvement [ J ]. *ArXiv preprint arXiv:1804.02767*, 2018.
- [ 93 ] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [ J ]. *ArXiv preprint arXiv:2004.10934*, 2020.
- [ 94 ] GE ZH, LIU S T, WANG F, et al. Yolox: Exceeding yolo series in 2021 [ J ]. *ArXiv preprint arXiv:2107.08430*, 2021.
- [ 95 ] LI CH Y, LI L L, JIANG H L, et al. YOLOv6: A single-stage object detection framework for industrial applications [ J ]. *ArXiv preprint arXiv:2209.02976*, 2022.
- [ 96 ] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [ C ]. 2023 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2023:7464-7475.
- [ 97 ] VARGHESE R, SAMBATH M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness [ C ]. 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). Chennai, India; IEEE, 2024:1-6.
- [ 98 ] 朱佳伟,文传博. 基于改进 SSD 的风机叶片缺陷检测 [ J ]. *复合材料科学与工程*, 2022(3):38-44.  
ZHU J W, WEN CH B. Defect detection of wind turbine blade based on improved SSD [ J ]. *Composite Science and Engineering*, 2022(3):38-44.
- [ 99 ] LYU L, YAO ZH Y, WANG EN M, et al. Efficient and accurate damage detector for wind turbine blade images [ J ]. *IEEE Access*, 2022, 10:123378-123386.
- [ 100 ] QIU Z F, WANG SH X, ZENG ZH X, et al. Automatic visual defects inspection of wind turbine blades via YOLO-based small object detection approach [ J ]. *Journal of Electronic Imaging*, 2019,28(4):43023.
- [ 101 ] SARKAR D, GUNTURI S K. Wind turbine blade structural state evaluation by hybrid object detector relying on deep learning models [ J ]. *Journal of Ambient Intelligence and Humanized Computing*, 2021,12(8):8535-8548.
- [ 102 ] 蒋兴群,刘波,宋力,等. 基于改进 YOLO-v3 的风力机叶片表面损伤检测识别 [ J ]. *太阳能学报*, 2023, 44(3):212-217.  
JIANG X Q, LIU B, SONG L, et al. Surface damage detection and identification of wind turbine blade based on improved YOLO-v3 [ J ]. *Acta Energetica Solaris Sinica*, 2023,44(3):212-217.
- [ 103 ] 李亦伦,成和祥,董礼,等. 基于改进 Yolov4 的风电机组叶片缺陷检测算法 [ J ]. *风机技术*, 2022, 64(1):46-53.  
LI Y L, CHENG H X, DONG L, et al. Defect detection algorithm technology for the blade of wind turbine based on Yolov4 [ J ]. *Chinese Journal of Turbomachinery*, 2022,64(1):46-53.
- [ 104 ] ZHANG CH, YANG T, YANG J. Image recognition of wind turbine blade defects using attention-based MobileNetv1-YOLOv4 and transfer learning [ J ]. *Sensors*, 2022, 22(16):6009.
- [ 105 ] CHEN W X, ZHU G Q, MAO M F, et al. Defect detection method of wind turbine blades based on improved YOLOv4 [ C ]. 2022 International Conference on Sensing, Measurement & Data Analytics in the Era of Artificial Intelligence (ICSMD). Harbin, China; IEEE, 2022:1-4.
- [ 106 ] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations [ C ]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA; IEEE, 2020:1577-1586.
- [ 107 ] ZHANG R, WEN CH B. SOD-YOLO: A small target defect detection algorithm for wind turbine blades based on improved YOLOv5 [ J ]. *Advanced Theory and Simulations*, 2022, 5(7):2100631.
- [ 108 ] RAN X K, ZHANG SH, WANG H T, et al. An improved algorithm for wind turbine blade defect detection [ J ]. *IEEE Access*, 2022, 10:122171-122181.
- [ 109 ] ZHU X X, HANG X Y, GAO X X, et al. Research on crack detection method of wind turbine blade based on a

- deep learning method [J]. *Applied Energy*, 2022, 328(15):120241.
- [110] ZHANG Y SH, YANG Y L, SUN J Q, et al. Surface defect detection of wind turbine based on lightweight YOLOv5s model [J]. *Measurement*, 2023, 220: 113222.
- [111] 王洪金,杜旭,赵丽劫,等. 引入人员反馈的风机叶片红外缺陷测量技术[J]. *中国测试*, 2024, 50(1): 32-38.
- WANG H J, DU X, ZHAO L J, et al. Measurement technology of wind turbine blades infrared defect with human feedback introduced[J]. *China Measurement & Test*, 2024, 50(1):32-38.
- [112] YE X Y, WANG L, HUANG CH, et al. Wind turbine blade defect detection with a semi-supervised deep learning framework [J]. *Engineering Applications of Artificial Intelligence*, 2024, 136:108908.
- [113] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *ArXiv preprint arXiv: 1706.03762*, 2017.
- [114] 杨宇龙,张银胜,段修贤,等. 基于轻量级卷积网络的风力发电机表面缺陷检测研究[J]. *电子测量与仪器学报*, 2024, 38(8):36-45.
- YANG Y L, ZHANG Y SH, DUAN X X, et al. Research on surface defect detection of wind turbine based on lightweight convolutional network[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(8):36-45.
- [115] YAO Y, WANG G ZH, FAN J H. WT-YOLOX: An efficient detection algorithm for wind turbine blade damage based on YOLOX [J]. *Energies*, 2023, 16(9):3776.
- [116] LIU Y H, ZHENG Y Q, SHAO ZH F, et al. Defect detection of the surface of wind turbine blades combining attention mechanism [J]. *Advanced Engineering Informatics*, 2024, 59:102292.
- [117] HU Y ZH, WANG L W, KOU T H, et al. YOLO-Tiny-attention: An improved algorithm for fault detection of wind turbine blade [C]. 2023 8th International Conference on Intelligent Computing and Signal Processing (ICSP). Xi'an, China: IEEE, 2023:1228-1232.
- [118] LIU L ZH, LI P R, WANG D H, et al. A wind turbine damage detection algorithm designed based on YOLOv8[J]. *Applied Soft Computing*, 2024, 154: 111364.
- [119] ZHOU W J, WANG Z J, ZHANG M SH, et al. Wind turbine actual defects detection based on visible and infrared image fusion [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3509208.
- [120] TAN M X, LE Q V. Efficientnet: Rethinking model scaling for convolutional neural networks [C]. *International Conference on Machine Learning*. PMLR, 2019:6105-6114.
- [121] 辛彦,吴国新,左云波. 基于 EfficientDet 的风机叶片缺陷检测方法[J]. *电子测量技术*, 2022, 45(5): 124-131.
- XIN Y, WU G X, ZUO Y B. Defect detection method of wind turbine blade based on EfficientDet [J]. *Electronic Measurement Technology*, 2022, 45(5): 124-131.
- [122] ZHANG H, LI F, LIU SH L, et al. Dino: Detr with improved denoising anchor boxes for end-to-end object detection [J]. *ArXiv preprint arXiv: 2203.03605*, 2022.
- [123] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]. *European Conference on Computer Vision*. Cham: Springer International Publishing, 2020:213-229.
- [124] GAO R X, MA Y F, WANG T F. Early stage damage detection of wind turbine blades based on UAV images and deep learning [J]. *Journal of Renewable and Sustainable Energy*, 2023, 15(4):043305.
- [125] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6):1137-1149.
- [126] SHIHAVUDDIN A S M, CHEN X, FEDOROV V, et al. Wind turbine surface damage detection by deep learning aided drone inspection analysis[J]. *Energies*, 2019, 12(4): 676.
- [127] LENG J X, MO M, ZHOU Y H, et al. Pareto pefocusing for drone-view object detection [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2023, 33(3):1320-1334.
- [128] CAI ZH W, VASCONCELOS N. Cascade R-CNN: Delving into high quality object detection [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT: IEEE, 2018:6154-6162.
- [129] MAO Y L, WANG SH X, YU D L, et al. Automatic image detection of multi-type surface defects on wind turbine blades based on cascade deep learning network[J]. *Intelligent Data Analysis*, 2021, 25(2): 463-482.

- [130] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017:2961-2969.
- [131] ZHANG J J, COSMA G, WATKINS J. Image enhanced Mask R-CNN: A deep learning pipeline with new evaluation measures for wind turbine blade defect detection and classification [J]. Journal of Imaging, 2021, 7(3): 46.
- [132] 张超, 文传博. 基于改进 Mask R-CNN 的风机叶片缺陷检测 [J]. 可再生能源, 2020, 38(9): 1181-1186.  
ZHANG CH, WEN CH B. Fault detection of wind turbine blade based on improved Mask R-CNN [J]. Renewable Energy Resources, 2020, 38(9): 1181-1186.
- [133] ZHANG CH, WEN CH B, LIU J H. Mask-MRNet: A deep neural network for wind turbine blade fault detection [J]. Journal of Renewable and Sustainable Energy, 2020, 12(5): 053302.
- [134] DIAZ P M, TITTUS P. Fast detection of wind turbine blade damage using Cascade Mask R-DSCNN-aided drone inspection analysis [J]. Signal, Image and Video Processing, 2023, 17(5): 2333-2341.
- [135] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. 2015 Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015: 234-241.
- [136] LI W R, PAN Z H, HONG N, et al. Defect detection of large wind turbine blades based on image stitching and improved Unet network [J]. Journal of Renewable and Sustainable Energy, 2023, 15(1): 013302.
- [137] XIE EN Z, WANG W H, YU ZH D, et al. SegFormer: Simple and efficient design for semantic segmentation

with transformers [J]. Advances in Neural Information Processing Systems, 2021, 34: 12077-12090.

- [138] LI W R, PAN Z H, ZHU Q X, et al. Wind turbine blade defect detection and measurement technology based on improved SegFormer and pixel matching [J]. Optics & Laser Technology, 2024, 179: 111381.

## 作者简介



**宋晔**, 2023 年于桂林理工大学获得学士学位, 现为南京航空航天大学博士研究生, 主要研究方向为图像处理与机器视觉。

E-mail: songye@nuaa.edu.cn

**Song Ye** received his B. Sc. degree from Guilin University of Technology (GLUT) in 2023. He is currently a Ph. D. candidate at Nanjing University of Aeronautics and Astronautics. His research interests include image processing and machine vision.



**吴一全** (通信作者), 1998 年于南京航空航天大学获得博士学位, 现为南京航空航天大学教授、博士生导师, 主要研究方向为视觉检测与图像测量、遥感图像处理与理解、红外目标检测与识别、视频处理与智能分析等。

E-mail: nuaaimage@163.com

**Wu Yiquan** (Corresponding author) received his Ph. D. degree from Nanjing University of Aeronautics and Astronautics in 1998. He is currently a professor and Ph. D. advisor at Nanjing University of Aeronautics and Astronautics. His main research interests include visual detection and image measurement, remote sensing image processing and understanding, infrared target detection and recognition, video processing and intelligent analysis, et al.