

文章编号:1007-2780(2026)02-0267-13

基于深度学习的无人机巡检风机叶片表面缺陷智能检测方法

郑欣¹, 田琳², 张艳³, 甘宗源¹, 黄威^{4*}

(1. 四川文理学院 人工智能与大数据学院, 四川 达州 635000;

2. 伊犁师范大学 电子工程学院, 新疆 伊宁 835000;

3. 四川文理学院 四川革命老区发展研究中心, 四川 达州 635000;

4. 景德镇学院 信息工程学院, 江西 景德镇 334000)

摘要:针对风机叶片表面缺陷人工检测效率低、现有深度学习方法环境适应性弱及多类型缺陷检测性能不足的问题,提出一种基于深度学习的无人机航拍三阶段智能检测方法,以实现高效、精准的缺陷识别。首先,从航拍视频中均匀抽帧,采用改进的EfficientNetV2-S网络实现损伤叶片初筛(准确率87.5%);然后,利用高斯混合聚类算法筛选典型损伤帧以压缩冗余数据;最后,基于集成Transformer模块与动态锚点策略的YOLO-v11网络完成缺陷精确检测。此外,构建包含剥落、裂纹等缺陷的15 000幅图像数据集用于方法验证。实验结果表明,该方法单帧检测召回率达88.4%、精度达71.5%,视频级检测召回率提升至95.0%、精度达86.4%,显著优于对比方法;可有效识别裂纹、剥落等缺陷,突破复杂环境地形限制,实现全叶片覆盖检测。所提方法解决了小目标与环境干扰难题,性能稳定,检测精度高,为风电智能化运维提供了有力支持。

关键词:风机叶片表面缺陷;无人机巡检;高斯混合聚类模型;YOLO-v11;EfficientNetV2

中图分类号:TP391 **文献标识码:**A **doi:**10.37188/CJLCD.2026-0002 **CSTR:**32172.14.CJLCD.2026-0002

收稿日期:2026-01-04;**修订日期:**2026-01-22.

基金项目:江西省教育厅科学技术研究项目(No.GJJ2402304);智能医学与健康大数据四川省高校重点实验室开放基金(No.ZNYX2501, No.ZNYX2514);政务数据安全达州市重点实验室开放基金(No.ZSAQ202514);四川革命老区发展研究中心开放基金(No.SLQ2025SA04)

Supported by Jiangxi Provincial Department of Education Science and Technology Research Project (No. GJJ2402304); Open Fund of Sichuan Provincial University Key Laboratory of Intelligent Medicine and Health Big Data (No.ZNYX2501, No.ZNYX2514); Open Fund of Dazhou Key Laboratory of Government Data Security (No.ZSAQ202514); Open Fund of Sichuan Revolutionary Old Base Development Research Center (No.SLQ2025SA04)

*通信联系人, E-mail:huangwei0731@163.com

Intelligent detection method for surface defects on wind turbine blades based on deep learning UAV inspection

ZHENG Xin¹, TIAN Lin², ZHANG Yan³, GAN Zongyuan¹, HUANG Wei^{4*}

(1. School of Artificial Intelligence And Bigdata, Sichuan University of Arts and Science, Dazhou 635000, China;

2. School of Electronic Engineering, Yili Normal University, Yining 835000, China;

3. Research Center of Sichuan Old Revolutionary Areas Development, Sichuan University of Arts and Science, Dazhou 635000, China;

4. School of Information Engineering, Jingdezhen University, Jingdezhen 334000, China)

Abstract: To achieve efficient and accurate defect detection for wind turbine blades, this study develops a UAV-based intelligent inspection system and investigates its core algorithms, including multi-stage defect screening, representative frame selection, and deep learning-based defect recognition. First, based on image features such as structural integrity and texture patterns, an improved EfficientNetV2-S network is proposed for preliminary damage screening (accuracy 87.5%). Next, Gaussian Mixture Clustering is employed to select representative damaged frames from video streams, effectively reducing data redundancy. Then, a YOLO-v11 network integrated with Transformer modules and dynamic anchor strategies is developed for precise defect localization and classification. Additionally, a comprehensive dataset containing 15 000 annotated UAV images of various defects (e.g., cracks, delamination) is established for algorithm validation. Experimental results demonstrate that the system achieves 88.4% recall and 71.5% precision in single-frame detection, while video-level analysis improves to 95.0% recall and 86.4% precision. The method outperforms existing approaches in detecting multiple defect types under complex environmental conditions. The proposed system meets the requirements for non-contact inspection, real-time processing, high accuracy, and strong anti-interference capability, providing an effective solution for intelligent wind turbine maintenance.

Key words: surface defects of wind turbine blades; UAV tour-inspection; Gaussian mixture model; YOLO-v11; efficientNetV2

1 引言

风机叶片作为风力发电机捕获风能的核心部件,长期暴露于复杂自然环境中,易产生裂纹、剥落等表面缺陷^[1-2]。这些缺陷在动态载荷作用下会快速扩展,缩短叶片使用寿命,甚至引发断裂等灾难性事故^[3-4]。因此,研究高效、精准的叶片表面缺陷检测方法,对预防故障、保障风机安全运行、降低运维成本具有重要意义。传统风机叶片缺陷检测主要依赖人工巡检,存在效率低下、成本高昂、主观性强等问题,且受恶劣天气与复杂

地形制约^[5-6],难以满足风电场大规模、高频次巡检需求。无人机(unmanned aerial vehicle, UAV)巡检技术通过高清成像设备高效获取叶片表面图像数据^[7-8],为突破上述瓶颈提供了新途径。然而,当前主流系统仍停留在“人工飞控、人工判图”阶段,缺乏高效的自动缺陷识别能力,导致海量航拍图像数据处理成为瓶颈^[9],检测性能远未达到智能化运维要求。

研究基于无人机航拍图像的风机叶片表面缺陷智能检测方法,对于降低风电设备的运维成本、保障风电场的安全稳定运行具有重要意义。现有缺陷智能检测方法主要分为两类:基于模式识别

的方法(如边缘检测^[10]、灰度分析^[11]、特征参数分类^[12-13]、分类器集成^[14])和基于深度学习的方法(如经典检测网络优化^[15]、结合注意力机制^[16]、融合多模态信息^[17]、半监督深度学习网络^[18]、YOLOv5轻量检测网络^[19]、YOLOv8检测网络结合多元信息感知^[20])。基于模式识别的方法通过人工设计特征提取器(包括灰度统计、LBP/Haralick纹理特征、形态描述子等)结合传统分类器(如SVM、随机森林),经图像预处理、特征提取、特征选择、分类决策4个阶段实现检测。该类方法具备可解释性强、计算成本低的优势,适合规则清晰、缺陷单一且稳定的场景,在小样本条件下仍能保持良好性能。然而,该类方法依赖专家经验设计特征,难以捕捉低对比度裂纹等细微缺陷,面对复杂背景或特征与背景相似场景时,泛化能力显著受限。基于深度学习的方法则利用卷积神经网络(如YOLO、U-Net)端到端自动学习特征,主流范式包括基于目标检测(定位+分类)^[21-22]、语义分割(像素级轮廓)^[23-24]、异常检测(仅需正常样本)^[25-26]实现高精度缺陷定位与分类。其核心优势是自动提取深层抽象特征,对复杂缺陷检出率高,且对环境干扰(光照变化、外观形变)鲁棒性强;不足之处在于依赖大规模高质量标注样本,计算资源消耗大,且模型决策逻辑缺乏可解释性。根据上述分析可知,基于卷积神经网络的通用目标检测算法解决了表面缺陷检测的关键问题,但将其应用于无人机航拍场景下仍然面临以下挑战:

(1)环境适应性弱:复杂背景(天空、云层、塔筒)、多变光照、拍摄角度差异及叶片曲面特性将降低模型鲁棒性;

(2)小目标检测性能不佳:高空航拍视角下,裂纹等关键缺陷尺度小,通用模型对其辨识度有限,导致召回率低;

(3)多类型缺陷处理能力不足:裂纹、剥落等不同类型缺陷的外观形态、尺度差异较大,单一模型难以同时兼顾多种类型缺陷的高精度识别;

(4)数据冗余严重:航拍视频含大量无效帧,即无缺陷或重复帧,逐帧深度分析计算开销巨大,缺乏有效的数据压缩与关键帧筛选机制。

针对上述挑战,本文提出基于深度学习的无人机航拍三阶段智能检测框架,核心创新归纳如下:

(1)高效初筛与冗余数据压缩:通过均匀抽

帧与轻量化EfficientNetV2-S网络实现损伤快速初筛(87.5%准确率),结合高斯混合聚类(GMM)算法筛选典型损伤帧,显著压缩冗余数据量,提升后续处理效率;

(2)高精度缺陷识别及定位:应用YOLO-v11网络(集成Transformer模块以增强全局上下文建模能力,并引入动态锚点策略优化小目标检测性能)对关键图像帧进行精确的缺陷识别及定位。

(3)专用数据集构建:为验证方法性能并推动领域研究,本文构建了一个大规模、高质量的风机叶片无人机航拍图像数据集,包含剥落、裂纹等多种典型缺陷,共计15 000幅精细标注图像。

2 风机叶片表面巡检图像数据集

构建风机叶片表面巡检图像数据集是研究智能检测方法的基础。我们采用无人机对多组风机的叶片进行拍摄,拍摄时以固定角度从叶尾匀速拍摄至叶尖后结束,拍摄部位包括桨上表面、桨下表面、桨前缘、桨后缘。无人机航拍高度的设定需与风机叶片的安装高度相协调,以确保采集到清晰的图像,从而为后续风机叶片表面缺陷的智能检测提供可靠依据。保存无人机拍摄得到的风机叶片巡检视频,并记录拍摄信息。专业巡检工程师从无人机航拍视频段中抽取出图像帧(每隔 N_1 帧抽取1帧,设置 N_1 为35)并进行标注。标注时,首先判读图片中的风机叶片表面是否存在损伤;然后,针对发生损伤的叶片,标注损伤位置、损伤类型。其中,损伤类型包括裂纹、剥落两大类,裂纹损伤包括开裂、雷击损伤,剥落损伤包括腐蚀、鼓包。

图1展示了风机叶片表面巡检图像数据集中的部分典型样本。图2展示了风机叶片表面巡检图像的标注过程。首先,判读风机叶片表面图像是否存在损伤,图2(a)所示为正常风机叶片表面图像,图2(b)所示为发生了损伤的风机叶片表面图像。针对损伤图像,使用矩形框标记损伤位置、损伤类型,图3展示了损伤图像及其标注,包括裂纹损伤、剥落损伤。我们构建了风机叶片表面巡检图像数据集,包含来自不同风机的15 000幅风机叶片表面图像,其中,正常叶片图像10 000幅,损伤叶片图像5 000幅(裂纹损伤图像2 500幅,剥落损伤图像2 500幅),损伤在图像中均清晰可见。



图 1 部分典型图像样本


Fig. 1 Representative image samples (partial)



(a) 正常风机叶片表面图像
(a) Surface image of normal fan blade
(b) 损伤风机叶片表面图像
(b) Surface image of the damaged fan blade

图 2 风机叶片表面图像损伤识别

Fig. 2 Surface damage detection on wind turbine blades



(a) 风机叶片裂纹损伤
(a) Crack damage
(b) 风机叶片剥落损伤
(b) Spalling damage

图 3 风机叶片损伤图像及其标注

Fig. 3 Defect typology in wind turbine blades with annotated exemplars

3 风机叶片航拍视频智能检测方法

借鉴文献[27-28]方法,本文提出了一种基

于深度学习的无人机航拍风机叶片表面缺陷智能检测方法。

3.1 智能检测流程

风机叶片无人机航拍视频智能检测流程如图 4 所示,包含 3 个核心步骤:叶片状态初步识别、典型损伤帧抽取、损伤帧精确识别。首先,抽取视频帧,并初步识别视频帧中的叶片状态;若有损伤帧,则使用高斯混合聚类(GMM)算法^[29]抽取典型损伤帧,交由 YOLO-v11 网络进行损伤帧精确识别,若此阶段未检测到具体损伤信息,对应风机叶片仍判定为正常。

3.2 风机叶片状态初步识别

风机叶片状态初步识别的流程如图 5 所示。首先,从视频中隔帧(可配置,采用了经验值 35)抽取视频帧,并利用 EfficientNetV2-S 网络初步识别叶片状态,存在损伤则保存图像帧及其全连接层特征,否则丢弃。视频处理完毕后,若无损伤帧则判定叶片正常;若有损伤帧,则进入后续处理。

风机叶片表面缺陷具有不规则、多尺度、多类型的特点,不同类型缺陷的形状、尺度、外观各不相同,甚至同一类型的缺陷都有较大的形状、尺度、外观差异^[30]。我们使用 EfficientNetV2-S 网络^[31]进行叶片状态初步识别。EfficientNetV2-S 网络是在基准模型基础上设置宽度倍率因子 1.4、深度倍率因子 1.8 得到,网络结构如表 1 所示。通过引入 Fused-MBConv 模块,将深度可分离卷积与普通卷积相结合,能更好地捕捉图像中的局部特征和全局特征;通过多层次特征融合,包含了




图4 风机叶片无人机航拍视频智能检测流程

Fig. 4 UAV-based intelligent detection workflow for wind turbine blade inspection




图5 风机叶片状态初步识别流程

Fig. 5 Preliminary condition assessment workflow of wind turbine blades

表1 EfficientNetV2-S网络架构

Tab. 1 Architecture specification of EfficientNetV2-S

Stage	Operator	Stride	Channels	Layers
0	Conv 3×3	2	24	1
1	Fused-MBConv 1, k3×3	1	24	2
2	Fused-MBConv 4, k3×3	2	48	4
3	Fused-MBConv 4, k3×3	2	64	4
4	MBConv 4, k3×3, SE0.25	2	128	6
5	MBConv 6, k3×3, SE0.25	1	160	9
6	MBConv 6, k3×3, SE0.25	2	256	15
7	Conv 1×1 & Pooling & FC	/	1 280	1

图像不同尺度和语义级别的信息,有助于准确识别物体的各种细节和特征;通过引入注意力机制,学习不同特征通道的重要性,可实现重要特征加权,抑制无关信息。通过上述改进,EfficientNetV2-S网络具有优异的识别性能。

EfficientNetV2-S网络采用交叉熵损失函数,如式(1)所示。其中,样本预测值为 a ,真实标签为 y ,每个批次处理样本数量为 m 。

$$J(y, p(y|a)) = -\frac{1}{m} \sum_{i=1}^m [y_i \ln a_i + (1 - y_i) \ln (1 - a_i)] \quad (1)$$

我们对训练图像进行数据扩增,包括翻转、加入随机噪声、光照饱和度及亮度调节、RandAugment,用于模拟风机叶片的转动、光照变化、损伤位移、相机抖动等情况。训练前,载入ImageNet数据集上预训练网络对应模块的权重。

3.3 典型损伤帧抽取

典型损伤帧抽取流程如图6所示,目的是压




图6 典型损伤帧的抽取流程

Fig. 6 Extraction workflow of representative damage frames

缩图像帧,进一步减少对重复损伤帧的处理。首先,对输入的损伤叶片图像帧的全连接层特征采用主成分分析法(principal component analysis, PCA)进行特征降维。接着,使用高斯混合聚类算法对降维后的特征向量进行无监督聚类。最后,保存每个类别中距离聚类中心点最近的 N_2 帧图像(N_2 可配置,采用经验值3),舍弃其他帧。抽取过程中,高斯混合聚类算法的实现过程如下:

步骤(1) 随机初始化每个高斯分布的参数,包括均值 μ_k 、协方差矩阵 $\sum k$ 、混合系数 $\gamma(z_{ik})$ 。

步骤(2) 按照公式(2)计算当前特征向量 x_i 属于不同高斯分布的后验概率:

$$\gamma(z_{ik}) = \frac{\pi_k \cdot N(x_i/\mu_k, \sum k)}{\sum_{j=1}^K \pi_j \cdot N(x_i/\mu_j, \sum j)}, \quad (2)$$

其中: $\gamma(z_{ik})$ 是数据特征向量 x_i 属于第 k 个高斯分布的后验概率, $N(x_i/\mu_k, \sum k)$ 是高斯分布的概率密度函数。

步骤(3) 根据后验概率更新高斯分布的参数,包括均值、协方差矩阵、混合系数,分别如公式(3)~(5)所示:

$$\mu_k = \frac{\sum_{i=1}^N \gamma(z_{ik}) x_i}{\sum_{j=1}^K \gamma(z_{ik})}, \quad (3)$$

$$\sum k = \frac{\sum_{i=1}^N \gamma(z_{ik}) (x_i - \mu_k)(x_i - \mu_k)^T}{\sum_{j=1}^K \gamma(z_{ik})}, \quad (4)$$

$$\gamma(z_{ik}) = \frac{\pi_k \cdot N(x_i/\mu_k, \sum k)}{\sum_{j=1}^K \pi_j \cdot N(x_i/\mu_j, \sum j)}. \quad (5)$$

步骤(4) 重复公式(3)~(5),直到参数收敛(参数变化小于阈值),聚类迭代结束。

步骤(5) 根据每个数据特征向量 x_i 的后验概率,将其分配到后验概率最大的高斯分布对应类别。

3.4 损伤帧精确识别

采用YOLO-v11网络^[32]实现损伤帧的精确识别,定位损伤位置并判别损伤类型。该网络通过引入Transformer模块、Mosaic数据增强、空间特征金字塔池化技术,结合跨层特征融合和动态锚点策略,显著提升了检测性能,其结构如图7所示,包含主干网络、颈部网络和头部网络。




图7 YOLO-v11网络架构

Fig. 7 Architectural overview of YOLO-v11 network

YOLO-v11网络的损失函数如公式(6)所示,融合了分类损失、边界框回归损失和分布焦点损失。此设计在保持高精度的同时,显著提升了复杂场景下目标检测的精度与效率:

$$L = L_{\text{cls}} + L_{\text{box}} + L_{\text{dfl}}. \quad (6)$$

分类损失 L_{cls} 基于交叉熵函数构造,如公式(7)所示,用于衡量预测类别概率与真实标签之间的差异:

$$L_{\text{cls}} = \sum_{i=0}^{S^2} l_i^{\text{obj}} \sum_{c \in \text{classes}} (p_i(c) - \hat{p}_i(c))^2, \quad (7)$$

其中: S 是网格大小; l_i^{obj} 表示第 i 个网格是否包含目标; $p_i(c)$ 是模型预测的第 i 个网格单元中目标

属于类别 c 的概率; $\hat{p}_i(c)$ 是真实标签,表示第 i 个网格中目标是否属于类别 c 。

边界框回归损失 L_{box} 通过最小化预测边界框与真实边界框之间的差异来提高检测准确性,使用交并比(IoU)来衡量边界框的重叠程度:

$$L_{\text{box}} = \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{obj}} \left((x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 \right) + \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{obj}} \left((\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2 \right), \quad (8)$$

其中: S 是网格大小; B 是每个网格单元预测的边

界框数量; $l_{ij}^{obj}(\cdot)$ 表示第*i*个网络单元中第*j*个边界框是否负责预测目标; x 、 y 是边界框中心点坐标; w 、 h 是边界框的宽和高;权重系数 λ_{coord} 用于平衡不同部分的损失。

分布焦点损失结合了交叉熵的优势,并通过加权增强了网络对困难样本的学习能力,提高检测性能,如式(9)所示:

$$L_{df} = - \sum_{i=1}^N \sum_{c=1}^C y_{ic} \left(\alpha (1 - p_{ic})^\gamma \log p_{ic} + (1 - \alpha) p_{ic}^\gamma \log (1 - p_{ic}) \right), \quad (9)$$

其中: N 是样本数量, C 是类别数量, y_{ic} 是第*i*个样本的真实标签, p_{ic} 是第*i*个样本属于类别*c*的预测概率,平衡因子 α 用于调整困难样本权重,聚焦参数 γ 用于控制对困难样本的关注程度。

4 实验结果及分析

4.1 实验设置

实验在表2所示的软硬件环境下进行,包含叶片状态初步识别、典型损伤帧筛选、损伤帧精确检测3个阶段。

表2 实验环境配置

Tab.2 Hardware and software configuration for experimental setup

硬件	规格	软件	版本
CPU	Xeon(R) Silver 4114	Python	3.9.18
GPU	4 x RTX 2060 12 GB	Anaconda 3	2023.09.0 (64-bit)
Memory	128G	CUDA Driver	11.0

(1)叶片状态初步识别阶段:采用EfficientNetV2-S网络完成叶片正常/损伤二分类。将风机叶片表面巡检图像统一缩放至300像素×300像素,保持长宽比不变,不足部分以灰度值0填充。再按类别分层抽样,训练集、验证集、测试集按7:1:2比例随机划分,并且训练集应用了水平镜像。训练时加载ImageNet预训练权重,采用Adam优化器,设置学习率为0.001,Batch size设置为4;采用交叉熵损失函数,训练200轮,保留训练集上性能最佳的权重。

(2)典型损伤帧抽取阶段:采用GMM算法,

将高斯模型数量 GM_k 设置为风机叶片数量的2倍,收敛阈值 τ 设置为0.001。

(3)损伤帧精确识别阶段:采用YOLO-v11网络识别叶片的损伤类型及位置。按损伤类型分层抽样,损伤图像(5 000张)按8:1:1的比例随机划分为训练集、验证集、测试集,正常图像(10 000张)全部用作测试集,以评估模型抑制误报的能力。图像尺寸统一缩放至480像素×480像素,训练集应用了水平镜像。训练时加载COCO数据集预训练权重,采用Adam优化器,学习率设置为0.001,Batch size设置为4,检测框置信度阈值为0.5;交并比重合度阈值为0.3,训练200轮,保留性能最佳的权重。

4.2 性能评估指标

为客观评价风机叶片表面缺陷检测性能,本文采用以下3个核心指标:召回率、准确率和精度,指标的值越高,表明对应方法的缺陷检测性能越好。

(1)召回率(Recall):衡量模型检出真实缺陷的能力,是指模型正确检出的缺陷数量占测试集中所有真实缺陷数量的比例,计算公式为:

$$\text{Recall} = \frac{D_d}{D_d + D_n} \times 100\%. \quad (10)$$

(2)准确率(Accuracy):衡量模型整体分类的正确性,是指所有正确预测(包括缺陷和正常)的样本数占测试集总样本数的比例,计算公式如式(11):

$$\text{Accuracy} = \frac{D_d + N_n}{D + N} \times 100\%. \quad (11)$$

(3)精度(Precision):衡量模型预测为缺陷的结果的可靠性,是指正确检出的缺陷数量占模型所有预测为缺陷的样本数量的比例;计算公式如式(12):

$$\text{Precision} = \frac{D_d}{D_d + N_d} \times 100\%, \quad (12)$$

其中: D 为损伤数据的数量, N 为正常数据的数量, D_d 为损伤数据被正确识别的数量, N_n 为正常数据中正确识别的数量, D_n 为损伤数据中识别错误的数量, N_d 为正常数据被识别错误的数量。

4.3 叶片状态初步识别实验及分析

本节对比了EfficientNetV2网络与6种经典识别网络(VGG16^[33],ResNet50^[34],DenseNet121^[35],Inception v4^[36],Inception-ResNet v2^[36])在风机叶片状态二分类任务上的性能。性能评估指标采

用召回率 (Recall)、准确率 (Accuracy) 和精度 (Precision),性能对比结果见表 3。图 8 展示了表 3 的对比结果 (紫色:Recall,黄色:Accuracy,红色: Precision),图 9、图 10 是叶片状态初步识别实验的典型结果示例,分析实验结果可知:

(1)EfficientNetV2 网络的识别性能显著领先。EfficientNetV2-S 和 EfficientNetV2-L 在召回率、准确率、精度 3 项指标上均明显优于对比网络,验证了其在叶片损伤初步识别任务上的优越性能。

表 3 叶片损伤初步识别性能对比

Tab. 3 Performance comparison for preliminary identification of blade damage

Networks	Recall/%	Accuracy/%	Precision/%
VGG 16	77.3	77.4	63.2
ResNet 50	83.3	82.5	69.9
DenseNet 121	82.6	82.1	69.4
Inception v4	82.0	82.6	70.6
Inception-ResNet v2	83.1	82.3	69.7
EfficientNetV2-S	90.7	87.5	76.3
EfficientNetV2-L	89.8	87.1	75.9




图 8 叶片损伤初步识别性能对比状态图

Fig. 8 Performance comparison for preliminary identification of blade damage

(2) EfficientNetV2-S 网络表现最佳。EfficientNetV2 系列网络中,EfficientNetV2-S 网络取得了最佳的综合性能 (召回率 90.7%,准确率 87.5%,精度 76.3%),略优于 EfficientNetV2-L 网络。

(3) VGG16 网络架构较浅且构造简单,容



图 9 叶片损伤初步识别的典型示例 (正常风机叶片)

Fig. 9 Typical examples of preliminary identification of blade damage (normal wind turbine blades)



图 10 叶片损伤初步识别的典型示例 (损伤风机叶片)

Fig. 10 Typical examples of preliminary identification of blade damage (damaged wind turbine blades)

易发生过拟合,3项指标均为最低;ResNet50、DenseNet121网络通过残差连接或密集连接缓解了深层网络训练问题,性能优于VGG16网络,但显著低于EfficientNetV2系列网络;Inception v4、Inception-ResNet v2网络采用多尺度卷积模块,性能接近ResNet、DenseNet网络水平(Inception v4网络的精度略高),但其复杂结构导致训练调优难度大,且Inception-ResNet v2网络对数据分布敏感,泛化能力受限。

EfficientNetV2网络的优势源于其先进的结构设计(如Fused-MBConv模块)、复合缩放策略(协同缩放深度、宽度、分辨率)以及采用的SiLU激活函数和正则化技术(标签平滑、随机深度)。这些特性使其在保持高效计算的同时,获得了更强的特征提取和泛化能力。综上,实验结果充分证明,EfficientNetV2-S网络是进行风机叶片状态初步识别的更优选择,其优异的召回率表明能检测出更多真实损伤,较高的精度则意味着误报率较低,这为后续的损伤精确识别环节奠定了良好基础。

4.4 风机叶片(单帧)表面损伤检测实验

本节评估所提方法在单帧风机叶片图像中表面损伤(剥落损伤、裂纹损伤)的检测性能。表4列出了所提方法在测试集上对损伤整体以及具体损伤类型(剥落、裂纹)的召回率(Recall)和精度(Precision)结果,图11直观展示了这些结果。

分析实验结果可知,所提方法在单帧图像上检测风机叶片表面损伤,取得了88.4%的召回率和71.5%的精度。这表明模型能够有效检出大部分真实存在的损伤(高召回率),但在判断为损

表 4 风机叶片(单帧)表面损伤检测结果

Tab. 4 Single-frame surface defect detection performance on wind turbine blades

损伤类别	Recall/%	Precision/%
整体损伤	88.4	71.5
剥落损伤	89.0	72.5
裂纹损伤	87.8	70.6




图 11 风机叶片(单帧)表面损伤检测性能柱状图

Fig. 11 Performance metrics for single-frame surface defect detection

伤的结果中存在一定比例的误报(精度相对较低),其性能满足风机叶片表面缺陷智能检测的初步要求。所提方法对剥落损伤的检测性能(Recall: 89.0%,Precision: 72.5%)略优于裂纹损伤(Recall: 87.8%,Precision: 70.6%),这是因为裂纹通常更细长、对比度更低,特征提取更具挑战性;而剥落区域通常具有更明显的形态和纹理特征变化。

图12展示了成功检测出风机叶片表面的剥落




图 12 风机叶片表面损伤检测示例(正确检测)

Fig. 12 Damage detection results on wind turbine blade surface (correct identification)

损伤和裂纹损伤的示例,并输出了正确的损伤类型和置信度(计算方法:前景目标概率乘缺陷类型置信度)。图 13 则展示了一个典型误判结果,模型将左图中的灰尘污染错误识别为裂纹损伤,并且针

对右图中的裂纹损伤发生了漏检,这表明模型在区分外观相似干扰物(如灰尘、污渍)与真实细微裂纹方面仍存在挑战,同时,模型检出率还存在进一步改进的空间,这些都是后续研究中改进的方向。



图 13 风机叶片表面损伤检测示例(误识别)
Fig. 13 Damage detection results on wind turbine blade surface (misidentified)

4.5 风机叶片(视频)表面损伤检测实验

为评估所提方法在无人机航拍风机叶片巡检视频场景下的缺陷检测性能,选取了 40 段巡检视频作为测试集(20 段正常叶片视频,20 段损伤叶片视频)。实验结果如表 5 所示,分别从视频级损伤存在性判别(初步识别)和帧级损伤实例检测(精确检测)两个层面进行评估。图 14 直观展示了这些结果。

表 5 风机叶片巡检视频缺陷检测性能结果

Tab. 5 Video-level defect detection performance in UAV-based blade inspection

性能	视频级初步识别	帧级精确检测
Recall	0.950	0.864
Precision	0.938	0.782

(1)视频级初步识别性能分析。所提方法判别出 22 段视频存在损伤,其中,19 段为真实损伤视频,存在 2 段误判。该方法采用固定帧抽取策略进行视频级判别,无需对视频中每一帧损伤都正确识别,只要在损伤视频中成功检测到至少一帧损伤图像,即可判定该视频存在损伤。这种机制有效利用了视频信息的冗余性,显著提升了视频级的损伤检出率(Recall 95.0%),明显优于单帧检测的召回率(88.4%)。

(2)帧级精确检测性能分析。在 20 段损伤视频中,人工标注 65 处真实损伤实例。所提方法共检测出 78 处损伤实例,其中,61 处为正确识别(Recall 93.8%),存在 17 处误检(Precision 78.2%),同时




图 14 风机叶片(视频)表面损伤检测性能状态图
Fig. 14 Video-based surface damage detection performance chart for wind turbine blades

存在 4 处漏检。该结果反映了模型在复杂视频场景下定位和识别具体损伤实例的能力,精度(78.2%)仍有提升空间,主要受到误检影响。

实验结果表明,所提方法在风机叶片巡检视频级损伤存在性判别上表现出色(Recall 95.0%),验证了其在实际无人机巡检应用中的潜力。然而,帧级精确检测存在一定的误报(Precision 78.2%)和少量漏检,尤其是将少量正常叶片视频误判为损伤(视频级误报)以及帧级出现的误检实例,是需要改进的方向。后续工作可通过优化帧采样策略、改进模型结构、增强对干扰物(如灰尘、光影)的鲁棒性等方式进一步提升检测性能。

5 结 论

针对风机叶片表面缺陷高效检测需求,本文

提出基于深度学习的无人机航拍三阶段智能检测方法,结合改进轻量化网络、高斯混合聚类(GMM)及集成Transformer的目标检测网络,构建15 000幅标注图像的专用数据集。通过实验评估与分析,得出以下结论:

(1)三阶段缺陷检测框架显著提升了综合性。“均匀抽帧/EfficientNetV2-S初筛(Accuracy 87.5%)、GMM筛选关键帧、YOLO-v11精确检测”的流程设计,有效解决了航拍视频数据冗余、复杂环境中目标及多缺陷检测难题。视频级损伤存在性判别召回率达95.0%、精度达86.4%,较单帧检测(Recall 88.4%, Precision 71.5%)性能显著跃升,验证了该框架在实际无人机巡检场景中的鲁棒性。

(2)关键技术协同优化效能突出。轻量初筛网络EfficientNetV2-S在损伤初筛任务中表现最优(Recall 90.7%, Accuracy 87.5%),为后续处理奠定了基础;基于GMM聚类的关键帧筛选机制减少87%冗余帧处理量,大幅降低了计算开销;

集成Transformer与动态锚点策略的YOLO-v11网络,实现了对裂纹(Recall 87.8%, Precision 70.6%)和剥落(Recall 89.0%, Precision 72.5%)等多类缺陷的精准定位与分类。

(3)工程应用价值明确。该方法在单帧和视频级检测上均达到了优异的性能指标(单帧 Recall 88.4%, Precision 71.5%; 视频级 Recall 95.0%, Precision 86.4%),突破了复杂环境与小目标的检测限制,能够满足风电智能化运维对叶片表面缺陷检测的实际需求。

综上所述,本文提出的智能检测方法通过三阶段深度学习框架,有效融合了轻量级初筛、无监督聚类压缩与高精度目标检测技术,并结合专用数据集的支撑,成功实现了风机叶片表面缺陷的高效、精准、自动化检测。本研究为风机叶片无人机巡检的自动化与智能化提供了可靠的技术方案,对降低风电运维成本、提升设备运行安全性与延长使用寿命具有重要的实践价值。

参 考 文 献:

- [1] 刘震宇,尹兆磊,陈晨,等. 基于WTBD-Det的风机叶片缺陷检测算法[J]. 激光与光电子学进展, 2025, 62(20): 20150004.
LIU Z Y, YI Z L, CHEN C, *et al.* Wind turbine blade defect detection algorithm based on WTBD-Det [J]. *Laser & Optoelectronics Progress*, 2025, 62(20): 20150004. (in Chinese)
- [2] 董秀芬,孙浩东,周登科,等. 海上风电风机叶片损伤不停机光电探测及识别[J]. 激光与光电子学进展, 2025, 62(6): 0612004.
DONG X F, SUN H D, ZHOU D K, *et al.* Offshore fan-blade damage non-stop photoelectric detection and identification [J]. *Laser & Optoelectronics Progress*, 2025, 62(6): 0612004. (in Chinese)
- [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. (in Chinese)
- [4] 朱广,顾晨,徐立云,等. 改进YOLOv8的风机叶片多尺度缺陷检测[J]. 光学精密工程, 2025, 33(9): 1496-1514.
ZHU G, GU C, XU L Y, *et al.* Improvement of YOLOv8 for multi-scale defect detection in wind turbine blades [J]. *Optics and Precision Engineering*, 2025, 33(9): 1496-1514. (in Chinese)
- [5] 沈君贤,马天池,宋狄,等. 基于可解释选择性集成框架的离心风机叶片裂纹损伤检测[J]. 机械工程学报, 2024, 60(12): 183-193.
SHEN J X, MA T C, SONG D, *et al.* Crack damage detection of centrifugal fan blades based on interpretable ensemble selection framework [J]. *Journal of Mechanical Engineering*, 2024, 60(12): 183-193. (in Chinese)
- [6] 曾勇杰,范必双,杨涯文,等. 改进YOLOv8算法在风机叶片缺陷检测上的应用[J]. 电子测量与仪器学报, 2024, 38(8): 26-35.
ZENG Y J, FAN B S, YANG Y W, *et al.* YOLOv8 algorithm is improved in the defect detection of wind turbine blades applications [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(8): 26-35. (in Chinese)

- [7] LI W R, ZHAO W H, DU Y F. Large-scale wind turbine blade operational condition monitoring based on UAV and improved YOLOv5 deep learning model [J]. *Mechanical Systems and Signal Processing*, 2025, 226: 112386.
- [8] PU J Y, ZHANG Q F, ZHAO W B, *et al.* Research on refined UAV inspection method of wind/solar power stations based on YOLOv8 [J]. *Journal of Engineering and Applied Science*, 2025, 72(1): 10.
- [9] ZHANG Z Y, SHU Z R. Unmanned aerial vehicle (UAV)-assisted damage detection of wind turbine blades: a review [J]. *Energies*, 2024, 17(15): 3731.
- [10] 唐震, 彭业萍, 王伟江, 等. 融合 Hough 直线检测和 Grab-cut 的风机叶片自适应分割方法[J]. 电子测量与仪器学报, 2021, 35(4): 161-168.
TANG Z, PENG Y P, WANG W J, *et al.* Adaptive segmentation method for wind turbine blades combining Hough line detection and Grab-cut algorithm [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(4): 161-168. (in Chinese)
- [11] 闫浩伟. 基于无人机的风机叶片表面缺陷自动检测方法[J]. 计算机测量与控制, 2024, 32(11): 72-79.
YAN H W. Automatic detection method for surface defects of fan blades based on drones [J]. *Computer Measurement & Control*, 2024, 32(11): 72-79. (in Chinese)
- [12] 刘玉洪, 吴一全. 基于机器视觉的太阳能电池片缺陷检测算法综述[J]. 光学精密工程, 2024, 32(6): 868-900.
LIU Y Q, WU Y Q. Review of defect detection algorithms for solar cells based on machine vision [J]. *Optics and Precision Engineering*, 2024, 32(6): 868-900. (in Chinese)
- [13] 姜晓恒, 段金忠, 卢洋, 等. 融合先验知识推理的表面缺陷检测[J]. 图学学报, 2024, 45(5): 957-967.
JIANG X H, DUAN J Z, LIU Y, *et al.* Fusing prior knowledge reasoning for surface defect detection [J]. *Journal of Graphics*, 2024, 45(5): 957-967. (in Chinese)
- [14] 孙坚, 杨宇兵. 基于特征提取和最优加权集成策略的风机叶片结冰故障检测[J]. 科学技术与工程, 2024, 24(11): 4501-4509.
SUN J, YANG Y B. Icing fault detection of wind turbine blades based on feature extraction and an optimal weighted ensemble strategy [J]. *Science Technology and Engineering*, 2024, 24(11): 4501-4509. (in Chinese)
- [15] 杨彦萍, 高军伟, 刘兆龙, 等. 基于改进 YOLO11 的印刷电路板表面缺陷检测算法[J]. 液晶与显示, 2025, 40(10): 1545-1556.
YANG Y P, GAO J W, LIU Z L, *et al.* Surface defect detection on printed circuit boards based on improved YOLO11 [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(10): 1545-1556. (in Chinese)
- [16] LIU Y H, ZHENG Y Q, SHAO Z F, *et al.* Defect detection of the surface of wind turbine blades combining attention mechanism [J]. *Advanced Engineering Informatics*, 2024, 59: 102292.
- [17] 陈名渝, 谢玥辰, 吕雄涛, 等. 冷轧钢表面与内部缺陷检测研究[J]. 中国光学(中英文), 2024, 17(4): 823-833.
CHEN M Y, XIE Y C, LV X T, *et al.* Detection of surface and internal defects in cold rolled steel [J]. *Chinese Optics*, 2024, 17(4): 823-833. (in Chinese)
- [18] HUANG C, CHEN M H, WANG L. Semi-supervised surface defect detection of wind turbine blades with YOLOv4 [J]. *Global Energy Interconnection*, 2024, 7(3): 284-292.
- [19] LIU Y H, ZHENG Y Q, WEI T, *et al.* Lightweight algorithm based on you only look once version 5 for multiple class defect detection on wind turbine blade surfaces [J]. *Engineering Applications of Artificial Intelligence*, 2024, 138: 109422.
- [20] HANG X Y, ZHU X X, GAO X X, *et al.* Study on crack monitoring method of wind turbine blade based on AI model: integration of classification, detection, segmentation and fault level evaluation [J]. *Renewable Energy*, 2024, 224: 120152.
- [21] MA Y X, YIN J X, HUANG F, *et al.* Surface defect inspection of industrial products with object detection deep networks: a systematic review [J]. *Artificial Intelligence Review*, 2024, 57(12): 333.
- [22] AMERI R, HSU C C, BAND S S. A systematic review of deep learning approaches for surface defect detection in industrial applications [J]. *Engineering Applications of Artificial Intelligence*, 2024, 130: 107717.
- [23] ZHAO L X, YU J B. Crop-paste and diffusion-based semi-supervised segmentation network for metal defect detection [J]. *Knowledge-Based Systems*, 2025, 318: 113573.

- [24] PAN J W, ZENG D Y, WU Z Z, *et al.* BiDNet: a real-time semantic segmentation network with antifeature interference and detail recovery for industrial defects [J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 5017916.
- [25] HOANG D C, TAN P X, NGUYEN A N, *et al.* Image-based anomaly detection in low-light industrial environments with feature enhancement [J]. *Results in Engineering*, 2025, 25: 104309.
- [26] MA W, LI Y, LAN S Y, *et al.* Semantic-aware normalizing flow with feature fusion for image anomaly detection [J]. *Neurocomputing*, 2024, 590: 127728.
- [27] 邓万字, 袁昭阳. 基于改进YOLOv8n的光伏板缺陷检测技术[J]. *液晶与显示*, 2025, 40(11): 1700-1709.
DENG W Y, YUAN Z Y. Photovoltaic panel defect detection technology based on improved YOLOv8n [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(11): 1700-1709. (in Chinese)
- [28] DING W Y, LIU H, CHEN F G. Video segmentation of industrial smoke based on dynamic fully convolutional network-Gaussian mixture model and multi-scale fusion attention module [J]. *Journal of Electronic Imaging*, 2023, 32(3): 033038.
- [29] YAO D P, XIE F Z, XU Y X. Bayesian sparse Gaussian mixture model for clustering in high dimensions [J]. *Journal of Machine Learning Research*, 2025, 26(1): 50.
- [30] GOHAR I, YEW W K, HALIMI A, *et al.* Review of state-of-the-art surface defect detection on wind turbine blades through aerial imagery: challenges and recommendations [J]. *Engineering Applications of Artificial Intelligence*, 2025, 144: 109970.
- [31] TAN M X, LE Q V. EfficientNetV2: smaller models and faster training [C]//*Proceedings of the 38th International Conference on Machine Learning*. Online: PMLR, 2021: 10096-10106.
- [32] JOCHER G. Ultralytics YOLO [EB/OL]. 2024. <https://github.com/ultralytics/ultralytics>.
- [33] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]. 3rd International Conference on Learning Representations. San Diego: ICLR, 2015: 1556.
- [34] HE K M, ZHANG X Y, REN S Q, *et al.* Deep residual learning for image recognition [C]//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016: 770-778.
- [35] HUANG G, LIU Z, VAN DER MAATEN L, *et al.* Densely connected convolutional networks [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017: 2261-2269.
- [36] SZEGEDY C, IOFFE S, VANHOUCKE V, *et al.* Inception-v4, inception-ResNet and the impact of residual connections on learning [C]//*Proceedings of the 31st AAAI Conference on Artificial Intelligence*. San Francisco: AAAI Press, 2017: 4278-4284.

作者简介:



郑欣,男,博士,副教授,2015年于电子科技大学获得博士学位,主要从事深度学习及人工智能方面的研究。
E-mail: 361368485@qq.com



黄威,男,博士,讲师,2022年于俄罗斯科学院设计与工艺信息学院获得博士学位,主要从计算机应用与计算机视觉方面的研究。E-mail: huangwei0731@163.com