基于无人机巡检图像的风电叶片缺陷检测方法

李　娜，刘晓旋，曹丽明

（中车永济电机有限公司西安中车电气研究院，西安 710016）

摘　要： 风电叶片是风力发电系统的关键结构组件，其表面缺陷将直接影响风电机组的运行效率与安全性。针对无人机采集的 8 192×5 460 超高分辨率图像在检测精度与效率方面带来的挑战，提出一种基于 YOLO 与 Transformer 融合结构的风电叶片多类别缺陷检测方法。首先，在 YOLO 主干网络之前引入轻量级 Transformer 模块，以增强输入阶段的全局语义感知能力。其次，为适配高分辨率图像的精细化检测需求，设计了一种窗口大小为 320×320、步长为 160 的高密度滑动窗口检测机制，实现缺陷区域的全覆盖处理。该方法支持裂纹、胶面脱落、污渍、腐蚀等类别叶片缺陷的高精度识别，并结合中文标注和面积换算模块，输出可视化图像与结构化缺陷数据。实验结果表明，在多个实际风场图像中，该方法均保持较高精度，同时具备良好的推理效率和小目标召回率，为风电设备智能巡检提供了可靠的技术支撑。

关键词： 风电叶片缺陷检测；YOLO；Transformer；滑动窗口；小目标识别；高分辨率图像处理

中图分类号： TP391　　**文献标识码：** A

Defect detection method for wind turbine blades based on drone inspection images

LI Na，LIU Xiaoxuan，CAO Liming

（Xi'an CRRC Electric Research Institute，CRRC Yongji Electric Motor Co.，Ltd.，Xi'an 710016，China）

Abstract：As the key structural components of wind power generation systems，wind turbine blades are characterized by surface defects that directly affect the operational efficiency and safety of the wind turbines. To address the challenges in detection accuracy and efficiency posed by ultra-high-resolution images of 8 192×5 460 pixels captured by Unmanned Aerial Vehicle（UAV），a multi-category defect detection method for wind turbine blades based on a fused YOLO and Transformer architecture is proposed. A lightweight Transformer module is introduced before the YOLO backbone network，by which the global semantic perception capability at the input stage is enhanced. Meanwhile，to accommodate the refined detection requirements of high-resolution images，a high-density sliding window detection mechanism with a window size of 320×320 and a stride of 160 is designed，by which full coverage processing of defect regions is achieved. High-precision recognition of multiple blade defect categories，including cracks，gel shedding，stains，and corrosion，is supported by the proposed method. Furthermore，visual images and structured defect data are output through the integration of Chinese annotation and an area conversion module. As demonstrated by experimental results on multiple real-world wind farm images，high accuracy，favorable inference efficiency，and robust small-target recall are maintained by the proposed method，thereby providing reliable technical support for the intelligent inspection of wind power equipment.

Key words：wind turbine blades defect detection，YOLO，Transformer，sliding window，small target recognition，high-resolution image processing

随着风电装机容量不断增加，风电运维模式正逐步由传统人工巡检向无人机智能巡检转变。风电叶片作为风电机组运行过程中的关键部件，其表面产生的裂纹、气蚀、胶面脱落、腐蚀等缺陷若未被发现和处理，可能进一步发展为局部结构损伤，严重时甚至导致部件脱落，对风电机组的安全稳定运行造成威胁[1-2]。因此，开展高精度、高效率的风电叶片缺陷检测研究，对于提升风电运维的智能化和数字化水平具有重要意义[3-6]。

目前，风电叶片缺陷检测方法主要包括基于传统图像处理的方法、基于卷积神经网络（Convolutional Neural Network，CNN）的检测方法，以及近年来逐渐发展的基于 Transformer 的模型改进方法[7-8]。其中，YOLO（You Only Look Once）系列检测器采用单阶段目标检测框架，具有检测速度快、端到端处理和工程部署便捷等优势，

已广泛应用于工业视觉检测领域[9-11]。然而,在细小缺陷检测场景下,传统YOLO模型对长距离上下文信息的建模能力仍存在一定局限,尤其对于风电叶片中的裂纹、点蚀等尺寸较小、纹理特征不明显的缺陷,容易出现漏检和定位不准确等问题[12]。

为增强模型对全局特征和上下文信息的表征能力,近年来Transformer结构逐渐被引入目标检测任务。Transformer依托自注意力机制能够有效建立不同区域之间的关联关系,从而增强模型对长距离依赖信息的建模能力,并为小目标识别提供更加充分的上下文特征[13-14]。基于此,本文在YOLO检测框架中引入轻量级Transformer模块,并将其设置于图像输入与Backbone主干网络之间,通过在卷积特征提取前引入全局语义信息,实现输入阶段的特征增强,为后续缺陷检测提供更加丰富的特征表示。

此外,风电叶片巡检图像通常具有较高的空间分辨率,本文所处理的典型图像分辨率达到8 192×5 460像素。若直接将原始图像缩放至常规的640×640输入尺寸,虽然能够降低模型计算量,但容易造成细小缺陷纹理和边缘信息丢失,从而降低小目标缺陷的检测能力。针对这一问题,本文设计了高密度滑动窗口检测策略,采用320×320像素的窗口和160像素的步长对原始图像进行重叠切片,分别对各窗口进行缺陷检测,再将检测结果映射至原始图像坐标系并进行融合。通过保留较高的图像细节,同时利用窗口间的重叠区域增强缺陷覆盖完整性,可有效降低小目标缺陷的漏检概率[15-16]。

为进一步提高检测结果的可读性和工程应用价值,本文设计了中文标注可视化与缺陷面积估算模块。该模块结合图像拍摄高度、成像参数等信息,对检测到的缺陷进行位置标注和面积换算,以结构化CSV文件形式输出相关结果,从而为后续缺陷统计、状态分析和维修决策提供数据支持。

本文主要贡献如下:(1)提出一种将轻量级Transformer模块引入YOLO输入阶段的检测结构,通过增强输入阶段的全局语义感知能力,提高模型对风电叶片细小缺陷及其上下文特征的表征能力;(2)针对8 192×5 460超高分辨率巡检图像,设计窗口大小为320×320像素、步长为160像素的高密度滑动窗口检测机制,在减少图像缩放造成的细节损失的同时,提高小目标缺陷的检测能力;(3)构建多类别缺陷检测与结果输出机制,实现裂纹、腐蚀、胶面脱落等缺陷的统一检测,并结合中文标注、缺陷面积换算和defect_summary结构化数据输出,提高检测结果的可读性和工程应用价值;(4)基于多个真实风场巡检图像开展实验验证,从检测精度、推理效率和小目标召回能力等方面对所提方法进行评价,验证其在实际风电叶片智能巡检场景中的应用潜力。

1 相关工作

风电叶片缺陷检测技术经历了由传统图像处理方法、基于深度卷积神经网络的检测方法向Transformer融合检测方法逐步发展的过程。针对不同技术路线的特点,本文从YOLO及其在缺陷检测中的应用、Transformer在视觉检测中的集成方式,以及高分辨率图像的小目标检测策略3个方面对相关研究进行梳理。

1.1 YOLO及其在缺陷检测中的应用

YOLO是一类基于回归思想的单阶段目标检测框架。自YOLOv1提出以来,该系列模型不断发展,形成了YOLOv5和YOLOv7等具有代表性的版本。其中,YOLOv5在检测精度与推理速度之间具有较好的平衡,在工业缺陷检测任务中得到了广泛应用。针对实际工程环境对实时性和部署效率的要求,YOLO系列模型能够在保证一定检测精度的基础上降低计算资源需求,因此具有较好的工程应用价值。

在风电叶片缺陷检测领域,已有研究将YOLO系列模型应用于叶片裂纹、腐蚀等表面缺陷识别。例如,Tan采用改进YOLOv5网络对风电叶片表面缺陷图像进行训练,在缺陷识别任务中取得了较高的检测精度[17]。然而,由于风电叶片缺陷具有尺寸小、形态不规则以及与叶片背景纹理相似等特点,传统YOLO模型在细小缺陷检测过程中仍易受特征信息不足的影响,在裂纹、点蚀等小尺寸目标检测方面存在一定的漏检问题。

1.2 Transformer在视觉任务中的集成方式

Transformer最初由Vaswani等提出,并应用于自然语言处理领域[18]。其核心自注意力机制能够建立序列中不同位置之间的关联关系,从而有效捕获长距离依赖信息。随着研究不断深入,Transformer逐渐被引入计算机视觉领域,并应用于图像分类、目标检测和语义分割等任务。

在目标检测领域,DETR模型首次将Encoder-Decoder Transformer结构引入目标检测任务,通过集合预测方式实现端到端目标检测[19]。随后,Swin Transformer采用分层结构和窗口自注意力机制,在降低计算复杂度的同时增强了不同尺度视觉特征的建模能力,成为视觉Transformer的重要代表之一。

近年来,研究者开始进一步探索Transformer与YOLO等卷积神经网络检测器的融合方式,并将Transformer用于增强工业缺陷检测中的全局特征表达能力。例如,Li[20]将轻量级Transformer引入YOLOv4检测器,在焊缝缺陷和金属表面损伤识别任务中提高了模型的召回性能。相关研究表明,卷积神经网络具有较强的局部特征提取能力,而Transformer能够有效补充全局上下文建模能力,二者具有较好的互补性。

在此基础上,本文将轻量级Transformer模块嵌入

YOLO 检测框架，并设置于图像输入与 Backbone 主干网络之间，使模型在进入传统卷积特征提取阶段之前获得一定的全局上下文信息，从而实现输入阶段的语义增强。与主要在主干特征提取阶段或检测头部分引入 Transformer 的方案相比，本文重点探索其在输入阶段的特征增强作用，以改善微小缺陷区域的初始特征表达，为后续多尺度特征提取和目标检测提供更充分的上下文信息。

1.3　小目标检测与滑动窗口检测机制

风电叶片巡检图像通常具有较高的空间分辨率，而缺陷目标在整幅图像中的尺寸相对较小，若经过大比例缩放，缺陷区域可能仅占据少量像素，其纹理、边缘等关键特征容易在下采样过程中丢失。因此，小目标缺陷检测是风电叶片视觉巡检中的关键技术难点之一[21-22]。

滑动窗口检测是一种适用于超高分辨率图像目标检测的有效方法。其基本思想是按照预设窗口尺寸将原始图像划分为多个局部区域，并通过一定程度的窗口重叠保证目标区域被充分覆盖，再将各窗口分别输入检测模型进行推理，最后将局部检测结果映射回原始图像坐标系并进行统一融合。与直接缩放整幅图像相比，该方法能够在较大程度上保留原始图像中的细节信息，因此特别适用于尺寸较小、分布分散的缺陷目标检测。

已有研究将滑动窗口策略应用于工业缺陷检测。例如，Zhou[23]针对金属表面缺陷检测采用窗口大小为 256×256 像素、步长为 128 像素的滑动窗口策略，有效提高了点蚀和裂纹等细小缺陷的召回率。此外，结合滑动窗口的目标检测方法被应用于遥感图像目标识别、交通标志检测等场景，进一步表明该策略适用于超大尺寸图像中的目标检测任务。

针对风电叶片巡检图像分辨率高、缺陷尺寸小且分布具有一定随机性的特点，本文设计了窗口大小为 320×320 像素、步长为 160 像素的高密度滑动窗口检测策略。窗口步长设置为窗口尺寸的 1/2，使相邻窗口之间保持较高比例的重叠区域。当缺陷位于窗口边缘时，可通过相邻窗口对其进行重复覆盖和检测，从而降低因目标被窗口截断而造成的漏检风险。完成各窗口独立检测后，将检测框映射至原始图像坐标系，并通过全局非极大值抑制（Non-Maximum Suppression，NMS）对重叠检测框进行筛选和融合，以减少重复检测结果，在保证检测覆盖率的同时兼顾检测精度和处理效率[24-25]。

2　方法设计

实际无人机巡检图像具有分辨率高、缺陷目标尺寸小、缺陷类型多样等特点。对此，本文设计了一种融合轻量级 Transformer 的改进 YOLO 缺陷检测方法，并结合高密度滑动窗口检测机制，实现超高分辨率叶片图像中的细粒度缺陷检测。整体检测流程如图 1 所示，主要包括图像滑动窗口切片、模型推理、检测结果坐标映射、结果融合、中文可视化以及缺陷面积统计等环节。

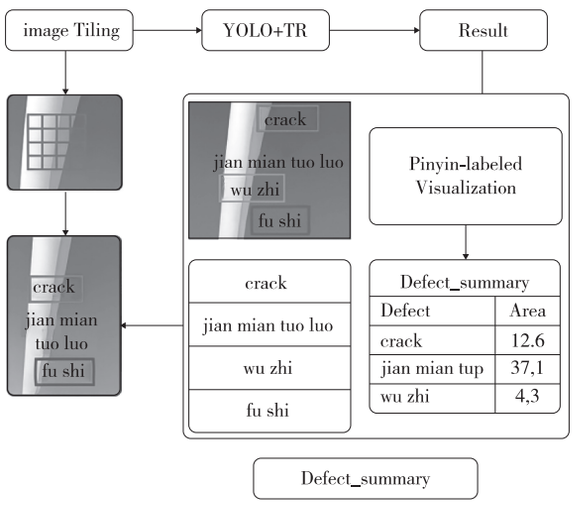

图 1　风电叶片缺陷检测方法流程

2.1　模型整体结构

本文以 YOLOv5s 网络为基础，在 YOLO 主干网络之前引入轻量级 Transformer 模块，以增强模型对输入图像全局上下文信息的感知能力，整体网络结构如图 2 所示。

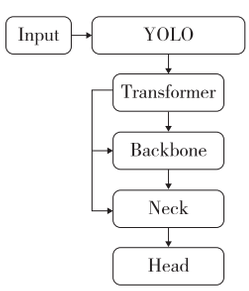

图 2　网络主干结构

（1）输入层：将高分辨率原始图像经滑动窗口切分后得到的 320×320 像素图像块作为模型输入。

（2）Transformer 编码器模块：在输入层之后引入轻量级 Swin Transformer 模块，采用基于窗口的多头自注意力（Window-based Multi-head Self-Attention，W-MSA）机制，对局部区域内的特征关系进行建模，并通过窗口划分降低自注意力机制带来的计算开销。

（3）YOLO 主干网络：采用 YOLOv5s 中的 CSPDarknet53 作为骨干特征提取网络，对经过 Transformer 增强后的图像特征进行进一步提取，获得不同层次的语义和空间特征。

（4）PAN-FPN 结构：保留 YOLOv5s 中的路径聚合特征金字塔网络（Path Aggregation Network-Feature Pyramid Network，PAN-FPN），对不同尺度的特征进行融合，以增强模型对不同尺寸缺陷目标的检测能力。

（5）检测头：通过检测头对多尺度特征图进行预测，输出缺陷目标的边界框、目标置信度以及类别概率，实现叶片缺陷的位置定位和类别识别。

通过上述结构设计，模型在进入传统卷积特征提取

阶段之前即可获得一定的上下文语义信息，从而增强对纹理对比度较低、形态细长的裂纹以及腐蚀等缺陷的特征表征能力，在保持YOLO检测效率的同时提高细小缺陷的识别能力。

2.2 滑动窗口检测机制

本文处理的无人机巡检原始图像分辨率为8 192×5 460像素，远高于模型常规训练输入尺寸。若直接将整幅图像缩放至640×640后输入检测模型，虽然能够降低计算量，但会导致细小缺陷区域所占像素比例显著降低，使裂纹、点蚀等目标的纹理和边缘信息发生不同程度的损失。为解决这一问题，本文采用高密度滑动窗口检测机制，将原始图像划分为多个局部区域后分别进行检测，具体流程如图3所示。

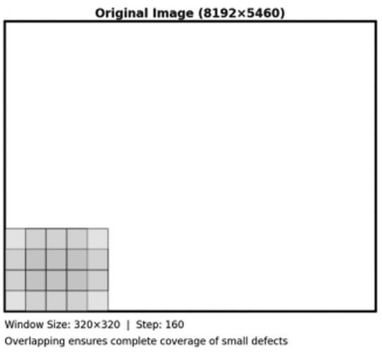

图3 图像切片过程

（1）图像切片：对原始图像进行规则化切片，窗口大小设置为320×320像素，步长设置为160像素。由于步长为窗口尺寸的一半，相邻窗口之间具有50%的重叠区域，从而保证位于窗口边缘附近的缺陷能够被相邻窗口重复覆盖和检测。

（2）批量模型推理：将切分得到的图像块分别输入改进后的“YOLO+Transformer”检测网络，独立完成缺陷目标检测，并获得各窗口内目标的边界框、类别和置信度等信息。

（3）坐标回映射：根据每个滑动窗口在原始图像中的左上角坐标，将窗口内预测得到的边界框转换至原始图像坐标系，使局部检测结果与整幅图像空间位置对应。

（4）全局NMS融合：将所有窗口的检测结果统一映射至原始图像坐标系后，采用NMS进行结果融合，去除由于窗口重叠产生的重复检测框，保留置信度较高的有效检测结果。

（5）结果可视化与数据输出：根据最终融合结果在原始图像中绘制缺陷边界框和中文类别标签，并将缺陷类别、位置、置信度及面积等信息写入CSV文件。

该滑动窗口策略避免了超高分辨率图像直接缩放造成的细节损失，同时利用窗口重叠提高了边缘区域的缺陷覆盖率。实验结果表明，与传统整图缩放方法相比，该策略能够明显提升小目标缺陷的召回能力[26]。

2.3 多类别缺陷识别任务设计

针对风电叶片实际运行过程中可能出现的典型表面缺陷，本文将检测任务设置为6类目标检测任务。具体缺陷类别及其主要视觉特征如表1所列。

表1 风电叶片缺陷类别

类别编号	缺陷类型	特征描述
C1	裂纹	呈线性不连续结构，纹理对比度较低，通常具有细长形态
C2	胶面脱落	表层材料局部脱落，边缘不规则，缺陷面积通常较大
C3	污渍	图像局部颜色加深，分布不均匀，形状具有较强随机性
C4	腐蚀	通常表现为点状或斑状异常区域，多集中于金属部位
C5	开裂	局部结构破损，边缘较为粗糙，具有明显的结构变化特征
C6	胶衣脱落	表面保护层脱落，局部出现颜色异常区域，纹理特征相对不明显

模型采用多类别检测头，同时输出不同缺陷类别对应的预测结果。训练过程中采用GIoU，BCE与Focal Loss组合损失函数，其中GIoU用于优化边界框回归，BCE用于类别和目标置信度学习，Focal Loss用于缓解不同类别以及难易样本之间的不均衡问题。测试阶段主要采用mAP@0.5，mAP@0.5:0.95，Precision，Recall和F1-score等指标评价模型性能。

该模型能够在同一检测框架下完成6类缺陷的统一识别，并分别输出各类别目标的位置和置信度等信息，为后续缺陷统计和状态分析提供基础数据。

3 实验设置与结果分析

为验证所提“YOLO+Transformer”缺陷检测方法在超高分辨率风电叶片巡检图像中的有效性，本文构建风电叶片缺陷图像数据集，并开展模型训练和测试实验。实验主要从整体检测精度、推理效率、小目标检测能力、不同滑动窗口参数以及各类别缺陷识别性能等方面对所提方法进行综合评价。

3.1 数据集构建

由于目前公开的高分辨率、多类别风电叶片缺陷图像数据集相对有限，本文基于实际风场巡检任务采集无人机图像，并通过人工标注构建风电叶片缺陷数据集。具体数据采集与处理过程如下。

图像来源：采用无人机巡检系统搭载35 mm焦距工业相机，在距叶片8~14 m的范围内进行图像采集，共获得约2 000张叶片巡检图像，原始图像分辨率为8 192×5 460像素。

缺陷类别：数据集包含裂纹、胶面脱落、污渍、腐蚀、开裂和胶衣脱落6类典型缺陷，缺陷类别及标注依据参考实际风电叶片运维检测标准，并结合现场专家经验进

行确定。

标注方式：采用LabelImg工具对缺陷区域进行矩形框标注，并统一转换为YOLO格式（即class x_center y_center width height），其中坐标和尺寸均进行归一化处理。

数据划分：按照70%∶15%∶15%的比例划分训练集、验证集和测试集，并尽可能保证不同数据子集中的各类别缺陷具有相对均衡的分布。

3.2　训练设置与超参数配置

模型训练采用PyTorch深度学习框架，在NVIDIA RTX A4000 GPU上完成。主要训练参数如表2所列。

表2　模型训练参数

参数名称	设置值
输入尺寸	640×640（训练）
滑窗参数	320×320，步长160（推理）
优化器	AdamW
初始学习率	0.000 1
Batch size	16
Epoch	300
数据增强	Mosaic、ColorJitter、Mixup、HSV变换
损失函数	GIoU+BCE+Focal Loss

Transformer模块采用Swin-Tiny配置，窗口大小设置为8，嵌入维度（Embedding Dimension）设置为64，通过控制网络规模将模型参数量控制在13.5 M以内，以兼顾特征表达能力和推理效率。

3.3　评价指标定义

为从检测精度、目标召回和推理效率等维度评价模型性能，本文采用以下指标。

mAP@0.5：当预测框与真实标注框之间的交并比（Intersection over Union，IoU）不低于0.5时，根据各类别的平均精度（Average Precision，AP）计算平均精度均值（mean Average Precision，mAP），用于评价模型整体目标检测精度。

mAP@0.5∶0.95：分别计算IoU阈值为0.50，0.55，0.60，…，0.95时的mAP，并对各阈值结果取平均，以更加严格地评价模型的目标定位精度。

Recall/Precision/F1-score：Precision表示预测为缺陷的样本中实际为缺陷的比例；Recall表示真实缺陷中被模型正确检测出的比例；F1-score为Precision和Recall的调和平均值，用于综合评价模型的精确率和召回率。

Small-object Recall：将尺寸小于32×32像素的检测目标定义为小目标，并计算该类目标的召回率，用于评价模型对细小缺陷的识别能力。

FPS：表示模型单位时间内完成的图像推理数量，用于衡量模型检测效率。本文统计滑动窗口完成整幅图像处理后的整体推理效率。

3.4　精度与速度对比实验

为验证Transformer模块对检测性能的改善作用，本文选取YOLO，YOLO-tiny和“YOLO+TR”3种模型进行对比，其中YOLO作为基线模型，YOLO-tiny作为轻量化检测模型，“YOLO+TR”为本文提出的融合Transformer结构的检测模型。实验结果如表3所列。

表3　不同检测方法性能对比

模型	mAP@0.5/%	mAP@0.5∶0.95/%	Recall/%	Small-object Recall/%	FPS
YOLO	85.4	61.2	84.1	54.6	95
YOLO-tiny	87.1	63.7	86.2	59.3	88
YOLO+TR（本文模型）	91.0	69.4	88.7	72.6	72

由表3可知，“YOLO+TR”模型的mAP@0.5达到91.0%，较基线YOLO提高5.6个百分点；mAP@0.5∶0.95达到69.4%，提高8.2个百分点。同时，Small-object Recall由54.6%提高至72.6%，提升18.0个百分点，说明Transformer模块能够有效增强模型对细小缺陷的特征表征能力。

3.5　滑动窗口效果分析

为进一步分析不同图像处理策略对缺陷检测性能的影响，本文对整图缩放、无重叠滑动窗口和半重叠滑动窗口3种策略进行对比，实验结果如表4所列。

表4　不同滑动窗口策略对检测结果的影响

滑窗策略	窗口大小	步长	Recall/%	漏检率/%	FPS
整图缩放	640×640	—	41.7	22.4	110
滑窗无重叠	320×320	320	62.3	13.7	83
滑窗半重叠（本文策略）	320×320	160	72.6	9.2	72

由表4可知，整图缩放方式虽然具有最高的处理速度，但Recall仅为41.7%，且漏检率达到22.4%，表明直接压缩超高分辨率图像会造成明显的小目标信息损失。采用320×320无重叠滑动窗口后，Recall提高至62.3%，漏检率下降至13.7%，说明图像切片能够有效保留细小缺陷特征。进一步将步长降低至160后，相邻窗口形成50%的重叠区域，Recall提高至72.6%，漏检率进一步下降至9.2%。虽然FPS由83下降至72，但检测完整性得到明显改善。因此，320×320窗口与160步长能够在检测精度、目标覆盖率和计算效率之间取得较好的平衡，适用于本文风电叶片超高分辨率图像检测任务。

3.6　缺陷类别识别准确度分析

为分析模型对不同类别缺陷的识别能力，进一步计算各类别的Precision，Recall和F1-score，结果如表5所列。

由表5可知，6类缺陷的F1-score均超过85%，说明模型对不同类型叶片缺陷具有较为稳定的识别能力。其中，腐蚀类别的F1-score最高，达到91.2%；裂纹与胶

面脱落的F1-score分别达到90.1%和90.0%，表明模型能够较好地提取结构性和纹理性缺陷特征；胶衣脱落的F1-score相对较低，为85.8%，主要是由于该类缺陷纹理特征不明显，且部分区域与叶片背景之间的颜色和亮度差异较小，增加了目标定位与类别判断的难度。总体而言，本文模型能够实现多类别风电叶片缺陷的有效识别。

表5 各类缺陷识别结果(%)

类别	Precision	Recall	F1-score
裂纹	91.2	89.1	90.1
胶面脱落	92.8	87.3	90.0
污渍	88.7	86.2	87.4
腐蚀	93.6	88.9	91.2
开裂	89.1	86.7	87.9
胶衣脱落	87.4	84.3	85.8

4 消融实验与对比分析

为进一步分析各关键模块对检测性能的实际贡献，设计消融实验和对比实验，从Transformer模块插入位置、滑动窗口参数以及类别识别结果等方面进行验证。同时，通过不同工况下的实景测试分析模型的鲁棒性和实际应用能力。

4.1 Transformer插入位置对比

为分析Transformer模块不同嵌入位置对模型检测精度和推理效率的影响，本文设计以下4种网络结构进行对比。

YOLO（Baseline）：采用原始YOLOv5s网络，不引入Transformer模块。

YOLO+TR@Input（本文模型）：将Transformer模块设置于输入图像与Backbone之间，在卷积特征提取之前进行上下文信息增强。

YOLO+TR@BackboneMid：将Transformer模块嵌入CSPDarknet主干网络中间层，以增强中间层特征的全局建模能力。

YOLO+TR@Neck：将Transformer模块设置于PAN-FPN特征融合层之后，对融合后的高层语义特征进行进一步增强。

不同结构的测试结果如表6所列。

表6 Transformer不同插入位置的性能对比

模型结构	mAP@0.5/%	Recall/%	参数量	FPS
YOLOv5s	85.4	54.6	7.5 M	95
+TR@Input（本文模型）	91.0	72.6	13.5 M	72
+TR@BackboneMid	89.4	68.9	15.1M	66
+TR@Neck	87.7	64.3	14.4M	68

由表6可知，在输入阶段引入Transformer能够获得最高的mAP@0.5和Recall，分别达到91.0%和72.6%。与原始YOLOv5s相比，mAP@0.5提高5.6个百分点，Recall提高18.0个百分点。

相较于在Backbone中间层和Neck阶段引入Transformer，输入阶段融合方式在检测精度方面表现更优，同时参数量仅为13.5 M，低于Backbone中间层和Neck两种方案。虽然引入Transformer后FPS有所下降，但综合检测精度、召回率和参数规模来看，将Transformer设置于输入与Backbone之间能够在特征增强和计算开销之间取得较好的平衡。

4.2 滑动窗口参数消融

为验证320×320窗口和160像素步长设置的合理性，本文进一步对不同窗口尺寸和步长组合进行消融实验，结果如表7所列。

表7 不同滑动窗口及步长组合的性能对比

窗口大小	步长	Recall/%	mAP@0.5/%	FPS
640×640	—	41.7	85.4	110
320×320	320	62.3	87.9	83
320×320	160	72.6	91.0	72
256×256	128	73.2	91.4	59

由表7可知，减小窗口尺寸并增加窗口重叠程度能够进一步提升模型对细小缺陷的检测能力。当采用256×256窗口、128步长时，Recall和mAP@0.5分别达到73.2%和91.4%，略高于本文所采用的320×320，160像素方案，但FPS降低至59，计算开销明显增加。

相比之下，320×320窗口、160步长在检测精度和推理效率之间具有更好的综合性能。因此，综合考虑检测效果、计算成本以及实际无人机巡检任务中的处理效率，本文最终选择320×320窗口和160步长作为滑动窗口参数。

4.3 类别混淆矩阵分析

为进一步分析不同缺陷类别之间的分类混淆情况，统计模型在主要缺陷类别上的混淆矩阵结果，部分结果如表8所列。

由表8可知，大多数样本能够被正确分类，不同缺陷类别之间的混淆程度总体较低。其中，腐蚀与污渍之间存在相对明显的类别混淆，主要原因可能是两类缺陷在部分巡检图像中具有相近的灰度分布和纹理表现，导致模型在局部视觉特征不足时难以进行准确区分。

表8 混淆矩阵结果

True/Pred	裂纹	胶面脱落	腐蚀	污渍
裂纹	192	6	3	2
胶面脱落	7	184	5	3
腐蚀	4	6	173	10
污渍	2	3	8	182

相比之下，裂纹和胶面脱落的正确分类数量较高，说明模型能够利用二者在结构形态和空间特征方面的差异进行有效区分。总体来看，各主要类别具有较高的分类正确率，表明融合 Transformer 后，模型对缺陷结构和上下文特征具有较好的综合表征能力。

4.4　鲁棒性分析与实景适应性

为验证模型在实际无人机巡检环境中的适应能力，本文选取不同成像条件下的叶片图像进行测试，主要包括以下 4 种典型工况：强光反射、雨后残留水珠、图像模糊与局部遮挡、远距离及大角度拍摄。

在相同测试数据和评价条件下，将本文方法与基础 YOLO 模型进行对比，并进一步分析 Transformer 模块与滑动窗口策略带来的性能增益。不同模型在上述场景下的 mAP@0.5 和 Recall 如图 4 所示。

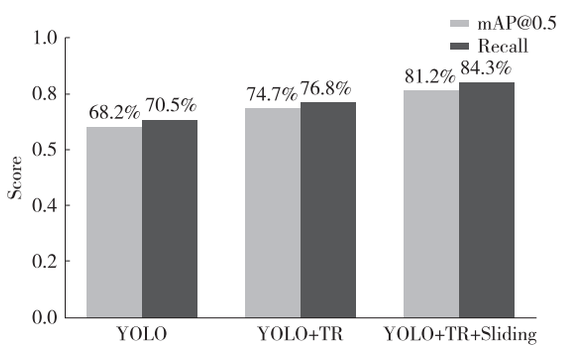

图 4　各模型检测精度与召回率对比

由图 4 可知，在不同实际巡检工况下，本文方法均保持较好的检测性能，mAP@0.5 均高于 88%，未出现明显的大面积漏检现象。尤其在远距离和图像轻度模糊场景中，Transformer 模块能够利用更充分的上下文信息辅助缺陷特征判断，在一定程度上弥补局部纹理信息缺失带来的影响。同时，滑动窗口策略能够避免高分辨率图像整体缩放造成的细节损失，使小尺寸缺陷在输入模型时仍保留较为完整的空间信息。两种策略的协同作用使模型在复杂实际场景下表现出较好的鲁棒性，为无人机风电叶片智能巡检的工程应用提供了支撑。

5　结束语

针对无人机风电叶片巡检过程中存在的图像分辨率高、缺陷目标尺寸小以及缺陷类型多样等问题，本文提出一种融合轻量级 Transformer 与高密度滑动窗口机制的 YOLO 风电叶片缺陷检测方法。通过在 YOLO 输入阶段引入 Transformer 模块，并结合超高分辨率图像滑动窗口检测策略，实现了对叶片细小缺陷的精细化识别。

尽管本文方法在风电叶片多类别缺陷检测任务中取得了较好的实验结果，但在复杂环境适应、缺陷精细分类以及工程部署等方面仍存在进一步优化空间。(1)增强相似缺陷的类别区分能力。当前腐蚀与污渍等类别在部分复杂场景下仍存在一定程度的特征混淆。后续可引入局部特征增强机制、注意力模块或语义分割分支，进一步提取缺陷边缘、纹理和区域结构特征，提高相似缺陷的分类精度。(2)扩展至视频序列检测与目标跟踪。该方法主要针对无人机巡检静态图像进行检测，后续可将模型扩展至巡检视频帧序列，通过引入目标跟踪和跨帧特征关联机制，实现缺陷目标的连续跟踪与跨帧一致性验证，降低单帧检测结果波动对巡检结果的影响。(3)引入多模态与少样本学习机制。除可见光图像外，可进一步融合红外图像、热成像等多模态信息，从不同维度获取叶片缺陷特征。同时，可结合自监督学习、迁移学习或少样本学习方法，降低模型对大规模人工标注数据的依赖，提高模型在不同风场和不同叶片类型上的泛化能力。(4)开展模型轻量化与边缘部署研究。针对无人机端或边缘计算设备计算资源有限的问题，可进一步采用模型剪枝、知识蒸馏和量化等方法压缩模型规模，并结合 ONNX 和 TensorRT 等推理加速技术，提高模型在边缘设备上的实时检测能力。(5)构建缺陷检测与运维决策闭环。在现有缺陷检测和面积统计功能的基础上，可进一步建立风电叶片缺陷数据库，对缺陷位置、面积、类别及历史变化趋势进行统一管理，并结合缺陷等级评估和叶片健康状态分析，逐步形成“图像采集—缺陷检测—状态评估—趋势分析—维修决策”的智能运维闭环。

参考文献：

[1] DOSOVITSKIY A. An image is worth 16×16 words: Transformers for image recognition at scale [EB/OL]. https://arxiv.org/abs/2010.11929? featured_on=pythonbytes.

[2] REDMON J. You only look once: Unified, real-time object detection [EB/OL]. https://arxiv.org/pdf/1506.02640.

[3] 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.

[4] 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.

[5] 王洪金，刘香怡，何赟泽，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.

[6] 何赟泽，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.

[7] TAN C. Wind turbine blade surface defect detection based on improved YOLOv5 model [J]. IEEE Access，2021，9：36642-36651.

[8] ZHENG H. Wind turbine blade defect detection using UAV images and deep learning [J]. Renewable Energy，2020，145：1546-1556.

[9] 白健鹏，勾月凯. 基于轻量型 YOLOv5 的风机桨叶检测与空间定位[J]. 交通信息与安全，2022，40(4)：1-12.

[10] 范虹宇,胡兴柳,马尹琪.基于改进的YOLOv7和无人机航拍技术的风机叶片缺陷检测[J].建模与仿真,2023,12(5):4855-4867.
[11] LIN T Y.Feature pyramid networks for object detection[EB/OL].https://cloud.tencent.com/developer/article/1489074.
[12] LIU Z,LIN Y,CAO Y,et al.Swin Transformer:Hierarchical vision transformer using shifted windows[EB/OL].https://borninfreedom.github.io/posts/2024/12/blog-post-3/.
[13] WANG L.A sliding window approach to detect defects in high-resolution images[J].Sensors,2022,22(7):2571.
[14] LIU W.SSD:Single shot multibox detector[EB/OL].https://cloud.tencent.com/developer/article/1489167.
[15] RAN Q.An improved algorithm for wind turbine blade defect detection[J].IEEE Access,2022,10:107932-107944.
[16] SVYSTUN S.Precision slicing for enhanced defect detection in high-resolution imaging[J].CEUR Workshop Proceedings,2024:1-18.
[17] WU Z.Algorithm for detecting surface defects in wind turbines based on a lightweight YOLO model[J].Scientific Reports,2024,14:12345.
[18]CHEN Y.PP-YOLO:An effective and efficient implementation of object detector[EB/OL].https://www.cnblogs.com/shuimobanchengyan/p/15240042.html.
[19] CHEN Y.Residual attention network for image classification[EB/OL].https://www.cnblogs.com/RyanXing/p/res_attention_net.html.
[20] LI L.Blade defect detection of wind turbine using enhanced YOLOv4 with UAV[J].Journal of Cleaner Production,2022,352:131396.
[21] LIN M.Network in network[EB/OL].https://zhuanlan.zhihu.com/p/181718930.
[22] LIU Y.Small object detection using context and attention[J].Neurocomputing,2022,469:42-53.
[23] ZHOU B.Object detection in remote sensing images using attention-based detection networks[J].Remote Sensing,2020,12(5):785.
[24] 梁海翔,唐艳慧,王宇庆,等.高分辨率遥感图像的目标检测[J].液晶与显示,2024,39(10):1350-1362.
[25] 吴柳青,胡翔云.基于多尺度多特征的高空间分辨率遥感影像建筑物自动化检测[J].国土资源遥感,2019,31(1):71-78.
[26] WANG S,ZHANG J.Few-shot defect detection for industrial scenarios via meta-learning[J].Pattern Recognition,2021,115:107899.

作者简介:

李娜(1986—),硕士,高级工程师,研究方向:风力发电、轨道交通智能产品设计及应用,E-mail:408103566@qq.com。

(上接第130页)

对较弱,因此不作重点分析。

4 结束语

基于通信岗位人员数据,本文采用Apriori关联规则算法分析了岗位、学历、技术等级与培训级别之间的关联关系。结果表明,不同岗位人员在学历、技术等级及培训层级方面存在一定关联特征,可据此识别不同人员群体的培训需求差异,增强培训计划制定的针对性。受样本数量和数据范围限制,相关分析结果存在一定局限性,后续可进一步扩大数据规模,并结合更多人员能力与培训效果指标,提高培训需求分析的准确性。

参考文献:

[1] 管军霖,师功才,陈宏.基于Apriori风险数据分析的网络漏洞挖掘研究[J].计算机仿真,2022,39(1):343-347.
[2] 余锐,郑亮,熊俊,等.基于改进Apriori算法的电力通信设备缺陷关联性分析[J].中国安全生产科学技术,2021,44(12):176-181.
[3] 李芳,郭进利,谭利明.基于Apriori算法的公司股东关联分析[J].软件导刊,2021,21(3):106-109.
[4] 李雄飞,董元方,李军,等.数据挖掘与知识发现[M].北京:高等教育出版社,2017:18-20.
[5] 袁梅宇.数据挖掘与机器学习WEKA应用技术与实践[M].北京:清华大学出版社,2017:107-117.
[6] 杨宇.背景知识在数据发布隐私保护中的应用与分析[J].武警工程大学学报,2018,38(4):18-21.
[7] 王丽,薛淑晖,吴海涛.基于Apriori算法的专利数据关联分析[J].信息与电脑,2020,34(7):31-32.

作者简介:

肖静静(1980—),本科,研究方向:信息通信。