

C2P-YOLO:一种轻量级的风电塔筒裂缝检测算法

段鹏松¹ 高杨¹ 张大龙¹ 曹仰杰¹ 赵杰²

1 郑州大学网络空间安全学院 郑州 450000

2 上海红檀智能科技有限公司 上海 200000

(duanps@163.com)

摘要 风电塔筒作为整个风电设备的支撑结构,其安全性至关重要。裂缝作为风电塔筒主要的病害之一,对其进行准确检测十分有必要。受限于特征提取能力不足,现有的裂缝检测算法存在精度较低、模型复杂度较高的问题,不能很好满足端侧设备现场检测的需求。为此,文中提出了一种基于YOLO的风电塔筒安全性检测算法C2P-YOLO。在主干网络部分,该算法利用轻量级的特征提取模块C2P来代替冗余的网络结构,以提取特征图中更丰富的特征信息。在颈部网络部分,该算法添加了轻量化上采样CARFE和注意力机制模块,以补充特征融合过程中的信息损失。实验结果表明,该算法在公开数据集NEU-DET上的mAP分数达到84.9%,相较于同类算法提升了3%~8%,且能保持较好的轻量化特性。

关键词:深度学习;缺陷检测;目标检测

中图分类号 TP183;TP391.41

C2P-YOLO: A Lightweight Crack Detection Algorithm for Wind Turbine Towers

DUAN Pengsong¹, GAO Yang¹, ZHANG Dalong¹, CAO Yangjie¹ and ZHAO Jie²

1 School of Cyberspace Security, Zhengzhou University, Zhengzhou 450000, China

2 Shanghai Red Sandalwood Intelligent Technology Co., Ltd., Shanghai 200000, China

Abstract The safety of wind turbine tower, as the support structure of the whole wind turbine, is crucial. As one of the main diseases of wind turbine tower, it is necessary to detect cracks accurately. Due to the lack of feature extraction capability, the existing crack detection algorithms have low accuracy and high model complexity, which cannot well meet the needs of end-side equipment on-site detection. For this reason, this paper proposes a YOLO-based wind tower safety detection algorithm C2P-YOLO. In the backbone network part, the algorithm utilizes the lightweight feature extraction module C2P instead of the redundant network structure, in order to extract richer feature information in the feature map. In the neck network part, the algorithm adds the lightweight up-sampling CARFE and attention mechanism modules to complement the information loss in the feature fusion process. Experimental results show that the algorithm achieves a mAP score of 84.9% on the publicly available dataset NEU-DET, which is 3%~8% higher than similar algorithms, and it can maintain a better lightweight property.

Keywords Deep learning, Defect detection, Object detection

目前,风力发电技术随着全球清洁能源需求的增加而蓬勃发展。然而,风力发电设备规模和数量在增长的同时,也带来了严重的安全性问题。风电塔筒作为整个风力设备的支撑结构,其在恶劣的自然环境中经常受到风力、紫外线辐射、温度变化等多种外部因素的侵蚀,从而导致风电塔表面产生腐蚀、裂纹等问题,影响其稳定性和安全性^[1]。目前,对于风电设施的安全性检测大多还停留在效率较低的人工检测阶段,无法满足当前工业领域对风电设施检测的智能化需求。因此,快速、准确的风电塔筒的表面缺陷检测研究成为保障风力发电安全可靠运行的迫切需求。

目标检测技术(Object Detection)是计算机视觉领域的研究热点之一,在人脸识别、车辆追踪以及工业缺陷检测等实际

应用场景中有着广泛的应用。该技术可以检测出风电塔筒表面图片上存在的缺陷,从而帮助从业者简单、高效地完成对风电塔筒维护工作。工业目标检测方法可以分为传统目标检测和基于深度学习的目标检测两类,但随着技术及数据的发展,传统的目标检测算法因时间效率低下以及鲁棒性和准确度较差,开始无法满足工业上的应用需求,基于深度学习的目标检测技术成为计算机视觉领域研究的焦点之一。

目前研究人员就基于深度学习的工业缺陷目标检测技术提出了多种算法,其代表性工作主要有文献[2-3]。Han等^[2]提出一种基于特征融合与级联检测网络的Faster R-CNN模型,其能准确检测出钢材表面缺陷的种类和位置。但其庞大的模型规模以及复杂的模型结构导致其在实际运用中

基金项目:郑州市协同创新重大专项(20XTZX06013);中国工程科技发展战略河南研究院战略咨询研究项目(2022HENYB03);河南省科技攻关项目(232102210050,242102210060)

This work was supported by the Zhengzhou City Collaborative Innovation Major Project(20XTZX06013), Strategic Consulting Research Project of Henan Research Institute of China Engineering Science and Technology Development Strategy(2022HENYB03) and Science and Technology Tackling Project of Henan Province(232102210050,242102210060).

通信作者:曹仰杰(caoyj@zzu.edu.cn)

存在很大限制,检测速度不佳。Si 等^[3]提出基于轻量化 YOLOv4 的工业缺陷检测模型,在 Neck 部分引入深度可分离卷积,大大减少了模型参数量,提升了检测速度。但该算法在面对复杂密集的风电塔筒缺陷时,难以进行高精度的分类和检测。

针对以上问题,本文对实时目标检测模型 YOLOv7 进行改进创新,引入全新的轻量化特征提取模块和高精度的小目标检测模块,提出了 C2P-YOLO 检测算法。

本文主要的研究内容及创新点如下:

1)提出了一种基于 C2P 的轻量级特征提取网络 Backbone。针对主干网络部分,本文设计了轻量级的 C2P 特征提取模块来代替其中冗余的特征提取结构,以此最大限度地减少模型的规模,提高特征利用效率。

2)提出了一种针对小目标缺陷的检测网络 Head。针对颈部网络部分,本文采用 Pconv、CARAFE 上采样模块和双重注意力机制进行构建和优化。PConv 同时减少了冗余计算和内存访问,可以更有效地提取空间特征。CARAFE 模块利用特征重组模块完成特征图的上采样操作,充分利用了特征图的语义信息。双重注意力机制可以自适应地集成局部特征和全局特征,不仅减小了模型规模,而且大大提升了模型对小目标缺陷的检测能力。

1 相关工作

目前在工业上进行缺陷检测最常用的方法主要有声发射^[4]技术和目标检测技术^[5]两种。声发射技术能够敏感地捕捉到动态缺陷萌生和扩展过程中的声音信息,有效检测材料结构整体质量水平,从而评价缺陷的实际危害程度^[6]。目标检测技术则是通过训练机器学习模型来识别和定位图像中的材料缺陷,从而实现自动化的质量控制。下面将从这两个方面介绍缺陷检测方法的相关工作。

1.1 声发射检测方法

声发射检测是一种可动态检测或监测在役运行状态下设备的无损检测技术。通过分析设备存在缺陷时产生的声波信号的频率、振幅和相位等特征,来判断材料或设备是否存在工业缺陷。

Xu 等^[7]基于声发射技术提出一种适用于风机叶片损伤的基于小波包分解(WPD)的聚类方法,用于损伤模式识别和单信号检测,以解释复杂的损伤模式并检测异常(即离群点)信号。研究表明,该方法在叶片健康状态监测中具有强大的鲁棒性,尤其是在面对噪声干扰时为风力涡轮叶片的实

时健康监测提供了一种有效的解决方案。Zhao 等^[8]提出了一种改进的基于声发射(AE)的结构损伤源定位方法,专门针对风力涡轮叶片。该方法首先利用半分析有限元(SAFE)方法获取风力涡轮叶片结构的色散关系,然后基于这些色散关系研究 AE 波在关键结构中的传播特性,为叶片损伤的检测和定位奠定了理论基础。Bejger 等^[9]的研究则进一步探索了 AE 信号的相干函数在风力涡轮叶片诊断中的应用。这项工作在前两者的基础上,提出了一种新的损伤诊断方法,利用相干函数来识别叶片的损伤状态,为实际应用中的叶片损伤诊断提供了新的视角和工具。

虽然基于声发射能够有效检测塔筒内部的裂纹,但面对风电塔筒表面的复杂缺陷,声发射技术只能检测到裂纹,对于更为细致的病害(例如氧化、斑状、点蚀表面等)并未涉及,且检测准确度不足。

1.2 YOLO 相关方法

近年来,随着深度学习在计算机视觉任务中的普及,基于深度学习的工业缺陷检测方法得到了飞速发展,并逐渐占据主流。而 YOLO 算法在保持检测速度的同时兼顾了检测精度,一跃成为了工业缺陷检测领域的主流模型之一。

Li 等^[10]基于单阶段检测器 YOLO 检测钢表面缺陷,融合浅层特征提升对钢带表面细小缺陷的检测能力,充分说明了 YOLO 模型在工业检测中的良好性能。Zhang 等^[11]则采用 YOLOv3 检测桥梁缺陷,并使用迁移学习、批再规范化与 Focal Loss 提升检测性能。之后 YOLOv4 算法在 YOLOv3 的基础上对模型结构进行了改进,在减少计算量的同时保持了检测性能并成为了工业检测中的主体。Liu 等^[12]通过改进 YOLOv4 算法,在 SPP 结构的基础上,使用 SoftPool 代替 MaxPool 并在 SPP 模块后增加了若干卷积层,在斑点缺陷的检测上具有较高的精度,扩大了 YOLO 模型在工业缺陷检测领域的应用范围。

随着 YOLO 算法的更新换代,越来越先进的实时检测模型成为了工业缺陷检测领域中的中流砥柱。然而,面对风电塔筒表面复杂密集的缺陷,这些 YOLO 算法的准确度仍然不能满足需求。而且巨大的模型参数量,使其难以部署到无人机或者爬壁机器人这些边缘设备上,这成为了其在工业上运用的巨大障碍。

2 C2P-YOLO 检测算法设计

2.1 概述

C2P-YOLO 算法的总体架构如图 1 所示。

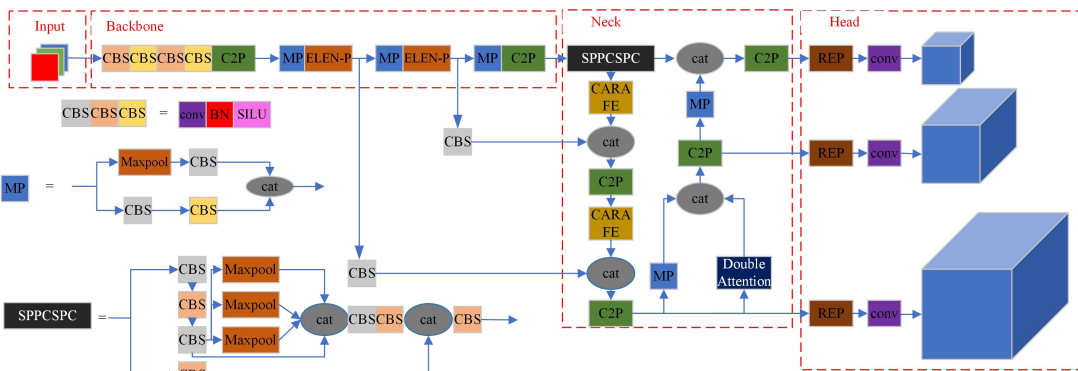


图 1 C2P-YOLO 算法总体架构图

Fig. 1 Overall architecture diagram of the C2P-YOLO algorithm

在 C2P-YOLO 算法中,首先使用轻量化特征提取模块 C2P 和多分支堆叠模块 ELAN-P 进行特征提取,再对特征图进行 CARFE 上采样和轻量化卷积 Pconv 的双操作,减少模型中的特征损失。最后,运用双重注意力机制来结合缺陷空间特征和局部特征,从而有效提升对风电塔筒表面的裂纹、裂缝等微小缺陷的检测能力。

2.2 轻量化特征提取模块

YOLOv7 中的 ELAN 模块通过聚合不同层的特征不仅有效提高了特征提取能力,而且获得了更丰富的梯度信息。然而,该模块的结构复杂,参数规模庞大,给设备造成了较大的计算负担。

针对该问题,本文根据 CSPNet 提取分流的思想,设计了一个轻量级的特征提取模块 C2P,用于代替 YOLOv7 中一部分结构冗余的 ELAN 模块,在有效降低参数数量的同时提高了模型的运行速度和特征提取能力。C2P 模块结合了 CSPNet 的特征分流思想以及 Pconv 的部分卷积策略,因此命名为 C2P(CSP-Pconv)模块。C2P 模块结构图如图 2 所示,该模块包含了 2 个标准卷积层、1 个 Bottleneck 模块以及 1 个 Pconv 结构。具体算法的流程如下:首先,将特征图输入分为两个分支,一个分支先进行卷积操作再将特征图送入 Bottleneck 模块,该模块先进行 1×1 卷积将通道数减小一半,再通过 3×3 卷积将通道数加倍并得到特征图;然后与仅经过一个基本卷积模块的分支进行 concat 通道拼接操作,最后将特征图输入 Pconv 卷积进行计算。




图 2 C2P 模块结构图

Fig. 2 Structure diagram of C2P module

Pconv 卷积利用了特征图的冗余,在降低计算量的同时更有效地提取空间特征。Pconv 卷积与普通卷积 Conv 的对比如图 3 所示,部分率的设置对模型的参数数量以及性能影响较大,为了模型在参数数量与模型性能之间达到最优平衡,本实验模型部分率设置为 $1/4$,Pconv 只在输入通道的 $1/4$ 部分上进行卷积,而保留剩余通道不变,计算量只有普通卷积的 $1/16$,大大降低了浮点操作(FLOPs)的数量。

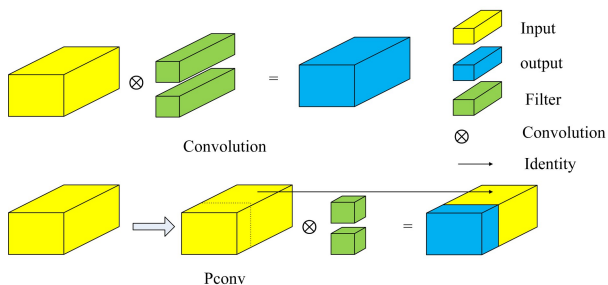


图 3 普通卷积和部分卷积对比图

Fig. 3 Comparison chart of ordinary convolution and partial convolution

2.3 小目标检测网络

风电塔筒表面缺陷的类间差异较小,采集到的图像中包含多类缺陷时易发生误检,而且伴随网络深度增加,提取特征

语义的能力虽然增强,但逐步丢失了目标局部和整体之间的关系。因此,为提高缺陷检测的准确率,本文通过融合深层和浅层特征来提高模型表征能力,从而对 Head 部分进行改进。

2.3.1 上采样模块

YOLOv7 采用最近邻插值上采样法^[13]对深层特征升维,从而完成与浅层特征的融合,但这种采样方法仅通过相邻的亚像素空间来决定上采样核,无法获取特征图中充分的语义信息,且感受野较小,不利于网络精确区分不同种类的缺陷。为解决上述问题,本文采用 CARAFE 上采样模块^[14]替换最近邻采样模块。CARAFE 可分为预测模块和特征重组模块,预测模块自适应地学习预测上采样核,特征重组模块则完成特征图的上采样操作。CARAFE 上采样模块的计算过程如下。

W, H, C 分别为特征图的宽度、长度以及通道数, α 为上采样倍率,输入特征图及输出特征图的形状如下:

$$\text{input feature map} = W \times H \times C \quad (1)$$

$$\text{output feature map} = \alpha W \times \alpha H \times C \quad (2)$$

1) 首先进行上采样核预测,若上采样核大小为 k_{up} ,则利用 1×1 卷积层将特征图通道数降维到 C_m ,然后利用 $k_e \times k_e$ 大小的卷积层来预测上采样核,最后在通道维展开得到全新的上采样核,该核维度大小为:

$$\alpha H \times \alpha W \times k_{up} \times k_{up} \quad (3)$$

2) 用 softmax 对上采样核进行归一化,对于输出特征图的每个像素点,将其映射回输入特征图,再取以其为中心、大小为 $k_{up} \times k_{up}$ 的区域和预测该点上采样核进行点积,得到上采样结果。

3) 特征重组,本文采用一种全新的形式进行特征重组,价权和算子的计算式如下:

$$X'l' = \sum_{n=-r}^r \sum_{m=-r}^r Wl'(n, m) X(i+n, j+m) \quad (4)$$

其中, X 代表特征图, l 代表特征图中对应点的位置, Wl 代表可学习的重组内核。

CARAFE 上采样模块建立了采样核与输入图像之间的对应关系,重新组合后的特征图语义信息更强,且相较于最近邻插值具有更大的感受野,可有效改善网络特征融合能力并提升模型对各类缺陷的表征能力。

2.3.2 双重注意力机制

一般的 YOLO 模型难以识别风电塔筒表面复杂且细微的工业缺陷,因此本文在 Head 网络部分中引入双重注意力机制^[15]来自适应地集成局部特征和全局依赖,以通过模型的特征提取能力。

双重注意力机制的核心思想是将整个空间的关键特征收集到一个紧凑的集合中,然后自适应地分布到每个位置,这样后续的卷积层即使没有很大的接收域也可以感知整个空间的特征。具体算法的步骤如下,首先进行特征聚合 (Feature Gathering),使用二阶注意力池化来聚合整个输入空间的特征,计算式如下:

$$G_{\text{bilinear}}(A, B) = AB^T = \sum_i \mathbf{a}_i \mathbf{b}_i^T \quad (5)$$

其中, \mathbf{a}_i 和 \mathbf{b}_i 分别是来自特征图 A 和 B 中的特征向量, G_{bilinear} 是二阶注意力池化的输出,也是一个包含视觉原语的集合。

下一步进行特征分布 (Feature Distribution),将聚合得到

的特征分布到输入的每个位置,以便后续卷积层能够感知全局信息,计算式如下:

$$z_i = \sum_j v_{ij} g_j = G_{\text{gather}}(X) v_i \quad (6)$$

其中, z_i 是位置 i 的新局部特征, v_i 是该位置的局部特征向量, g_j 是从第一步聚合得到的特征向量,而函数 G 表示特征聚合过程中的双线性池化操作。

将上述两步结合起来,形成双重注意力机制的计算图。具体的计算式为:

$$\mathbf{Z} = F_{\text{distr}}(G_{\text{gather}}(X), \mathbf{V}) = G_{\text{gather}}(X) \odot \text{softmax}(\rho(X; \mathbf{W}_\rho)) \quad (7)$$

其中, \mathbf{Z} 是输出张量, \mathbf{V} 是通过 softmax 函数归一化后的关注权重向量, \odot 表示逐元素乘法。

这种方法通过结合两种不同的注意力机制——空间注意力(Spatial Attention)和通道注意力(Channel Attention),大大增强了模型对图像特征的学习和理解能力。

3 实验结果和分析

本章首先描述数据集以及实验的环境设置,并在钢材数据集中进行了大量对比实验以及消融实验,以验证其在风电塔筒检测中的有效性,最后为了验证其鲁棒性,又在 VOC 数据集上与其他优秀模型进行对比。

3.1 实验设置

3.1.1 数据集

本实验采用东北大学收集的 NEU-DET 钢材缺陷数据集^[16]来验证 C2P-YOLO 模型在风电塔筒表面缺陷检测的有效性。NEU-DET 数据集中包含 1800 幅灰度图像,其中训练集 1440 幅,测试集和验证集各 180 幅,分辨率均为 200×200 像素。按常见钢材表面缺陷将其分为 6 类:(a) 裂缝(Cracking)、(b) 夹杂物(Inclusion)、(c) 斑块(Patches)、(d) 点蚀表面(Pitted-Surface)、(e) 氧化皮(Rolled-in-Scale)和 (f) 划痕(Scratches)。各类缺陷实图如图 4 所示。




图 4 钢材缺陷数据集示意图

Fig. 4 Schematic diagram of steel defect dataset

3.1.2 评价指标

实验使用 5 种评价指标,即 Precision, Recall, Params, mAP 和 F1-score 分别介绍如下。

Precision 又称为精准率,反映模型检测精准程度,计算式为:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (8)$$

其中, TP 表示待检目标被正确检测到的数量, FP 表示非待检目标被错误判定为待检目标的数量。

Recall 又称召回率,反映模型的漏检率,计算式为:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (9)$$

其中, TP 表示待检目标被正确检测到的数量, FN 表示待检目标被视为错误检测的数量。

mAP 反映所有类别的识别平均准确率的均值,计算式为:

$$mAP = \frac{\sum_{i=1}^k AP_i}{k} \quad (10)$$

其中, k 为图像总类别数, i 为检测次数, AP 为单一类别的识别平均准确率, $AP@0.5$ 表示该类别 P-R 曲线下方的面积。mAP@0.5 由所有类别的识别平均准确率 $AP@0.5$ 相加取平均值得到。

F1-score 表示准确率和召回率的调和平均数,计算式为:

$$F1\text{-score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (11)$$

3.1.3 实验环境设置

本次实验在 Windows 环境下的云平台进行部署,具体实验参数值如表 1 所列。

表 1 实验参数设置

参数名称	参数值
GPU 型号	NVIDIA Ge Force RTX 2060
编译语言	Python 3.10
深度学习框架	Pytorch 13.1+cuda12.0
Epoch	200
Batch size	16
图像大小	640×640
优化器	SGD
初始学习率	0.01
学习率动量	0.937
衰减系数	0.0005
置信度阈值	0.001
IOU 阈值	0.5

3.2 对比实验

为了更全面地评估 C2P-YOLO 的检测性能,本文使用 NEU-DET 数据集将 C2P-YOLO 与经典检测模型 Faster RCNN+FPN、YOLO 系列检测模型进行对比,结果如表 2 所列。

表 2 NUE-DET 数据集实验对比结果

Table 2 Experimental comparison results of the NUE-DET dataset

模型	P/%	R/%	mAP@0.5/%	Parameter
Faster RCNN+FPN	70.4	68.1	71.3	9.77×10^7
SSD	65.2	60.3	65.3	6.32×10^7
YOLOX	69.1	71.5	73.5	1.93×10^8
YOLOv5X	75.4	73.7	77.6	1.64×10^8
YOLOv7	75.9	69.3	75.7	7.83×10^7
YOLOv8l	70.3	70.4	72.5	8.35×10^7
C2P-YOLO(本文)	88.0	75.1	84.9	5.84×10^7

由表 2 可知,本文模型的缺陷检测精准率、召回率相较于其他检测模型有极大的提升。精准率相较于 YOLOX,

YOLOv5X, YOLOv7 以及 YOLOv8l 模型分别提升了 18.9%, 12.6%, 12.1%, 17.7%。综上所述, C2P-YOLO 对各类缺陷识别效果最佳, 在精准率、召回率以及 mAP 分数上均优于其他代表性模型。不仅如此, 本文模型的参数量相较于原模型减少了 25%, 充分满足端侧设备的要求, 在主流的检测模型中有着强大的竞争力。

3.3 消融实验

为验证每种改进点对网络模型的增益, 本文设置 4 组消融实验组。改进前的 YOLOv7 实验结果作为后组的基准进行对比, 第一组为改进上采样方式后的模型检测结果, 第二组为采用 C2P 模块后的模型检测结果, 第三组为引入双重注意力机制后的模型检测结果, 第四组为 C2P-YOLO 模型的检测结果。实验结果如表 3 所列。

表 3 消融实验结果
Table 3 Ablation experiment results

实验	CARAFE	C2P	DoubleAttention	mAP@0.5/%
YOLOv7	×	×	×	75.7
实验组一	√	×	×	78.9
实验组二	×	√	×	79.3
实验组三	×	×	√	81.4
实验组四(本文)	√	√	√	84.9

对比 YOLOv7 和实验组一可以看出, CARAFE 上采样改进方法可以有效改善网络特征融合能力, 提升模型对各类缺陷的表征能力, 并且有效减少了模型参数量以及计算复杂度。对比 YOLOv7 和实验组二可以看出, C2P 模块不仅大大降低了模型的参数量和计算复杂度, 而且提高了模型对小目标缺陷的检测性能。对比 YOLOv7 和实验组三可以看出, 增加双重注意力机制虽然增加了模型的复杂度, 但模型的性能相较于原始模型 mAP@0.5 提升了 3.9%, 检测准确率大大提升。

3.4 迁移实验

为了验证 C2P-YOLO 模型在实际工业场景中缺陷检测的有效性以及通用性, 进一步采用 GC10-DET 真实工业表面缺陷数据集^[17]来进行实验。

GC10-DET 数据集共有 2 270 张灰度图像, 包含了 10 种类型的表面缺陷, 即冲孔(Pu)、焊缝(WI)、新月形缝隙(Cg)、水斑(Water Spot)、油斑(Os)、丝斑(Ss)、夹杂物(In)、轧坑(Rp)、折痕(Cr)、腰部折痕(Wf)。该数据集中的图像采集于光照充足、低干扰的结构化场景, 更符合实际工况下的检测环境。

本文在各种参数相同的情况下将 C2P-YOLO、YOLOv7 以及最先进的 YOLOv8 进行对比, 对比结果如表 4 所列。

表 4 GC-10 数据集上的实验对比结果

Table 4 Experimental comparison results on the GC-10 dataset

模型	mAP@0.5/%	Parameter
Faster R-CNN	32.6	1.368×10^8
YOLOv5	57.3	7.03×10^7
YOLOv7	62.8	7.48×10^7
YOLOv8	64.4	8.07×10^7
C2P-YOLO(本文)	64.2	5.26×10^7

从对比表中可以看出, C2P-YOLO 模型在实际工业缺陷

数据集的检测中相较于原模型 YOLOv7, 不仅在性能上提升了 1.4%, 而且减少了 29.7% 的模型规模。与 YOLOv8 相比, 其参数量仅有 YOLOv8 的 65%, 检测性能仅低了 0.2%, 充分证明了 C2P-YOLO 模型在工业缺陷检测中的实用性。

结束语 传统的缺陷检测算法面对风电塔筒表面缺陷时, 检测精度不高, 检测成本高昂。为此, 本文提出了一个全新的轻量级缺陷检测算法 C2P-YOLO。首先, 本文针对 YOLOv7 算法中复杂的 ELAN 模块, 提出了全新的轻量化特征提取模块 C2P 进行代替, 不仅提高了算法的特征提取能力, 而且减小了 25% 的模型规模。其次, 采用上采样算子 CARAFE 替换最近邻上采样算法, 减少特征图上采样过程中的信息损失; 最后, 运用双重注意力机制提高了模型对风电塔筒表面微小缺陷的检测能力。在实验部分, 通过多组实验验证了 C2P-YOLO 算法在风电塔筒检测方面的准确性以及先进性。C2P-YOLO 的参数量及计算复杂度较低, 能够有效部署在边缘设备如无人机以及爬壁机器人上, 满足工业上对风电塔筒检测的要求。但针对每种缺陷的严重程度, 本文算法不能做出有效的检测, 难以帮助风电塔筒维护人员对风电设备的整体状态进行评估, 后续对算法的改进以及数据的处理将会是研究的重点。

参考文献

- [1] SHAN L. Selection of the wind turbine tower structure and mechanical properties research[D]. Harbin: Harbin Institute of Technology, 2009:12-15.
- [2] HAN Q, ZHANG Z, XU X Y, et al. Steel surface defect detection algorithm based on FF R-CNN[J]. Journal of Taiyuan University of Technology, 2021, 52(5): 754-763.
- [3] SI S L. Light weight YOLOv4 steel surface defect detection method[D]. Fuxin: Liaoning University of Engineering and Technology, 2022.
- [4] DING S, YANG C, ZHANG S. Acoustic-Signal-Based Damage Detection of Wind Turbine Blades - A Review[J]. Sensors, 2023, 23(11): 4987.
- [5] ZHANG Y, YANG Y, SUN J, et al. Surface Defect Detection of Wind Turbine Based on Lightweight YOLOv5s Model[J]. Measurement, 2023: 113222.
- [6] GENG R S, SHEN G T, LIU S F. Acoustic emission signal processing and analysis technology[J]. Nondestructive Testing, 2002, 24(1): 23-28.
- [7] XU D, LIU P F, CHEN Z P. Damage mode identification and singular signal detection of composite wind turbine blade using acoustic emission[J]. Composite Structures, 2021, 255: 112954.
- [8] ZHAO Z, CHEN N Z. Acoustic emission based damage source localization for structural digital twin of wind turbine blades[J]. Ocean Engineering, 2022.
- [9] BEJGER A, DRZEWIENIECKI J B, BARTOSZKO P, et al. The Use of Coherence Functions of Acoustic Emission Signals as a Method for Diagnosing Wind Turbine Blades[J]. Energies, 2023, 16(22): 7474.
- [10] LI J, SU Z, GENG J, et al. Real-time detection of steel strip surface defects based on improved YOLO detection network[J]. IF-

AC-Papers On Line, 2018, 51: 76-81.


- [11] ZHANG C, CHANG C, JAMSHIDI M. Concrete bridge surface damage detection using a single-stage detector[J]. *Comput-Aided Civil Infrastruct Eng*, 2020, 35: 389-409.
- [12] LIU Q, WANG C, LI Y, et al. A Fabric Defect Detection Method Based on Deep Learning [J]. *IEEE Access*, 2022, 10: 4284-96.
- [13] OLIVIER R, HANQIANG C. Nearest Neighbor Value Interpolation[J]. *International Journal of Advanced Computer Science & Application*, 2012, 3(4): 25-30.
- [14] WANG J, CHEN K, XU R, et al. Carafe: Content-aware reassembly of features[C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2019: 3007-3016.
- [15] LIN H, JING C, HUANG Y, et al. A2 Net: Adjacent Aggregation Networks for Image Raindrop Removal[J]. *IEEE Access*, 2020, PP(99): 1.
- [16] SONG K, YAN Y. A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects

[J]. *Applied Surface Science*, 2013, 285: 858-864.

- [17] LV X, DUAN F, JIANG J, et al. Deep metallic surface defect detection: The new benchmark and detection network[J]. *Sensors*, 2020, 20(6): 1562.



DUAN Pengsong, born in 1983, Ph. D., associate professor. His main research interests include edge computing and intelligent perception.



CAO Yangjie, born in 1976, professor. His main research interests include machine learning, computer vision and high-performance computing.