

文章编号 1004-924X(2025)09-1496-19

## 改进 YOLOv8 的风机叶片多尺度缺陷检测

朱 广<sup>1,2\*</sup>, 顾 晨<sup>1</sup>, 徐立云<sup>2</sup>, 史艳琼<sup>1</sup>, 丁郑阳<sup>1</sup>, 张 旭<sup>1</sup>, 张永华<sup>1</sup>

(1. 安徽建筑大学 机械与电气工程学院, 安徽 合肥 230601;

2. 同济大学 机械与能源工程学院, 上海 201804)

**摘要:** 针对风机叶片在缺陷检测过程中精度较低, 存在漏检误检的问题, 提出了一种基于 YOLOv8 的改进算法。首先, 提出了一种基于高效多尺度注意力的双卷积核结构代替瓶颈结构形成 DE-C2f 模块, 提升网络对多尺度特征的提取能力。其次, 设计全局感受野特征融合模块 (GRE-SPPF), 帮助网络捕获全局特征信息, 扩大网络感受野。最后, 在 Neck 中增设小目标检测层和多尺度特征融合结构, 提高对小目标和复杂目标的检测性能, 同时, 在检测头前引入注意力和卷积融合模块 (ACFM), 使网络专注于关键信息, 并有效抑制背景干扰。在风机叶片缺陷数据集上的实验结果表明, 改进算法的 mAP@0.5 和 mAP@0.5:0.95 分别达到了 91.1% 和 61.8%, 相比于基准算法分别提升了 6.2% 和 6.4%, 召回率达到 84.9%, 增长 7.7%, 且参数量没有明显增加, 能有效应用于风机叶片的缺陷检测中。

**关键词:** 风机叶片; 缺陷检测; YOLOv8; 多尺度特征; 小目标; 注意力机制

**中图分类号:** TP391.41; TP183 **文献标识码:** A

**doi:** 10.37188/OPE.20253309.1496 **CSTR:** 32169.14.OPE.20253309.1496

## Improvement of YOLOv8 for multi-scale defect detection in wind turbine blades

ZHU Guang<sup>1,2\*</sup>, GU Chen<sup>1</sup>, XU Liyun<sup>2</sup>, SHI Yanqiong<sup>1</sup>, DING Zhengyang<sup>1</sup>,  
ZHANG Xu<sup>1</sup>, ZHANG Yonghua<sup>1</sup>

(1. School of Mechanical and Electrical Engineering, Anhui Jianzhu University, Hefei 230601, China;

2. School of Mechanical Engineering, Tongji University, Shanghai 201804, China)

\* Corresponding author, E-mail: guangzhu123@ahjzu.edu.cn

**Abstract:** To address the challenges of low accuracy, missed detection, and false detection in defect identification of wind turbine blade, an enhanced algorithm based on YOLOv8 is proposed. Initially, a DE-C2f module is introduced, replacing the bottleneck structure with a dual convolution kernel design based on efficient multi-scale attention, thereby improving the network's multi-scale feature extraction capability. Subsequently, a global receptive field feature fusion module (GRE-SPPF) is implemented to enhance the capture of global feature information and expand the receptive field. Further improvements include the addition of a small-object detection layer and a multi-scale feature fusion structure in the Neck, optimizing detection performance for small and complex objects. An attention and convolution fusion module

收稿日期: 2024-12-16; 修订日期: 2025-01-24.

基金项目: 安徽省科技重大专项 (No. 202203a05020022); 企业委托项目 (No. HYB20230260); 大学生创新创业项目 (No. 202310878064)

(ACFM) is also integrated before the detection head to prioritize critical information while mitigating background interference. Experimental results on a wind turbine blade defect dataset indicate that the proposed algorithm achieves mAP@0.5 and mAP@0.5:0.95 values of 91.1% and 61.8%, respectively, marking improvements of 6.2% and 6.4% over the baseline algorithm. The recall rate reaches 84.9%, a 7.7% enhancement, with no substantial increase in computational parameters, demonstrating the algorithm's efficacy for practical wind turbine blade defect detection.

**Key words:** wind turbine blade; defect detection; YOLOv8; multi-scale features; small object; attention mechanism

## 1 引言

风力发电技术作为一种清洁且可再生的能源越来越受到关注。在运行过程中,风机叶片的性能和状态直接影响整个发电系统的效率和安全性,由于长时间暴露于自然环境中,容易受到风速、温度变化、雷击、冰雹攻击等自然因素的影响,出现裂纹、剥离、侵蚀等多种缺陷。若不及时发现和修复,叶片会损坏,严重时甚至会引发风机整体故障,造成停机损失和安全事故。因此,对风机叶片进行定期的缺陷检测极为重要。

传统风机叶片的缺陷检测方法主要通过人工检测,该方法效率低且不安全。研究人员基于超声波、振动和传感器等技术提出了多种检测方法。Arcos Jiménez等<sup>[1]</sup>基于超声波无损测试监测系统,通过小波变换进行信号滤波来检测叶片上的泥浆污染。Doliński等<sup>[2]</sup>基于风机叶片振动参数的一维连续小波变换来确定叶片损伤的分层位置和无损诊断。Liu等<sup>[3]</sup>利用FBG传感器在不同负载条件下的应变传递效率建立了一个计算模型,并通过应变变化监测风机叶片的损伤。然而,以上方法需与叶片表面直接接触,存在安装困难、经济成本高和数据采集难度大等问题,且声波技术存在环境要求高和缺陷难以定位的问题。

针对这些问题,机器视觉技术脱颖而出。Wu等<sup>[4]</sup>基于三维数字图像的光学技术检测叶片运行过程中的相对变形和故障。Sahir Moreno等<sup>[5]</sup>基于深度学习的方法检测叶片表面的磨损和断裂。相比之下,深度学习方法在面对复杂

缺陷和多变环境时,准确率和查全率更具优势。目前,基于深度学习的目标检测方法分为单阶段和双阶段检测算法。双阶段算法首先会生成多个候选区域,随后对这些候选区域进行分类和边界框回归。它拥有较高的精度和较强的泛化能力,但检测速度较慢,如Faster RCNN<sup>[6]</sup>和Mask R-CNN算法<sup>[7]</sup>,因此并不适合风机叶片的实时检测。而单阶段检测算法如YOLO<sup>[8]</sup>,SSD<sup>[9]</sup>等在检测速度上有显著优势。它们直接在图像上预测不同类别的目标及其位置,无需区域提议步骤。Lv等<sup>[10]</sup>基于改进SSD框架和ResNet网络开发了EADD损伤检测器,提升了风机叶片损伤检测性能,但提升精度较低。Zhu等<sup>[11]</sup>基于YOLOv5提出了MI-YOLO模型,通过多元信息融合,引入C3TR模块和更改损失函数,有效检测风电机组叶片的表面裂纹,但该方法对小目标的检测能力较弱,会出现漏检误检的问题。Zheng等<sup>[12]</sup>通过改进损失函数、目标分类函数和激活函数,在YOLOv5的基础上提出D-YOLO-v5模型,对叶片裂纹进行识别,但研究对象单一,不具备良好的泛化性和稳定性。Tong等<sup>[13]</sup>提出了一种WTBD-YOLOv8的风机缺陷检测方法,该方法有效减少了模型参数数量,提高了检测性能和效率,但模型整体精度的提升有限。由此可见,以上方法都在一定程度上提升了风机叶片的检测性能,但在面对背景干扰和复杂、微小缺陷时仍会存在精度较低和漏检误检的情况,如微裂纹和小划痕,这些尺寸小于10 mm且占图像表面积小于0.5%的缺陷往往边缘模糊且容易被背景噪声覆盖,在图像中的可见性较差。针对风机叶片缺陷检测过程

中精度不高和召回率低的问题,本文基于YOLOv8算法做出相关改进。针对因复杂背景干扰导致的特征提取困难问题,提出了一种基于高效多尺度注意力的双卷积核结构改进设计DE-C2f模块,加强网络的计算效率和对不同尺度特征的提取能力。由于最大池化引起的局部信息丢失,导致检测不全的问题,设计了GRE-SPPF(Global Receptive Field and ECA-SPPF)模块,在提取细节特征的同时,捕获全局特征信息,扩大网络感受野,减少漏检误检情况。为解决小目标和复杂目标难以识别问题,在网络中增设小目标检测层和多尺度特征融合结构,提升网络对语义特征和几何特征的捕获能力。为克服卷积核在处理远距离信息交互时能力较弱的问题,在输出端检测头前引入注意力与卷积融合模块(Attention and Convolution Fusion Module,ACFM),更好地捕获全局上下文信息,提升网络处理局部细节的能力。

## 2 YOLOv8 算法

YOLOv8是当前领先的目标检测模型之一,具有卓越的检测速度和精度,在部分数据集集中效果优于YOLOv10和YOLOv11等模型,且拥有更大的改进空间。YOLOv8算法由主干网络、颈部网络和检测头组成,分别用于提取特征、融合特征和检测目标,其网络结构如图1所示。

主干网络使用CBS,C2f和SPPF模块来提取特征。CBS模块负责初步的特征提取;C2f模块通过增加跳连和Split操作,提供了丰富的梯度流信息;SPPF模块通过空间金字塔池化结构增强特征的多尺度融合能力。颈部网络结合FPN和PAN网络,实现了多尺度特征的高效融合。检测头通过解耦头结构,使用VFL(Varifocal Loss)作为分类损失函数和(Complete Intersection Over Union,CIOU)结合分布聚焦损失(Distribution Focal Loss,DFL)作为回归损失函数,优化了监测和处理分类任务的能力,提高了模型对不同尺寸特征图上目标的识别和定位能力。

YOLOv8采用无锚框技术,通过中心点和宽高直接预测物体,减少了模型的计算负担,提高了运算速度。引入动态TaskAlignedAssigner正样本分配策略,帮助模型有效地学习各种复杂场景,提升检测精度和稳定性。

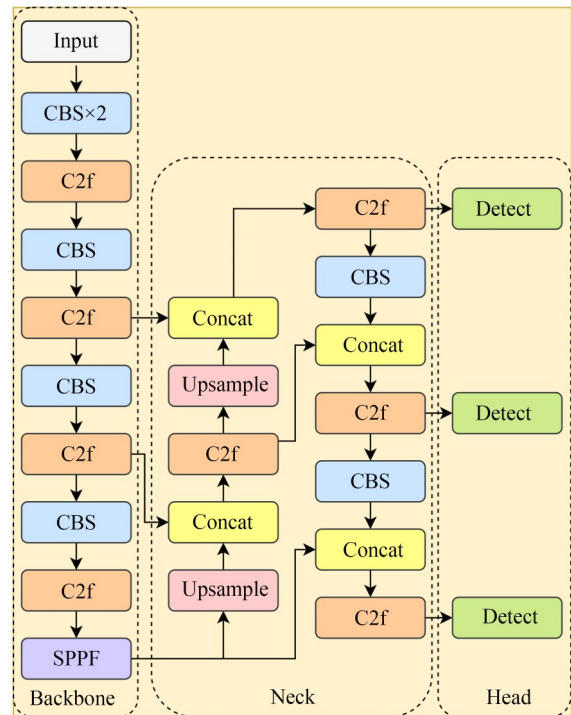


图1 YOLOv8网络结构

Fig. 1 Architecture of YOLOv8 network

## 3 改进 YOLOv8 算法

针对YOLOv8算法在风机叶片缺陷检测上精度不高,存在漏检误检的问题,本文改进了YOLOv8算法。首先,为提高复杂背景下的特征提取能力,结合双卷积核Dualconv<sup>[14]</sup>和EMA注意力机制<sup>[15]</sup>改进C2f模块,以增强网络对多尺度特征的提取,并提升了整体计算效率。其次,考虑到特征提取时的局部信息丢失,设计GRE-SPPF模块,增强网络提取全局特征信息的能力,以减少漏检误检概率。最后,增设小目标检测层和多尺度特征融合层,并在检测头前引入ACFM,提升网络对复杂、微小目标的检测性能。改进的YOLOv8网络结构如图2所示,图中浅灰色背景部分为改进模块和改进点。

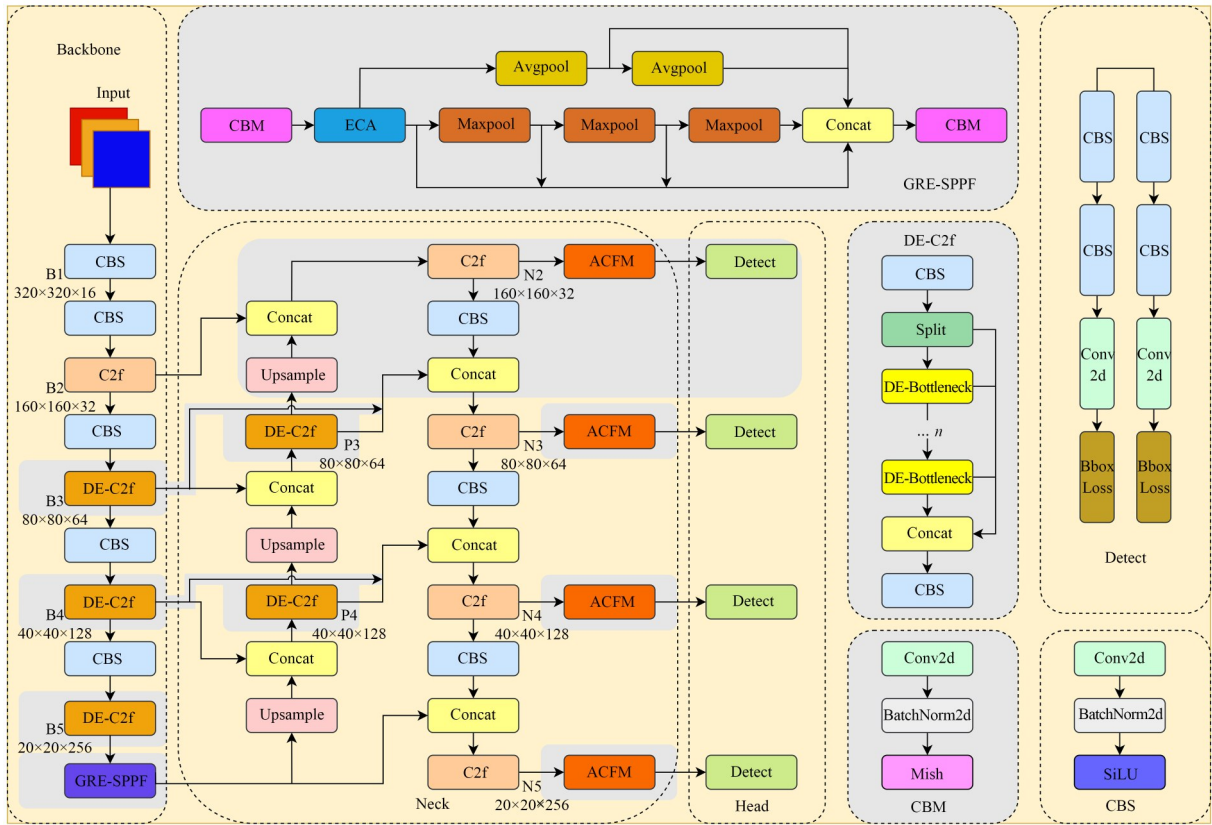


图 2 改进的 YOLOv8 网络结构

Fig. 2 Architecture of improved YOLOv8 network

### 3.1 改进 C2f 模块

传统卷积层通常使用固定尺寸的卷积核,难以同时有效捕捉小尺度的细节和大尺度的上下文信息,这限制了其捕捉不同尺度特征的能力。而且风机叶片缺陷具有一定的复杂性,传统卷积层在处理大尺度输入或进行深层特征提取时,会产生较多的参数和计算资源,导致模型效率低下。因此,本文设计了 DE-C2f 模块以解决以上问题。

#### 3.1.1 DualConv

DualConv 的结构布局<sup>[14]</sup>如图 3 所示。它通过结合  $3 \times 3$  和  $1 \times 1$  卷积核同时处理相同的输入特征映射通道,优化了信息处理和特征提取过程。其中,  $3 \times 3$  卷积核用于提取特征,  $1 \times 1$  卷积核用于整合特征。此外, DualConv 利用组卷积技术高效地排列卷积滤波器,降低了计算成本和参数数量。在组卷积技术中,将输入和输出特征图分成多个组,每组的卷积滤波器仅处理对应的输入特征图的一部分,有效减少了模型的复杂度。如图 3 所示, Dualconv 将  $N$  个卷积滤波器分

成  $G$  组, 每组处理完整的输入特征图, 其中  $M/G$  输入特征图通道由  $3 \times 3$  和  $1 \times 1$  卷积核同时处理, 其余  $(M - M/G)$  输入通道由  $1 \times 1$  卷积核单独处理。这种设计不仅减少了网络模型参数, 还通过保留输入特征映射的原始信息, 加强了卷积层间的信息共享, 使得  $3 \times 3$  卷积核在进行特征提取时可以捕获更多的空间信息,  $1 \times 1$  卷积核在整合特征信息时, 模型参数和计算成本也会有效降低。因此, DualConv 相比于传统卷积有更强的特征提取能力, 更少的参数数量和计算成本。其计算公式如下:

$$Y_i = \left[ (W_{1 \times 1} + W_{3 \times 3}) X_{\frac{M}{G}, i} + W_{1 \times 1} X_{M - \frac{M}{G}, i} \right] \times \frac{N}{G}, i = 1, 2, \dots, G, \quad (1)$$

$$Y = [Y_1, Y_2, \dots, Y_G], \quad (2)$$

其中:  $Y_i$  为第  $i$  组输出特征,  $W_{1 \times 1}$  和  $W_{3 \times 3}$  分别表示  $1 \times 1$  和  $3 \times 3$  卷积,  $M$  和  $N$  分别为输入通道数量和卷积滤波器数量,  $X_{\frac{M}{G}, i}$  表示第  $i$  组中  $M/G$  输

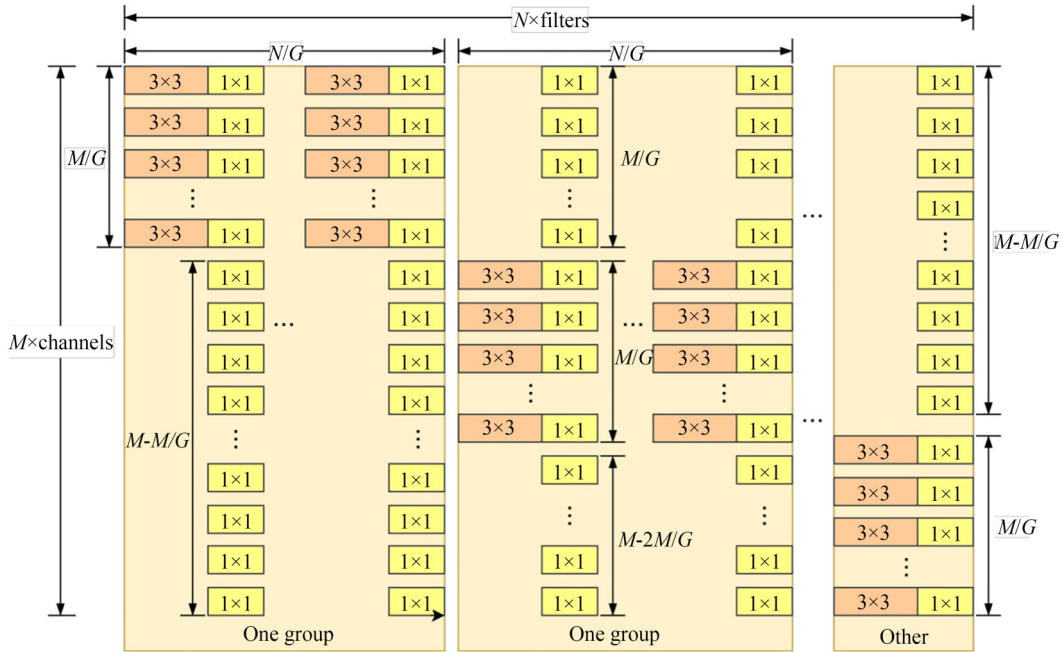


图 3 DualConv 的结构布局 ( $M$  为输入通道数量,  $N$  为卷积滤波器数量, 同时也为输出通道数量)

Fig. 3 Structure layout of DualConv ( $M$  is the number of input channels,  $N$  is the number of convolution filters, which also represents the number of output channels)

入通道特征,  $X_{M-\frac{M}{G} \cdot i}$  表示剩余 ( $M-\frac{M}{G}$ ) 输入通道特征,  $G$  为分组组数,  $Y$  为输出特征。

### 3.1.2 高效多尺度注意力机制

由于风机叶片缺陷存在大小不一, 形态各异的问题, 模型难以同时识别大面积损伤和微小裂缝, 导致模型的检测精度降低。因此, 本文引入高效多尺度注意力机制 (Efficient Multi-scale Attention, EMA), 加强模型处理上下文信息和多尺度特征提取能力, 提升模型的检测性能。EMA 结构如图 4 所示, 它采用并行子结构通过 3 个平行分支 (两个  $1 \times 1$  卷积和一个  $3 \times 3$  卷积) 提取多尺度特征,  $1 \times 1$  分支通过全局平均池化在垂直和水平方向上编码通道信息, 捕获全局特征,  $3 \times 3$  分支负责局部细节特征的提取。之后, EMA 使用跨空间信息聚合方法, 通过 2D 全局平均池化对  $1 \times 1$  和  $3 \times 3$  分支的输出进行全局空间信息编码, 以获取全局空间信息。接着, 利用 SoftMax 拟合线性变换提升网络计算效率, 并使用矩阵点积运算 Matmul 实现两分支上的信息交互, 增强不同尺度特征之间的联系, 提升网络对全局上下文信息的理解。最后, 将输出特征与原始特征进行重新加权操作, 加强网络对关键特征的关注。

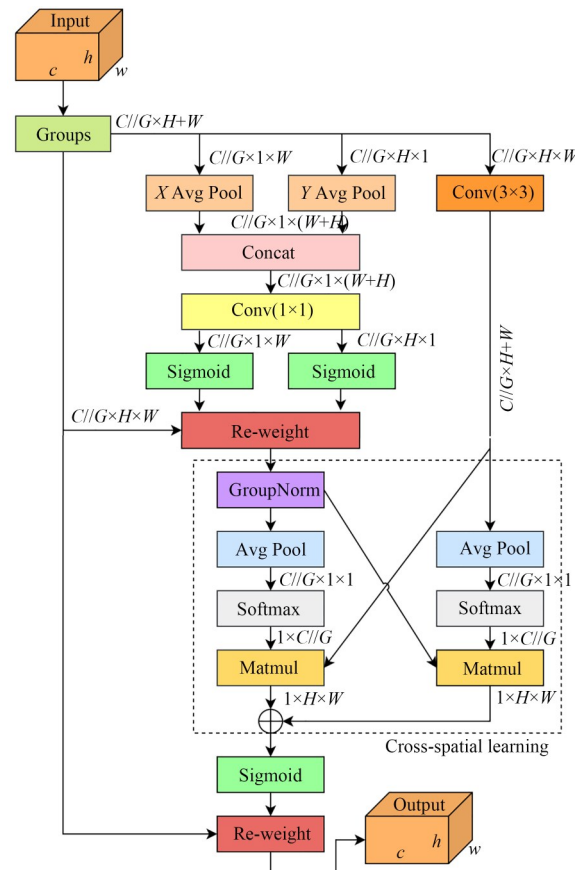


图 4 EMA 注意力机制结构

Fig. 4 Structure of EMA attention mechanism

### 3.1.3 DE-C2f 模块

DE-C2f 模块结构如图 5 所示。首先,采用 DualConv 代替 Bottleneck 结构中的标准卷积,通过  $3 \times 3$  和  $1 \times 1$  卷积核之间的信息交互,从不同角度学习输入数据,使网络能在同一层中提取到不同尺度的特征,捕获到更细粒度的信息和更广泛的上下文信息,克服标准卷积对多尺度特征提取的困难。再利用组卷积技术,减少卷积操作中的乘加运算,降低模型的计算复杂度,提升整体运行效率。例如分成 4 组,此时模型可保持适当的参数量和更高的精度,拥有更好的泛化性能。在卷积之后引入 EMA 机制得到 DE-Bottleneck 结构,通过并行子结构和跨空间信息聚合,融合不同尺度的上下文信息,对重要特征图产生更好的像素级关注,从而进一步提升网络对多尺度特征的提取和关注度。最后,将改进的 DE-Bottleneck 结构替换 C2f 模块中原有的 Bottleneck 得到 DE-C2f 模块,有效应对在复杂背景下传统卷积难以提取多尺度特征问题,提升网络的检测性能。

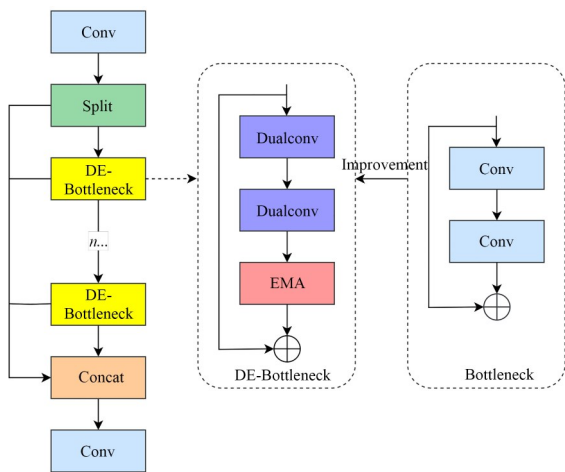


图 5 DE-C2f 模块结构

Fig. 5 Structure of DE-C2f module

### 3.2 改进 SPPF 模块

风机叶片操作环境复杂,且在一张图像中通常存在多种缺陷特征。YOLOv8 网络中的 SPPF 模块将输入特征图进行 3 次最大池化操作并按金字塔划分,使得多尺度特征整合到一个固定长度的特征向量中,有效地提取输入特征信息。但由于只采用最大池化操作,该网络会丢失部分局部

特征信息,出现漏检情况。针对该问题,本文设计了 GRE-SPPF 模块。

#### 3.2.1 高效通道注意力机制

高效通道注意力机制 (Efficient Channel Attention, ECA)<sup>[16]</sup> 能够通过较小的计算成本调制通道维度上的有效注意力,其网络结构如图 6 所示。首先,对输入特征图进行全局平均池化操作,将特征从  $c \times h \times w$  压缩为  $c \times 1 \times 1$  的特征向量,有效地聚合空间信息,并提取图像的全局特征,为后续的通道注意力学习提供全局信息。之后,使用卷积核为  $k$  的自适应一维卷积学习通道注意力信息,捕获通道之间的局部交叉依赖性,使模型能够自适应地调整不同通道的权重,突出重要的通道特征,并增强对重要特征的全局信息的捕捉。再通过 sigmoid 激活函数将一维卷积的输出转换为权重系数。最后,将这些权重乘以原始的通道特征图进行通道加权,对重要特征赋予更高的权重,而背景噪声和冗余信息所在通道会被赋予较低的权重,以减少噪声引起的负面影响。ECA 模块会根据通道数自适应地计算一维卷积的核大小  $k$ , 公式如下:

$$k = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}}, \quad (3)$$

其中:  $C$  是输入特征的通道数,  $\gamma$  和  $b$  为超参数,  $\gamma$  设为 2,  $b$  设为 1,  $\lfloor t \rfloor_{\text{odd}}$  表示  $t$  最接近的奇数。




图 6 ECA 网络结构

Fig. 6 Architecture of ECA network

#### 3.2.2 GRE-SPPF 模块

SPPF 模块和 GRE-SPPF 模块改进前后的结构对比如图 7 所示。首先,由于 Mish 函数具备良好的平滑性和非单调性,能够适应复杂的数据特征,且梯度传递性能高效,帮助模型提升收敛速度和稳定性<sup>[17]</sup>。因此,将 CBS 模块中的激活函

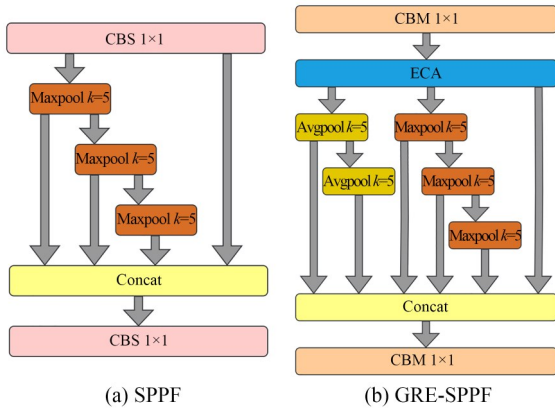


图 7 SPPF 模块和 GRE-SPPF 模块的结构对比

Fig. 7 Structure comparison between SPPF and GRE-SPPF modules

数 SiLU 替换成 Mish 形成 CBM, 使卷积在提取特征时更好地学习复杂的细节特征, 并表现出更好的稳定性和效率。之后, 在 CBM 模块后引入 ECA 机制, 通过全局平均池化捕获全局特征信息, 并利用自适应一维卷积对输入的通道特征进行有效注意力调制, 强化对重要特征的关注, 并抑制背景噪声与冗余信息的干扰。最后, 在提取多尺度特征的过程中, 增加两次池化核为 5 的平均池化操作, 以获取更多局部区域中的背景整体特征和被遮挡的复杂缺陷特征, 使网络捕获并整合全局特征信息, 来应对因最大池化而产生特征提取不足的问题。GRE-SPPF 模块具体的计算公式如下:

$$x = \text{CBM}(x_{\text{input}}), \quad (4)$$

$$x = \text{ECA}(x), \quad (5)$$

$$Y_1 = \text{Max}(x), \quad (6)$$

$$Y_2 = \text{Avg}(x), \quad (7)$$

$$Y_3 = \text{Concat}(Y_1, \text{Max}(Y_1), \text{Max}(\text{Max}(Y_1))), \quad (8)$$

$$Y_2, \text{Avg}(Y_2), x), \quad (8)$$

$$Y_{\text{out}} = \text{CBM}(Y_3), \quad (9)$$

其中:  $x_{\text{input}}$  为输入特征, Max 为最大池化操作, Avg 为平均池化操作, Concat 为特征拼接操作,  $Y_{\text{out}}$  为最终输出特征。通过将原始特征, 最大池化特征和平均池化特征拼接结合, 网络能够获得更全面的特征信息, 将特征图中的重要信息和基于全局感受野的背景信息有效融合, 实现了更好的特征提取效果。相比于 SPPF 模块, GRE-SPPF 在不失细节特征的同时, 增强了对全局特征

信息的捕捉, 通过全局与局部细节特征的高效结合, 使网络更深入地理解图像中的复杂结构, 缓解了风机叶片因背景复杂, 缺陷多样产生的漏检误检问题。

### 3.3 改进 Neck 结构

在风机叶片中存在微小裂纹和细微划痕, 这些缺陷尺寸普遍较小。因此, 本文在 Neck 中增加了小目标检测层, 用于检测微小目标。新增多尺度特征融合结构, 将主干中的浅层几何特征信息和 Neck 中的深层语义信息相融合, 使网络能够提取全方位的特征信息, 从而提升模型的检测效果。

#### 3.3.1 小目标检测层

在风机叶片缺陷检测中, 小目标缺陷指尺寸较小且难以识别的表面缺陷, 如微小裂纹、细小划痕和局部腐蚀等。这些缺陷通常占图像面积的 0.5% 以下, 像素在  $4 \times 4$  至  $16 \times 16$  之间, 与周围背景的对比度较低, 缺乏明显边缘, 在图像中难以清晰辨认。

在 YOLOv8 模型中包含 3 个检测层, 通过生成尺寸为  $20 \times 20$ ,  $40 \times 40$ ,  $80 \times 80$  的特征图, 以检测尺寸在  $32 \times 32$ ,  $16 \times 16$ ,  $8 \times 8$  以上的目标。由于风机叶片存在微裂纹、腐蚀点和小划痕等细微缺陷, 这些小目标特征信息在经过不断地下采样池化操作后, 会被背景信息淹没, 导致在  $20 \times 20$ ,  $40 \times 40$  尺寸的特征图中出现信息丢失的问题, 使得模型的检测精度降低并出现漏检情况。尽管  $80 \times 80$  能够检测一部分小目标, 但由于远距离拍摄以及微小缺陷导致图像中存在尺寸在  $8 \times 8$  以下的目标, 使它对小目标的识别能力仍然不足。因此, 本文新增  $160 \times 160$  的小目标检测层, 用来检测更小的目标区域。通过在原始网络结构中增加颈部特征融合层数并引出  $160 \times 160$  检测头, 使网络检测小目标的极限提升至  $4 \times 4$  像素, 帮助模型更好地学习并检测小目标的纹理特征和细节信息。该检测层与其他 3 个检测层协同工作, 使网络更好地检测多尺度目标, 并有效减少了对细微缺陷的漏检误检率。

#### 3.3.2 多尺度特征融合结构

在 Neck 中, YOLOv8 通过结合 FPN 和 PAN 的优点形成了 PAN-FPN 结构, 首先通过上采样和特征融合操作将深层语义信息和浅层几何信

息连接起来,建立一个多尺度的特征金字塔,使网络捕获更多特征信息。再采用自底向上的路径,将浅层高分辨率特征通过卷积和横向连接与深层语义特征相结合,以增强浅层特征的语义表达能力和深层特征的细节信息利用能力。PAN-FPN 结构促进了不同尺度特征的有效整合,并提升了模型对复杂场景中多尺度目标的检测能力。然而,随着网络深度的增加,浅层几何信息在不断的下采样和特征融合过程中丢失,导致网络对边缘和纹理等细节信息的检测不足。因此,本文将 backbone 中的丰富几何特征融入 PAN 的特征融合模块中。如图 8 所示,将主干部分 B3, B4 层中的浅层特征信息分别融入至 N3, N4 层中,实现 B3-P3-N3 和 B4-P4-N4 特征信息的有效结合。该方法避免了网络中浅层几何特征信息的丢失,通过与颈部较强的语义信息结合,增强网络对复杂目标(边缘纹理特征和远距离背景信息)的检测,提升模型的泛化性能。




图 8 多尺度特征融合结构

Fig. 8 Architecture of multi-scale feature fusion

### 3.4 注意力与卷积融合模块

ACFM<sup>[18]</sup>网络结构如图 9 所示,包括全局和局部分支。在全局分支中,通过  $1 \times 1$  卷积和  $3 \times 3$  深度卷积得到查询(Q)、键(K)和值(V)的张量,再通过 softmax 规范 Q 和 K 来计算注意力图,减少计算负担。将自注意力机制整合到全局分支中,有助于增强网络长距离的信息交互能力,捕获多样的全局特征。在局部分支中,首先使用  $1 \times 1$  卷积调整通道维度,并采用通道混洗的方式增加模型复杂度,从而增强模型的表征能力并减少过拟合的风险,最后利用  $3 \times 3 \times 3$  卷积进行特征提取。通过卷积和自注意力机制的融合,模型可以有效地捕获全局和局部特征,提升了模型性能,并增强了对复杂数据结构的处理能力。计算公式如下:

$$\text{Attention}(Q, K, V) = V \text{Softmax}\left(\frac{QK}{\alpha}\right), \quad (10)$$

$$f_{\text{att}} = W_{1 \times 1} \text{Attention}(Q, K, V) + Y, \quad (11)$$

$$f_{\text{conv}} = W_{3 \times 3 \times 3}(\text{CS}(W_{1 \times 1}(Y))), \quad (12)$$

其中:  $f_{\text{att}}$  为全局分支的输出,  $W_{1 \times 1}$  为  $1 \times 1$  卷积, Y 为输入特征,  $\alpha$  为在 Softmax 运算之前调制矩阵相乘的幅度,  $f_{\text{conv}}$  为局部分支的输出,  $W_{3 \times 3 \times 3}$  为  $3 \times 3 \times 3$  卷积, CS 为通道混洗操作。

根据 ACFM 模块捕获全局和局部特征信息的特性,本文在 YOLOv8 模型检测头前加入 ACFM。通过增强图像中不同区域之间的信息关联,对输出特征进行有效区分,使模型抑制与

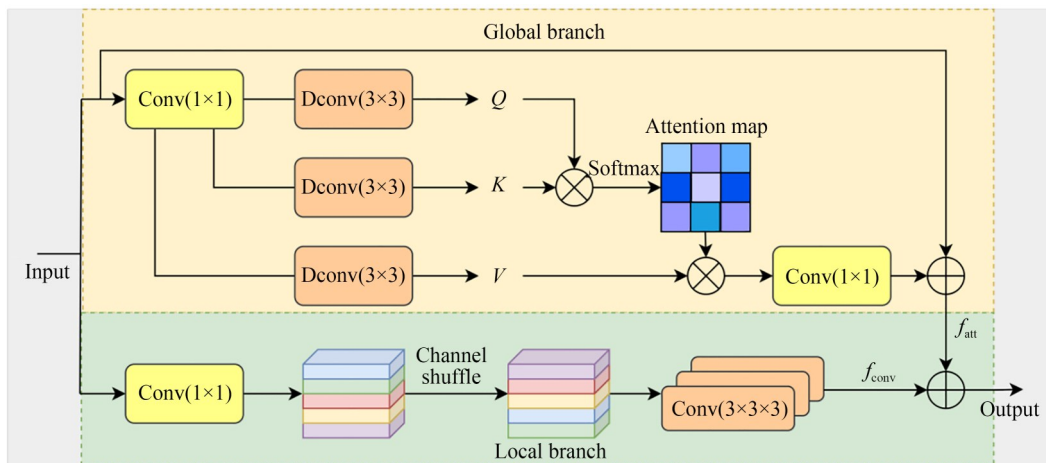


图 9 ACFM 网络结构

Fig. 9 Architecture of ACFM network

目标无关的背景信息,减少漏检误检几率,并加强模型对重要特征的关注能力,提升对关键目标的检测性能。在风机缺陷检测过程中,可以获得更加全面的检测效果。

## 4 实验与结果分析

### 4.1 数据集

由于目前没有专业的风机叶片缺陷公共数据集,因此,本文通过采用大疆无人机在不同角

度和不同光线的条件下对某风力发电厂的风机叶片进行拍摄,共拍摄 3 265 张图像,每张图像的分辨率为  $640 \times 640$ 。裂纹、损伤和油漆脱落 3 种风机叶片常见的缺陷如图 10 所示,采用 LabelImg 工具对图像进行标签制作,共标注 10 450 个对象,其中裂纹、损伤和油漆脱落的数量分别为 1 370(13%),6 195(59%),2 885(28%),最后将数据集按 8:1:1 的比例划分成训练集、验证集和测试集。其中,2 612 张图像用于训练,327 张图像用于验证,326 张图像用于测试。




图 10 各类缺陷示意图

Fig. 10 Various types of defects

### 4.2 实验环境

实验操作系统为 Linux 系统,硬件使用 CPU 为 AMD EPYC 7542 32-Core Processor, GPU 为 GeForce RTX 3090-24G,软件使用编程语言为 Python 3.8.10,采用 PyTorch 2.0.0 作为深度学习框架,CUDA 为 11.8。对于模型的训练,训练轮次设为 300 轮,批量数为 16,早停触发轮数 patience 为 50,初始学习率为 0.01,动量参数设置为 0.937,优化器采用 SGD 优化器,输入图像的分辨率为  $640 \times 640$ 。

### 4.3 评价指标

针对改进的 YOLOv8 网络结构,本文选取准确率 ( $P$ )、召回率 ( $R$ )、全类平均精度均值 ( $mAP@0.5$ ,  $mAP@0.5:0.95$ )、参数量 Parameters 和 FPS 来对实验结果进行评估。Precision 表示模型预测为正例的样本中实际为正的比

例。AP 为某一类别的平均精度,通过计算准确-召回曲线下方面积得出。mAP 是所有类别 AP 值的平均值,用于评估模型对多类别目标检测的整体性能,值越高,模型检测效果越好。其中,  $mAP@0.5$  表示当 IoU 阈值为 0.5 时所有类别的平均检测率,  $mAP@0.5:0.95$  为以步长 0.05, IoU 阈值在 0.5 至 0.95 之间的平均 mAP。Parameters 表示模型的参数量,用于衡量模型的复杂度;FPS 表示模型每秒可以处理的图像数量,值越高,检测速度越快。具体的计算公式如下:

$$P = \frac{TP}{TP + FP}, \quad (13)$$

$$R = \frac{TP}{TP + FN}, \quad (14)$$

$$AP = \int_0^1 P(R) dR, \quad (15)$$

$$mAP = \frac{1}{c} \sum_{i=1}^c AP_i, \quad (16)$$

$$\text{Parameters} = IK^2C + C, \quad (17)$$

其中:TP 为正确预测的样本数量,FP 为错误预测的样本数量,FN 为正样本中未检测出的样本数量; $P(R)$ 为基于准确率和召回率的曲线,表示模型在不同召回率下的准确率, $c$ 为类别数量;Parameters 中  $I$  为输入通道数, $K$  为卷积核大小, $C$  为输出通道数,根据卷积层的核大小和通道数计算每层参数量,并相加得出模型的总参数量。

#### 4.4 消融实验

为了验证改进算法中每一步改进的有效性,本文以原始 YOLOv8 为基线算法,并结合不同改进策略进行消融实验,结果如表 1 所示,其中“√”表示引入相应模块。由表可知,模型 1 为基线算法,mAP@0.5 为 84.9%,mAP@0.5:0.95 为 55.4%。准确率和召回率分别为 86.8%,77.2%,参数量为 3.01M。在基线算法中加入 160×160 检测层后,mAP@0.5 和 mAP@0.5:0.95 分别提升了 2% 和 1.9%,可见小目标层加强了模型对细微缺陷的检测,提升了模型整体的

精度。之后,引入多尺度特征融合结构,召回率和 mAP@0.5 分别提升了 2.1% 和 0.7%,有效增强了模型对复杂目标的捕获,但准确率下降了 2.7%。在基线算法中单独引入 ACFM,召回率和 mAP@0.5 分别提升了 1.3% 和 0.7%,准确率和 mAP@0.5:0.95 却分别下降了 0.5% 和 0.3%,但通过模型 10 可知,ACFM 在改进算法中存在一定的作用。单独引入 GRE-SPPF 模块后,召回率和 mAP@0.5 分别提升了 3.2% 和 0.9%,通过增强对全局信息的捕获并与局部信息相融合,有效缓解了检测过程的漏检情况。在基线算法中应用 DE-C2f 模块,mAP@0.5 和 mAP@0.5:0.95 分别提升了 3.5% 和 3.7%,可见通过 DE-C2f 模块对多尺度特征的提取,有效提升了模型对叶片缺陷的检测性能。最后,将所有改进点同时作用 YOLOv8,mAP@0.5 和 mAP@0.5:0.95 分别达到了 91.1% 和 61.8%,相比于基线算法分别提升了 6.2% 和 6.4%,且准确率和召回率分别提升了 2% 和 7.7%,参数量仅仅提升了 0.15M。

表 1 消融实验

Tab.1 Ablation Experiment

Number	160×160 detection layer	Improved neck	ACFM	GRE- SPPF	DE-C2f	$P(\%)$	$R(\%)$	mAP@ 0.5(%)	mAP@0.5: 0.95(%)	Param s/M	FPS
1	—	—	—	—	—	86.8	77.2	84.9	55.4	3.01	111.1
2	√	—	—	—	—	88.2	79.5	86.9	57.3	2.92	104.2
3	—	√	—	—	—	85.5	81.6	87.6	59.1	2.94	107.5
4	—	—	√	—	—	86.3	78.5	85.6	55.1	3.51	90.1
5	—	—	—	√	—	83.7	80.4	85.8	55.5	3.07	108.7
6	—	—	—	—	√	85.6	82.2	88.4	59.1	2.66	86.2
7	—	√	—	—	√	88.0	80.7	88.5	59.9	2.58	75.2
8	—	√	√	—	—	84.1	83.5	88.0	58.4	3.46	84.0
9	—	√	√	√	—	86.5	83.9	88.8	59.6	3.50	79.4
10	—	√	—	√	√	85.8	83.4	88.8	61.7	2.62	74.6
11	—	√	√	√	√	88.6	84.9	91.1	61.8	3.16	63.7

根据实验结果和数据分析,可见改进算法有效地提升了对风机叶片缺陷的检测精度,并抑制了漏检误检率,提升了模型的整体检测性能。在检测速度上,改进算法相比于最高检测速度有一定的降低,但仍保持在 63.7 frame/s,完全满足风

机叶片的实时检测需求。

图 11 为 YOLOv8 算法和改进算法的 PR 曲线图。由图可得,改进算法曲线相比于原始 YOLOv8 算法曲线更接近右上角,且拥有更大的曲线下方面积,表明准确率和召回率较高,检测性

能更加优越。改进算法的裂纹、损伤和油漆脱落 3 种缺陷的 AP 分别提高了 6.2%, 5.2% 和

7.3%, 可见本文算法能够有效地检测不同尺度与不同类别的缺陷目标。




图 11 YOLOv8算法和改进算法的PR曲线

Fig. 11 PR curves of YOLOv8 and improved algorithm

图 12 为风机叶片缺陷算法改进前后 map 曲线对比。显然,改进后的算法在 map@0.5 和

map@0.5:0.95 两个指标上均表现更佳,从而验证了本文所提算法的有效性和实用性。

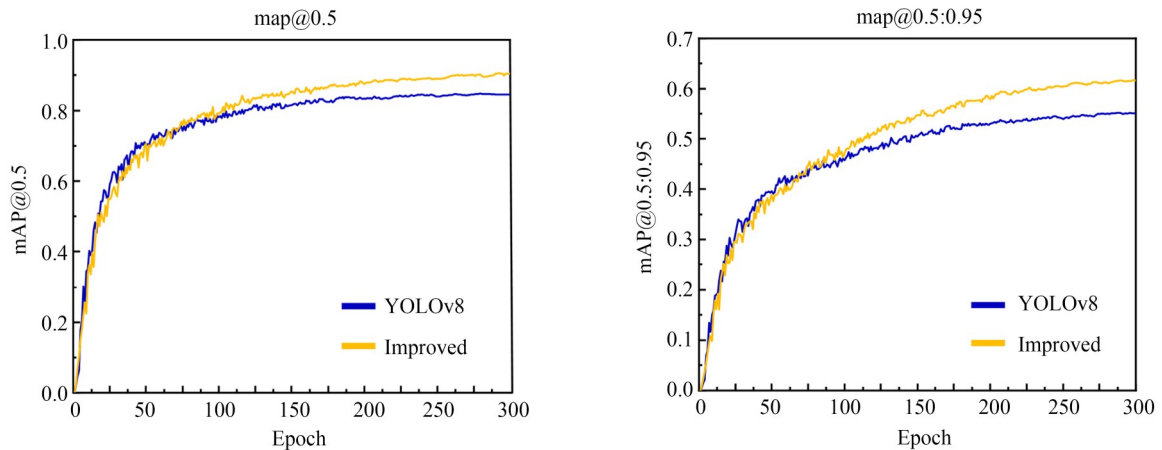


图 12 风机叶片缺陷算法改进前后 mAP 曲线对比

Fig. 12 Comparison of mAP curves before and after algorithm improvement for wind turbine blade defects

## 4.5 对比实验

### 4.5.1 注意力机制模块效果对比

为了验证 ACFM 的有效性,本文以表 1 中的模型 8 为基线,在检测头前加入不同的注意力机制进行对比,实验结果如表 2 所示。

通过对比可见,在检测头前加入 ACFM 后,

相比于加入其他注意力机制,召回率和 mAP@0.5(%)都具有明显的优势。当加入 GAM 后, mAP@0.5:0.95(%)提升至 59.1%, 优于其他模型,但参数量较高。因此,本文选用 ACFM,并加入至检测头前,提升模型对风机叶片缺陷的检测效果。

表 2 注意力机制模块效果对比

Tab. 2 Comparison of effectiveness of attention mechanism modules

Model	$P(\%)$	$R(\%)$	mAP@0.5(%)	mAP@0.5:0.95(%)	Params/M
M3+ACFM	84.1	<b>83.5</b>	<b>88.0</b>	58.4	3.46
+CBAM <sup>[19]</sup>	88.3	78.8	87.6	58.1	3.03
+EMA	84.1	82.7	87.5	57.7	2.94
+MCA <sup>[20]</sup>	<b>88.6</b>	77.5	86.9	57.0	2.94
+SE <sup>[21]</sup>	87.0	81.1	87.2	59.1	2.99
+ECA	84.4	81.7	87.3	57.5	2.94
+GAM <sup>[22]</sup>	83.3	82.3	88.0	<b>59.2</b>	5.12
+iEMA <sup>[23]</sup>	84.7	83.5	87.2	58.3	3.04
+SEAM <sup>[24]</sup>	87.6	81.7	87.6	59.2	3.05
+MLCA <sup>[25]</sup>	87.3	81.9	87.7	58.4	2.94

图 13 为 YOLOv8 添加 ACFM 前后可视化热力图。由图可知, YOLOv8 易受背景干扰, 且对微小缺陷的关注度低, 存在漏检情况。

ACFM 通过融合全局和局部特征信息, 有效抑制了无关背景特征信息, 并提升了对小目标的聚焦能力。




图 13 ACFM 模块添加前后热力图对比

Fig. 13 Comparison of heatmaps before and after adding ACFM

#### 4.5.2 不同 SPPF 改进模块效果对比

为了进一步验证 GRE-SPPF 改进模块的有效性,以本文改进的 YOLOv8 算法为基准,引入不同的 SPPF 模块进行对比,包括 SPPF, Sim-SPPF, SPPFCSPC 和文献 [28-32] 中的 SPPF-LSKA, DPAM, SPPFAPGC 等。实验结果如表 3 所示。由表可知, SimSPPF 的  $mAP@0.5:0.95(\%)$  达到了 62.6%, 优于其他模型且相比 GRE-SPPF 高出 0.8%, 表明它在高精度的目标检测上存在稍许的优势; 然而, 召回率以及  $mAP@0.5(\%)$  比 GRE-SPPF 分别低了 3% 和

1.5%, 可见它对全局目标的检测以及定位能力存在明显的不足。与 SPPF-LSKA 相比, GRE-SPPF 的召回率,  $mAP@0.5(\%)$  以及  $mAP@0.5:0.95(\%)$  分别高出 5.8%, 2.2% 和 1.5%, 拥有显著的优势, 尽管 SPPF-LSKA 在准确率上较高, 但对图像的全面检测却存在明显的劣势。通过对比可知, GRE-SPPF 模块相比其他模型拥有较高的召回率和  $mAP@0.5(\%)$ , 可帮助模型检出更多的目标, 并对全局目标有更高精度的定位能力, 有效应对叶片缺陷检测中的漏检误检问题。

表 3 不同 SPPF 改进模块效果对比

Tab. 3 Comparison of effectiveness of different SPPF improvement modules

Module	$P(\%)$	$R(\%)$	$mAP@0.5(\%)$	$mAP@0.5:0.95(\%)$	Params/M
SPPF	88.5	83.3	89.2	61.8	3.10
SimSPPF <sup>[26]</sup>	88.6	81.9	89.6	<b>62.6</b>	3.10
SPPFCSPC <sup>[27]</sup>	88.9	81.5	88.9	60.7	4.71
SPPF-LSKA <sup>[28]</sup>	<b>89.6</b>	79.1	88.9	60.3	3.37
DPAM <sup>[29]</sup>	87.9	80.9	89.7	61.2	3.20
SPPFAPGC <sup>[30]</sup>	85.8	82.0	87.0	57.8	3.24
GRF-SPPF <sup>[31]</sup>	86.6	84.9	89.6	61.5	3.17
SPPF-S <sup>[32]</sup>	86.8	83.5	89.7	60.7	3.11
GRE-SPPF	88.6	<b>84.9</b>	<b>91.1</b>	61.8	3.16

#### 4.5.3 DE-C2f 模块在不同位置的模型效果对比

DE-C2f 模块可以有效捕获多尺度上下文信息并提升模型的运算效率, 由于它在不同位置对

模型产生的检测效果不同, 本文基于改进的 YOLOv8 模型在不同位置添加 DE-C2f 模块, 以寻找最佳的引入位置, 使模型性能最优。实验结果如表 4 所示。

表 4 DE-C2f 模块在不同位置的模型效果对比

Tab. 4 Comparison of model performance with DE-C2f module at different locations

Location	$P(\%)$	$R(\%)$	$mAP@0.5(\%)$	$mAP@0.5:0.95(\%)$	Params/M
B2-B5	87.8	80.3	87.8	58.3	3.22
B2-B5&P3-P4&N2-N5	<b>89.6</b>	84.3	90.0	61.2	2.92
B2-B5&N2-N5	86.9	79.5	87.1	58.1	2.97
B2-B5&P3-P4	88.2	82.8	89.1	59.7	3.16
P3-P4&N2-N5	85.9	81.7	88.1	59.5	3.22
N2-N5	86.2	82.7	87.6	58.9	3.28
B3-B5&N2-N5	87.3	81.8	88.5	58.4	2.98
B3-B5&P3-P4&N3-N4	88.9	82.9	90.3	60.0	3.11
B3-B5&P3-P4	88.6	<b>84.9</b>	<b>91.1</b>	<b>61.8</b>	3.16

在表中, B2-B5表示将特征层B2-B5处的C2f替换为DE-C2f模块, 以此类推。各特征层位置如图2所示。由表可知, 将B3-B5和N3-N4特征层中的C2f替换为DE-C2f模块后, 召回率、mAP@0.5(%)和mAP@0.5:0.95(%)都明显优于其他方法, 达到了最高。在替换B2-B5&P3-P4&N2-N5层中C2f后, 准确率达到89.6%, 但mAP@0.5(%)和召回率较低。因此, 本文在B3-B5&P3-P4层中引入了DE-C2f模块, 增强网络对叶片缺陷特征的提取能力, 并提高模型的检测效率。

#### 4.5.4 模型对比实验

为了验证本文改进YOLOv8模型在风机叶片缺陷检测上的优越性, 将它与Faster-RCNN, RT-DETR-l<sup>[33]</sup>以及YOLO系列模型进行对比实验, 结果如表5所示。可见, 两阶段目标检测模

型Faster-RCNN相比其他模型检测效果较低, 且参数量大, 难以满足风机叶片缺陷检测的需求。实时端到端检测模型RT-DETR是一种基于transformer的实时推理目标检测模型, 在检测目标时兼顾速度和精度两个特性, 但在风机叶片缺陷检测时, 与YOLO系列模型对比, 其效果显然一般, 还需要较大的参数量。而改进YOLOv8模型相比YOLOv5n, YOLOv6<sup>[26]</sup>, YOLOv7-tiny<sup>[27]</sup>, YOLOv8s, YOLOv9s<sup>[34]</sup>, YOLOv10n<sup>[35]</sup>以及YOLOv11n, 拥有更高的准确率和查全率, mAP@0.5(%)分别提升了6.5%, 11.3%, 10.1%, 5.6%, 4.5%, 8.2%和5.4%, 且参数量与原始YOLOv8n相比仅增加了0.15M。由此可见, 本文改进模型相比其他模型在叶片缺陷检测中具有明显的优势, 拥有更好的检测性能。

表5 模型对比实验

Tab. 5 Model comparison experiment

Model	P(%)	R(%)	mAP@0.5(%)	mAP@0.5:0.95(%)	Params/M	FPS
Faster-RCNN	30.8	65.9	52.0	25.0	137.10	—
SSD	36.1	62.3	53.4	27.3	26.29	—
RT-DETR-l	77.8	69.1	76.6	45.6	31.99	63.2
YOLOv5n	87.6	76.3	84.6	55.3	2.50	108.7
YOLOv6	80.4	75.2	79.8	49.8	4.23	125.0
YOLOv7-tiny	84.5	74.4	81.0	48.3	6.02	—
YOLOv8n	86.8	77.2	84.9	55.4	3.01	111.1
YOLOv8s	88.0	76.9	85.5	56.9	11.10	116.3
YOLOv9s	86.5	78.6	86.6	59.8	7.17	64.5
YOLOv10n	82.0	75.9	82.9	53.3	2.70	104.2
YOLOv11n	84.6	79.1	85.7	55.1	2.58	66.2
Ours	88.6	84.9	91.1	61.8	3.16	63.7

#### 4.6 可视化分析

为了体现本文改进算法的有效性, 分别使用YOLOv8算法和本文改进算法对风机叶片缺陷测试集进行测试, 并选取其中具有代表性的图片进行可视化分析, 直观比较两种算法的检测效果, 结果如图14所示。

通过对比发现, 在第1, 2, 4, 5幅图中改进算法能够更准确地检测YOLOv8漏检的目标; 对于两个算法均能检测出的目标, 改进算法相比于原始算法具有更高的置信度得分, 置信度越高, 说

明预测框中目标存在的概率越高, 学习的目标信息更多。由热力图可见, 改进算法能够有效应对背景干扰, 对小目标和遮挡目标具有更好的识别能力, 显著提升了对风机叶片缺陷的识别精度。可视化分析表明, 本文改进后的YOLOv8算法相比原始算法具有更高的精度和查全率, 表现出更好的检测效果和性能。

#### 4.7 泛化性实验

为了进一步验证本文改进YOLOv8算法的推广性, 本文采用北京大学公开的PCB板缺陷数




图 14 YOLOv8模型改进前后可视化对比

Fig. 14 Visualization comparison before and after YOLOv8 model improvement

据集<sup>[36]</sup>对所提算法进行泛化性实验。该数据集共包含 693 张图片,涵盖缺洞、鼠咬、开路、短路、毛刺和伪铜 6 种缺陷。将该数据集按 8:1:1 的比例划分成训练集、验证集和测试集,训练轮数设为 200,其他参数与第 3.2 节保持一致,实验结果如表 6 所示。

由表可知,在 PCB 板缺陷数据集中,本文改进算法的  $mAP@0.5(\%)$  和  $mAP@0.5:0.95(\%)$  分别达到了 94.1% 和 51.6%,相比原始

YOLOv8 算法分别提升了 2% 和 4.9%,在鼠咬、开路和毛刺 3 种缺陷下的  $AP@0.5(\%)$  分别提升了 2.1%, 4.9% 和 6.7%,但在伪铜缺陷下  $AP@0.5(\%)$  下降了 1.1%。

YOLOv8 算法和本文改进算法在 PCB 板缺陷数据集集中的  $mAP@0.5(\%)$  和  $mAP@0.5:0.95(\%)$  曲线比较如图 15 所示。由图可知,改进 YOLOv8 算法具有良好的泛化性,可用于不同的缺陷检测数据集中。

表 6 PCB 缺陷数据集实验结果对比

Tab. 6 Comparison of experimental results on PCB defect dataset

(%)

Model	AP@0.5						mAP@0.5	mAP@0.5 :0.95
	Missing hole	Mouse bite	Open circuit	Short	Spur	Spurious copper		
YOLOv8	99.5	88.8	89.9	96.7	83.2	94.1	92.1	46.7
Ours	99.5	90.9	94.8	96.6	89.9	93.0	94.1	51.6

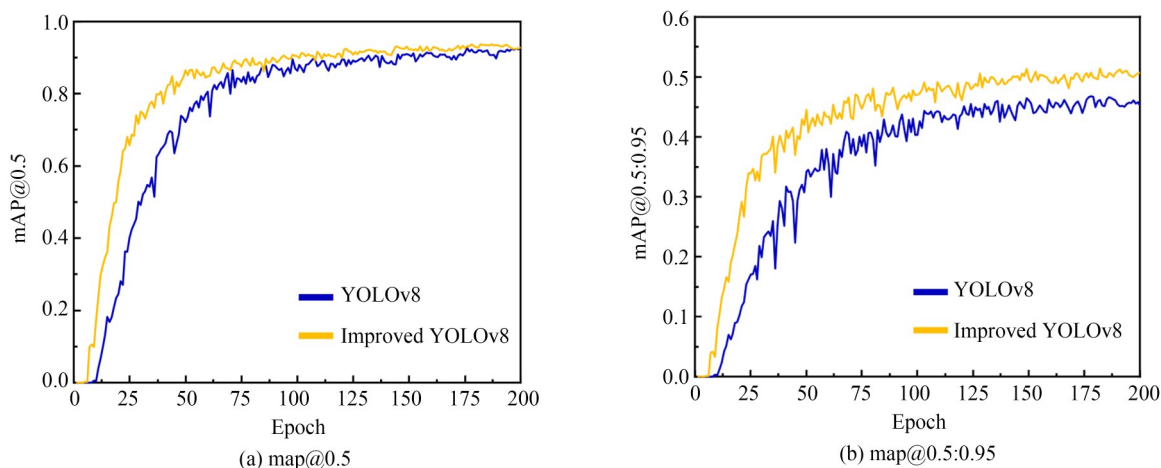


图 15 PCB 板缺陷算法改进前后 mAP 曲线对比

Fig. 15 Comparison of mAP curves before and after algorithm improvement for PCB defects

## 5 结 论

针对风机叶片缺陷检测存在精度不高、漏检误检的问题,本文提出了一种改进的 YOLOv8 算法。首先,通过设计 DE-Bottleneck 结构提出了 DE-C2f 模块,提升网络对多尺度特征的提取能力,并减少网络参数量和计算量,提高网络的运行效率。其次,构建全新的特征融合模块 GRE-SPPF,加强网络对全局特征的捕获能力,缓解检测过程中的漏检和误检。最后,在 Neck 中增加小目标层和多尺度特征融合结构,增强网络对小目标和复杂目标的识别能力,并在检测头前引入 ACFM,使网络抑制无关背景特征,并聚焦重要特征。实验结果表明,本文改进算法相比其他检测算法拥有更高的准确率和召回率,且具有良好的泛化性能。mAP@0.5 和 mAP@0.5:0.95 分别达到了 91.1% 和 61.8%,优于其他检测算法,相比于原始 YOLOv8 算法分别提升了 6.2% 和 6.4%,且参数量没有明显提升,改进后的算法能够在复杂环境中高效、准确地识别多样缺陷,可应用于风电场自动监控、风机故障排查定期维护以及叶片制造的缺陷检测等实际应用中。

由于改进算法相比于基线算法计算量略有增加,检测速度有所下降。后续研究将聚焦模型轻量化设计,优化检测精度与计算效率的平衡,提升算法在实际应用中的运行速度。通过剪枝、量化和蒸馏等技术,降低模型复杂度,增强其在边缘设备上的实时检测能力。同时,优化算法在不同硬件平台,如边缘计算设备上的适配性,结合硬件加速和轻量化设计,提升部署效率,实现风机叶片缺陷检测的智能化与高效化。

### 作者贡献声明:

朱广:研究方法的提出,实验方案设计,论文初稿撰写;

顾晨:实验执行,数据收集与结果验证,协助核心模型参数调优与测试分析;

徐立云:论文的审阅与编辑,技术支持和学术指导;

史艳琼:数据整理,图表制作和论文原稿撰写,技术支持和学术指导;

丁郑阳:文献调研;

张旭、张永华:数据初步整理,算法对比分析。


## 参考文献:

- [1] 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 Engineering & System Safety*, 2019, 184: 2-12.
- [2] DOLIŃSKI Ł, KRAWCZUK M, ŻAK A. Detection of delamination in laminate wind turbine blades using one-dimensional wavelet analysis of modal responses[J]. *Shock and Vibration*, 2018, 2018(1): 4507879.
- [3] LIU Z, LIU X, ZHU S P, *et al.* Reliability assessment of measurement accuracy for FBG sensors used in structural tests of the wind turbine blades based on strain transfer laws[J]. *Engineering Failure Analysis*, 2020, 112: 104506.
- [4] WU R, ZHANG D S, YU Q F, *et al.* Health monitoring of wind turbine blades in operation using three-dimensional digital image correlation[J]. *Mechanical Systems and Signal Processing*, 2019, 130: 470-483.
- [5] MORENO S, PENA M, TOLEDO A, *et al.* A new vision-based method using deep learning for damage inspection in wind turbine blades[C]. 2018 15th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE). September 5-7, 2018. Mexico City. IEEE, 2018: 1-5.
- [6] SHI L C, LONG Y, WANG Y Z, *et al.* Evaluation of internal cracks in turbine blade thermal barrier coating using enhanced multi-scale faster R-CNN model[J]. *Applied Sciences*, 2022, 12(13): 6446.
- [7] ZHANG C, WEN C 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.
- [8] 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). June 27-30, 2016. Las Vegas, NV, USA. IEEE, 2016: 779-788.
- [9] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: Single Shot MultiBox Detector[M]. Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [10] LV L, YAO Z Y, WANG E M, *et al.* Efficient and accurate damage detector for wind turbine blade images [J]. *IEEE Access*, 2022, 10: 123378-123386.
- [11] 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: 120241.
- [12] ZHENG Y Q, LIU Y H, WEI T, *et al.* Wind turbine blades surface crack-detection algorithm based on improved YOLO-v5 model[J]. *Journal of Electronic Imaging*, 2023, 32: 033012.
- [13] TONG L, FAN C L, PENG Z B, *et al.* WTBD-YOLOv8: an improved method for wind turbine generator defect detection [J]. *Sustainability*, 2024, 16(11): 4467.
- [14] ZHONG J, CHEN J, MIAN A. DualConv: dual convolutional kernels for lightweight deep neural networks [J]. *IEEE Trans Neural Netw Learn Syst*, 2023, 34(11): 9528-9535.
- [15] 王蕾, 郭文平, 陈欣慰, 等. 融合多尺度特征的蜗杆表面缺陷检测[J]. *光学精密工程*, 2024, 32(11): 1746-1758.
- WANG L, GUO W P, CHEN X W, *et al.* Worm surface defect detection with fusion of multi-scale features [J]. *Optics and Precision Engineering*, 2024, 32(11): 1746-1758. (in Chinese)
- [16] 蔡引娣, 张殿鹏, 孙梓盟, 等. 基于改进 YOLOv8 模型的增材制造微小气孔缺陷检测及其尺寸测量 [J]. *光学精密工程*, 2024, 32(21): 3222-3230.
- CAI Y D, ZHANG D P, SUN Z M, *et al.* YOLOv8 model-based additive manufacturing micro porosity defect detection and its dimension measurement [J]. *Optics and Precision Engineering*, 2024, 32(21): 3222-3230. (in Chinese)
- [17] MISRA D. Mish: A self regularized non-monotonic activation function [EB/OL]. (2019-08-23) [2025-02-05]. <https://arxiv.org/abs/1908.08681>.
- [18] CHEN Z L, LU S N. Caf-yolo: A robust framework for multi-scale lesion detection in biomedical imagery [EB/OL]. (2024-08-04) [2024-12-10]. <https://arxiv.org/abs/2408.01897>.
- [19] WOO S, PARK J, LEE J Y, *et al.* CBAM: convolutional block attention module [C]. *Computer Vision-ECCV 2018*. Cham: Springer International Publishing, 2018: 3-19.

- [20] YU Y, ZHANG Y, CHENG Z Y, *et al.* MCA: Multidimensional collaborative attention in deep convolutional neural networks for image recognition [J]. *Engineering Applications of Artificial Intelligence*, 2023, 126: 107079.
- [21] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. June 18-23, 2018. Salt Lake City, UT. IEEE, 2018: 7132-7141.
- [22] LIU Y, SHAO Z, HOFFMANN N. Global attention mechanism: Retain information to enhance channel-spatial interactions [EB/OL]. (2021-12-10) [2024-12-10]. <https://arxiv.org/abs/2112.05561>.
- [23] 崔家礼, 王涵, 郑瀚, 等. 基于LDI-YOLOv8的融合图像检测方法[J/OL]. *微电子学与计算机*, 2024: 1-14. (2024-08-09). <https://kns.cnki.net/kcms/detail/61.1123.tn.20240808.1049.002.html>.
- CUI J L, WANG H, ZHENG H, *et al.* Fusion image detection method based on LDI-YOLOv8 [J/OL]. *Microelectronics & Computer*, 2024: 1-14. (2024-08-09). <https://kns.cnki.net/kcms/detail/61.1123.tn.20240808.1049.002.html>. (in Chinese)
- [24] YU Z P, HUANG H B, CHEN W J, *et al.* YOLO-FaceV2: a scale and occlusion aware face detector [J]. *Pattern Recognition*, 2024, 155: 110714.
- [25] WAND H, LU R S, SHEN S Y, *et al.* Mixed local channel attention for object detection[J]. *Engineering Applications of Artificial Intelligence*, 2023, 123: 106442.
- [26] LI C, LI L, JIANG H, *et al.* YOLOv6: A single-stage object detection framework for industrial applications [EB/OL]. (2018-04-08) [2024-12-10]. <https://arxiv.org/abs/1804.02767>.
- [27] WANG C Y, BOCHKOVSKIY A, LIAO H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023. Vancouver, BC, Canada. IEEE, 2023: 7464-7475.
- [28] 张冀, 王文彬, 余洋. 基于RFCARep-YOLOv8n的光伏电池缺陷检测算法[J]. *计算机工程与应用*, 2025, 61(3): 131-143.
- ZHANG J, WANG W B, YU Y. Defect detection of photovoltaic cells based on RFCARep-YOLOv8n [J]. *Computer Engineering and Applications*, 2025, 61(3): 131-143. (in Chinese)
- [29] 梁礼明, 冯耀, 龙鹏威, 等. 融合岛式双向特征金字塔的遥感图像目标检测[J/OL]. *计算机工程与应用*, 2024: 1-15. (2024-09-06). <https://kns.cnki.net/kcms/detail/11.2127.TP.20240906.1356.011.html>.
- LIANG L M, FENG Y, LONG P W, *et al.* Target detection in remote sensing image based on island bidirectional feature pyramid[J/OL]. *Computer Engineering and Applications*, 2024: 1-15. (2024-09-06). <https://kns.cnki.net/kcms/detail/11.2127.TP.20240906.1356.011.html>. (in Chinese)
- [30] 许德刚, 王双臣, 王再庆, 等. 改进YOLOv8算法的城市车辆目标检测[J]. *计算机工程与应用*, 2024, 60(18): 136-146.
- XU D G, WANG SH CH, WANG Z Q, *et al.* Improved YOLOv8 urban vehicle target detection algorithm[J]. *Computer Engineering and Applications*, 2024, 60(18): 136-146. (in Chinese)
- [31] 郭伟, 闻雯, 金海波, 等. 跨尺度多维协作特征交互的航拍绝缘子多缺陷检测[J/OL]. *计算机工程与应用*, 2024: 1-15. (2024-08-15). <https://kns.cnki.net/kcms/detail/11.2127TP.20240814.1111.002.html>.
- GUO W, WEN W, JIN H B, *et al.* Multi-defect detection of aerial insulators based on cross-scale and multi-dimensional cooperative feature interaction[J/OL]. *Computer Engineering and Applications*, 2024: 1-15. (2024-08-15). <https://kns.cnki.net/kcms/detail/11.2127TP.20240814.1111.002.html>. (in Chinese)
- [32] 齐向明, 严萍萍, 姜亮. 基于YOLOv8n的航拍图像小目标检测算法[J]. *计算机工程与应用*, 2024, 60(24): 200-210.
- QI X M, YAN P P, JIANG L. Small target detection algorithm for aerial images based on YOLOv8n [J]. *Computer Engineering and Applications*, 2024, 60(24): 200-210. (in Chinese)
- [33] ZHAO Y A, LV W Y, XU S L, *et al.* DETRs beat YOLOs on real-time object detection [C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 16-22, 2024. Seattle, WA, USA. IEEE, 2024: 16965-16974.

- [34] WANG C Y, YE H I H, LIAO H Y M. YOLOv9: Learning what you want to learn using programmable gradient information. [EB/OL]. (2024-02-21) [2024-12-10]. <https://arxiv.org/abs/2402.13616>. (2024-05-23) [2024-12-10]. <https://arxiv.org/abs/2405.14458>.
- [35] WANG A, CHEN H, LIU L, *et al.* Yolov10: Real-time end-to-end object detection [EB/OL]. (2024-05-23) [2024-12-10]. <https://arxiv.org/abs/2405.14458>.
- [36] CAI X, WU J. PCB bare board defect detection based on improved YOLOv7-tiny[C]. 2023 *China Automation Congress (CAC)*. November 17-19, 2023. *Chongqing, China*. IEEE, 2023: 5768-5773.

#### 作者简介:



朱 广(1979—),男,安徽颍上人,硕士,副教授,硕士生导师,2003年于安徽理工大学获得学士学位,2007年于中国矿业大学(北京)获得硕士学位,同济大学访问学者(2024级),主要从事机器视觉、图像处理与目标检测等方面的研究。E-mail: [guangzhu123@ahjzu.edu.cn](mailto:guangzhu123@ahjzu.edu.cn)



顾 晨(2001—),男,江苏盐城人,硕士研究生,2023年于南通大学获得学士学位,主要从事机器视觉、图像处理与目标检测等方面的研究。E-mail: [1053971760@qq.com](mailto:1053971760@qq.com)