

基于改进 EfficientNet 的海上风机叶片 早期缺陷检测及分类*

付军军¹ 陈 林² 童华敏² 舒征宇¹ 王 灿¹

(1. 三峡大学电气与新能源学院 宜昌 443002; 2. 国网宜昌供电公司 宜昌 443000)

摘 要: 针对海上风机叶片小尺寸缺陷检测准确率低、分类效果较差的问题,提出一种基于 EfficientNet 的改进海上风机叶片表面早期缺陷检测模型。首先,在 EfficientNet 特征提取网络中引入非对称卷积替换普通 3×3 卷积,增强了卷积核骨架信息,提高网络提取缺陷信息的能力;其次提出一种混合空间通道注意力模块聚焦空间和通道信息,结合 BiFPN 特征融合模块对不同深度的语义信息进行特征融合,提升算法多尺度特征融合能力;最后引入 Focal-EIOU 和 Focal Loss 损失函数计算位置损失和分类损失,提高定位精度,解决模型训练过程中正、负图像样本的比例失衡的问题。实验结果表明,本文所提算法模型平均精度均值为 97.6%,对风机叶片表面早期缺陷的检测性能有明显提升。

关键词: 缺陷检测;深度学习;EfficientNet;海上风机叶片;注意力机制

中图分类号: TP391.4;TN957.52 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Early defect detection and classification of offshore wind turbine blades based on improved EfficientNet

Fu Junjun¹ Chen Lin² Tong Huamin² Shu Zhengyu¹ Wang Can¹

(1. College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China;

2. State Grid Yichang Power Supply Company, Yichang 443000, China)

Abstract: Aiming at the problem of low accuracy and poor classification effect of small size defect detection of offshore wind turbine blades, an improved early defect detection model of offshore wind turbine blade surface based on EfficientNet is proposed. Firstly, the asymmetric convolution is introduced into the EfficientNet feature extraction network to replace the ordinary 3×3 convolution, which enhances the convolution kernel skeleton information and improves the ability of the network to extract defect information. Secondly, a hybrid spatial channel attention module is proposed to focus on space and channel information, and the BiFPN feature fusion module is used to fuse the semantic information of different depths to improve the multi-scale feature fusion ability of the algorithm. Finally, Focal-EIOU and Focal Loss functions are introduced to calculate the position loss and classification loss, so as to improve the positioning accuracy and solve the problem of imbalance between positive and negative image samples in the model training process. The experimental results show that the average accuracy of the proposed algorithm model is 97.6%, and the detection performance of early defects on the surface of wind turbine blades is significantly improved.

Keywords: object detection; deep learning; EfficientNet; offshore wind turbine blade; mechanism of attention

0 引 言

风力发电是风能利用的主要形式,是目前最具商业化发展前景的发电方式之一^[1]。随着风电累计装机容量的不断增加,风电设备的运行维护问题受到了广泛关注。目前,国内风电建设逐渐从内陆向近海发展,与陆地风电相比,海

上风电效益要高出 20%~40%^[2]。海上风电设备所处环境较为恶劣,设备易受湿热空气、紫外线、高盐雾海风腐蚀等环境影响。叶片是风力发电机的重要组成部分,叶片早期损伤可能只是蒙皮磨损,但随着环境因素的侵蚀会产生砂眼孔洞^[3]。早期发现的细小裂纹等缺陷可在几小时内完成修复,但如果处理不及时,内部纤维遭到破坏后叶片可能

会发生断裂,导致停机、重新更换叶片等问题^[4]。根据损伤程度及其影响,叶片的损伤类型可分为早期损伤和严重损伤。为了减少维护时间和成本,海上风电叶片检测工作应注重在缺陷扩散之前预警早期损坏^[5]。

传统的人工检测方法不仅对检测工人的专业水平要求较高,检测的效率也十分低下。此前,风机叶片的实时监测技术主要包括声发射监测、振动信号监测和应变监测^[6-8]等;离线检测技术主要包括超声扫描和红外线成像等^[9-10]。这类算法对环境因素非常敏感、操作繁琐,检测结果也不够直观,难以判断叶片缺陷的类别^[11]。随着无人机技术的发展,利用无人机采集图像,再对叶片缺陷进行分析的方法成为主流。目前的目标检测算法主要分为两阶段(two-stage)和单阶段(one-stage)两大类^[12]。两阶段算法首先生成大量候选框,再对候选框进行分类,如 Fast R-CNN^[13]、Faster R-CNN^[14]等。唐心亮等^[15]以 Faster R-CNN 为基础提出自适应旋转区域建议网络,以获取最优预测框,针对多方向检测中出现的边界不连续的问题,通过 Gaussian Wasserstein 距离和焦点损失作为损失函数来代替传统的 Smooth L1 损失函数,增强了网络对多尺度多方向目标的检测能力。但两阶段算法卷积计算量大,实际应用中处理大规模数据时计算效率有待提高。单阶段目标检测将检测视为回归问题,能够同时取得较高检测精度和速度,常用的单阶段目标检测包括 YOLO(you only look once, YOLO)^[16]系列和 SSD(single shot multibox detector, SSD)^[17]等。刘琼等^[18]在 YOLOv5 的 Backbone 部分融入卷积块注意力模块,同时在 Neck 部分使用移动窗口转换模块(STB)替换 CSP_2 模块,提高了缺陷特征提取能力,在飞机蒙皮表面缺陷数据集平均精度达到了 92.88%。贾君霞等^[19]对 SSD 算法的各个特征图进行尺度不变的卷积操作构建语义信息增强的特征图,并将原始特征图与增强特征图按照 Concat 方式特征融合,生成 SSD 算法的改进特征金字塔网络,提高了网络在复杂环境下的目标检测能力。该方法虽取得了一定成果,但由于无人机航拍叶片图像的特点,风电机组叶片图像存在缺陷尺度不一的问题,网络模型对多尺度目标尤其是小尺寸缺陷检测能力尚有不足。

本文针对目前海上风机叶片缺陷检测算法存在的模型复杂度高、小尺寸缺陷检测准确率低的问题,提出一种基于 EfficientNet 特征提取网络、注意力机制、多尺度特征融合与改进损失函数的海上风机叶片早期缺陷检测算法。该算法以 EfficientNet 网络为基础,引入非对称卷积替换普通 3×3 卷积,增强网络特征提取的能力;引入加权双向特征金字塔网络(bidirectional feature pyramid network, BiFPN)实现跨尺度特征融合,并提出一种混合空间通道注意力模块聚焦空间和通道信息,提升算法多尺度特征融合能力;采用 Focal-EIOU 及 Focal Loss 损失函数解决训练过程中正负样本不平衡的问题。最后通过所建立的海上风机

叶片缺陷图像数据集对算法进行实验验证分析。本文算法能够实现海上风机叶片早期缺陷检测及分类,有利于海上风机叶片的巡检维护工作。

1 基于 EfficientNet 的特征提取网络

1.1 EfficientNet 特征提取网络

特征提取网络的设计是目标检测任务最为关键的任务之一,以往通过手工设计的特征提取网络如 AlexNet^[20]、VGGNet^[21]、ResNet^[22]等,都是通过工程经验来确定输入图像的分辨率、卷积核的个数和网络的深度。有学者提出利用神经结构搜索技术(neural architecture search, NAS)对网络的深度(d)、通道的宽度(w)、输入分辨率(r)三个参数进行合理的配置,并基于此设计了一种全新的特征提取网络 EfficientNet^[23]。EfficientNet 的缩放方法如式(1)所示。

$$\begin{cases} d = \alpha^\phi \\ w = \beta^\phi \\ r = \gamma^\phi \\ \text{s. t. } \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \\ \alpha, \beta, \gamma \geq 1 \end{cases} \quad (1)$$

式中: ϕ 为混合因子,统一缩放深度、宽度和分辨率这 3 个维度; α 、 β 、 γ 为深度、宽度和分辨率的缩放基数。在 EfficientNetB-0 的基础上使用不同的 ϕ 进行搜索分别得到 EfficientNetB-1 至 EfficientNetB-7 的参数。以 EfficientNetB-0 为例,结构如表 1 所示。

表 1 EfficientNetB-0 结构
Table 1 The structure of EfficientNetB-0

序号	模块	输入 分辨率	输出 通道	次数
1	Conv3×3	224	32	1
2	MBConv1,3×3	112	16	1
3	MBConv6,3×3	112	24	2
4	MBConv6,5×5	56	40	2
5	MBConv6,3×3	28	80	3
6	MBConv6,5×5	14	112	3
7	MBConv6,5×5	14	192	4
8	MBConv6,3×3	7	320	1
9	Conv1×1,FC	7	1 280	1

EfficientNetB-0 中的模块 1 是一个包含 3×3 卷积、批归一化层(batch normalization, BN)、Swish 激活函数的卷积层;模块 2~8 是 MBConv 结构, 3×3 和 5×5 代表卷积核大小,具体结构如图 1 所示;最后通过一个全连接层(fully connected, FC),输出提取的特征。

在 MBConv 结构中,第 1 个卷积层目的是扩充特征的通道数,MBConv6 代表经过 1×1 卷积后的输出通道数扩




图 1 MBConv 结构

Fig. 1 The structure of MBConv

充为输入通道的 6 倍；模块 2 为深度可分离卷积 (depthwise conv, DWC), 目的是减少模型的参数量和计算量；模块 3 为 SE 通道注意力机制模块 (squeeze and excitation networks, SE), 作用是提高模型对特征的提取能力, 提高模型的精度和识别效果；模块 4 是使用卷积降低特征的通道数；模块 5 为 Dropout 层, 防止训练过程中产生过拟合的情况。

为了取得计算成本和准确率方面的平衡, 考虑到数据集样本的情况, 本文选择 EfficientNet-B2 版本作为基础模型, 去除了最后一个 MBConv6 之后的所有层, 只保留特征提取层, 以便专注于特征提取。

1.2 引入非对称卷积

风机叶片表面早期缺陷往往尺寸较小, 形状不规则, 在天气、光线、角度和其他外部干扰条件下观察时, 很难区分风力涡轮机叶片损伤特征的细微差异, 且缺陷目标与叶片背景相似, 对比度较低, 导致特征提取的效果较差。Ding 等^[24]提到, 卷积核的骨架权值通常很大, 且卷积核的骨架部位提取到的信息更有价值。考虑到卷积基本单位大多为 3×3 卷积, 但 3×3 卷积难以提取垂直或水平边缘、纹理等非对称特征, 为了提高网络提取缺陷信息的能力, 在 3×3 卷积核的对应位置上引入非对称核来增强骨架信息。改进后的非对称卷积块由大小为 1×3 、 3×1 和 3×3 的三个卷积核组成, 形成 3 个并行卷积分支, 当训练完成后网络进入部署阶段时, 3 个并行分支分别对图像进行特征提取, 然后进行批归一化并进行相加, 输出等价于骨架增强卷积核提取的特征提取结果, 其原理如图 2 所示。

假设卷积核的大小为 $H \times W$, 卷积核的个数为 D , 输入特征图的通道数为 C , 使用 $F \in R^{H \times W \times C}$ 表示卷积核, $M \in R^{U \times V \times C}$ 表示输入, $O \in R^{R \times T \times D}$ 表示卷积输出。在 CNN 体系结构中, 通常采用批量归一化减少过度拟合, 加快训练过程, 批量归一化层之后还会加入一个线性变化。则对于第 j 个卷积核 $F^{(j)}$, 相应的卷积输出如式(2)所示。

$$O_{:,j} = \left(\sum_{k=1}^C M_{:,k} * F_{:,k}^{(j)} - \mu_j \right) \frac{\gamma_j}{\sigma_j} + \beta_j \quad (2)$$




图 2 非对称卷积原理

Fig. 2 The principle of asymmetric convolution

式中: $*$ 代表二维卷积, $M_{:,k}$ 是 M 的第 k 个通道的特征图, $F_{:,k}^{(j)}$ 代表的第 k 个通道的卷积核。 μ_j 和 σ_j 是批标准化的通道平均值和标准差, γ_j 和 β_j 是缩放系数和偏移量。

通过在平方核的相应位置加入非对称核, 将 3 个 BN 融合分支合并成标准卷积层, 能够在与原始结构相同的计算预算下产生与非对称卷积相同的输出。

使用 $F'^{(j)}_{:,k}$ 表示融合后的卷积核, b_j 代表偏置, $\bar{F}^{(j)}$ 和 $\hat{F}^{(j)}$ 分别代表 1×3 和 3×1 卷积核的输出。融合后的结果如式(3)~(5)所示。

$$F'^{(j)} = \frac{\gamma_j}{\sigma_j} F^{(j)} \oplus \frac{\bar{\gamma}_j}{\bar{\sigma}_j} \bar{F}^{(j)} \oplus \frac{\hat{\gamma}_j}{\hat{\sigma}_j} \hat{F}^{(j)} \quad (3)$$

$$b_j = -\frac{\mu_j \gamma_j}{\sigma_j} - \frac{\bar{\mu}_j \bar{\gamma}_j}{\bar{\sigma}_j} - \frac{\hat{\mu}_j \hat{\gamma}_j}{\hat{\sigma}_j} + \beta_j + \bar{\beta}_j + \hat{\beta}_j \quad (4)$$

$$O_{:,j} + \bar{O}_{:,j} + \hat{O}_{:,j} = \sum_{k=1}^C M_{:,k} * F'^{(j)}_{:,k} + b_j \quad (5)$$

其中, $\oplus$ 为对应位置的求和操作, $O_{:,j}$ 、 $\bar{O}_{:,j}$ 、 $\hat{O}_{:,j}$ 代表原始 3×3 、 1×3 、 3×1 三个分支的输出, $\bar{\mu}_j$ 、 $\hat{\mu}_j$ 、 $\bar{\sigma}_j$ 、 $\hat{\sigma}_j$ 分别代表 1×3 和 3×1 卷积进行批标准化时的通道平均值和标准差, $\bar{\gamma}_j$ 、 $\hat{\gamma}_j$ 、 $\bar{\beta}_j$ 、 $\hat{\beta}_j$ 分别代表 1×3 和 3×1 卷积的缩放系数和偏移量。

将 EfficientNet 特征提取网络中的 3×3 卷积替换为非对称卷积后, 能够显著提升网络特征提取的效果, 提高风机叶片早期缺陷的检测精度。并且当训练完成后网络进入部署阶段时, 由于推理阶段的网络结构和原始网络完全相同, 而网络参数采用了融合的卷积核参数, 因此推理阶段不增加额外计算量。

2 多尺度特征融合

2.1 特征融合网络选取

在海上风机叶片损伤检测任务中, 存在大体相似的叶片损伤特征, 只是在细节上有细微的差别。随着网络深度

的不断增加,特征图中包含的语义信息不断积累,而浅层表征信息逐渐消失。小目标缺陷的相对尺寸较小,对特征图进行下采样时,小目标缺陷能够被利用的特征逐渐减少。因此,海上风机叶片早期损伤检测首要解决的问题之一就是选择对多尺度缺陷特征的融合方式。目前常见跨尺度特征融合的网络结构有特征金字塔网络(feature pyramid networks, FPN)^[25]、路径聚合网络(path aggregation network, PANet)^[26]及利用神经网络结构搜索的 FPN(neural architecture search FPN, NAS-FPN)^[27]等。

BiFPN^[28]是在 FPN 的基础之上改进的,在不增加成本的情况下融入更多特征,解决了 FPN 对于不同层存在语义差异的问题,结构如图 3 所示。




图 3 BiFPN 结构

Fig. 3 The structure of BiFPN

BiFPN 的优势不仅体现在网络优化,考虑到不同分辨率特征对融合输入特征图的贡献不同,BiFPN 提出了一种简单而高效的加权特融合机制。以第 4 级特征为例,如式(6)、(7)所示。

$$P_4^{td} = \text{Conv} \left(\frac{\omega_1 \cdot P_4^{in} + \omega_2 \cdot \text{Resize}(P_5^{in})}{\omega_1 + \omega_2 + \epsilon} \right) \quad (6)$$

$$P_4^{out} = \text{Conv} \left(\frac{\omega'_1 \cdot P_4^{in} + \omega'_2 \cdot P_4^{td} + \omega'_3 \cdot \text{Resize}(P_3^{in})}{\omega'_1 + \omega'_2 + \omega'_3 + \epsilon} \right) \quad (7)$$

式中: P_4^{td} 是由上向下第 4 级中间特征, P_4^{out} 是第 4 级输出, $\omega_i, \omega'_i (i = 1, 2, 3)$ 为权重系数, ϵ 用于避免分母为零, Resize 表示上采样或下采样,用于调整特征图大小以融合不同尺度特征。

2.2 混合空间通道注意力机制

在深度学习模型中引入注意力机制能够使得模型从复杂的特征信息中关注到更为重要信息上。由于海上风机叶片图像中各类缺陷尺度不一,引入注意力机制能有效提高模型的聚焦信息的能力。

为了提高多尺度特征融合的效果,在 SE^[29] 注意力机制的基础上进行改进,并引入空间注意力机制,聚焦空间信息。通道注意力模块需要使用全局的池化方法对特征进行聚合,但对于风机叶片缺陷检测等细粒度识别任务,全局池化无法捕获特征图中的关键信息,会导致识别精度出现瓶

颈。因此,在 SE 模块前面增加一个双池化层,将特征映射到平均池化和最大池化的并行结构中,对于输入的特征图,平均池化保留全局特征,最大池化保留局部突出的特征。为了避免通道注意力模块对空间注意力模块提取叶片缺陷特征造成影响,将两模块并行链接,获得更丰富的特征信息。本文将所提出的混合空间通道注意力机制加入到特征融合网络处,优化对海上风机叶片缺陷的检测性能。改进的注意力机制如图 4 所示。




图 4 改进后的注意力模块

Fig. 4 Improved attention module

改进的注意力模块原理如式(8)、(9)所示。

$$M_c = \sigma(W(\text{GAP}([\text{AP}(F_1); \text{MP}(F_1)]))) \quad (8)$$

$$M_s = \sigma(f^{7 \times 7}([\text{GAP}(F_1); \text{GMP}(F_1)])) \quad (9)$$

其中, GAP 和 GMP 分别为全局平均池化和全局最大池化, AP 和 MP 分别为全局平均池化和全局最大池化。 W 和 $f^{7 \times 7}$ 分别代表通道注意力机制中的全连接操作及空间注意力机制中的 7×7 卷积操作, σ 代表 sigmoid 激活函数。 M_c 和 M_s 分别代表空间和通道注意权重。最终的输出为:

$$F_2 = M_c \cdot F_1 + M_s \cdot F_1 \quad (10)$$

最终的神经网络结构如图 5 所示。




图 5 网络整体结构图

Fig. 5 The overall structure of the network

3 预测模块损失函数

目标检测任务中,网络预测模块的主要负责对象分类和定位任务,结构如图 6 所示。特征融合网络将不同尺度的特征信息分别输入到不同尺寸的检测模块中,经过卷积操作后,生成每个锚点的类别和边界框回归参数的信息。




图 6 预测模块结构

Fig. 6 The structure of the prediction module

其中, $H \times W$ 代表特征图大小, A 为特征图每个网格包含的锚点数量, n 为预测类别数。 $A \times n$ 表示每个网格各锚点的类别预测信息, $A \times 4$ 表示每个锚点的位置预测信息。在训练阶段, 预测模块解析出预测框参数信息后, 会计算生成的预测框和标注框的损失值, 最后进行梯度的反向传播并进行参数更新。

损失函数在目标检测算法中扮演着至关重要的角色, 它衡量了模型预测与实际标注之间的差异, 是算法优化的核心。然而模型训练过程中正、负图像样本的比例严重失衡, 许多简单的负样本主导了网络的优化过程, 导致模型对前景正样本目标学习不足, 召回率低, 模型性能不稳定。考虑到这个问题, 本文选择 Focal-EIOU 损失函数和 Focal Loss 损失函数计算预测框的位置损失和分类损失。

交并比(intersection over union, IOU)用于衡量预测边框与实际边框之间的差距, 为预测框与实际框交集面积与并集面积的比值。EIOU^[30] 损失函数以 IOU 为基础, 不仅考虑了预测框和实际框之间的距离, 还能够更精确的表述预测框宽高损失, 从而提高模型的收敛速度和回归精度。其具体形式如式(11)所示。

$$L_{EIOU} = L_{IOU} + L_{dis} + L_{asp} = L_{IOU} + \frac{\rho^2(b, b^{gt})}{(\omega^c)^2 + (h^c)^2} + \frac{\rho^2(b, b^{gt})}{(\omega^c)^2} + \frac{\rho^2(b, b^{gt})}{(h^c)^2} \quad (11)$$

其中, $L_{IOU} = 1 - IOU$ 、 L_{dis} 、 L_{asp} 分别表示 IOU 损失, 距离损失、宽高损失。 b 、 b^{gt} 分别表示预测框和实际框的中心点坐标, ρ 表示两者欧式距离, ω^c 、 h^c 表示预测框和真实框的最小外接矩形的宽高。考虑到训练过程中样本不均衡的问题, 引入可以控制抑制的程度参数 γ_b , 最终的 Focal-EIOU 公式如式(12)所示。

$$L_{Focal-EIOU} = IOU^{\gamma_b} L_{EIOU} \quad (12)$$

Focal Loss^[31] 同样通过引入权重系数解决正负样本不平衡问题, 计算分类损失, 降低易分类样本的权重, 使模型训练更加关注于困难样本, 原理如式(13)、(14)所示。

$$FL(p_i) = -\alpha_i (1 - p_i)^{\gamma_c} \log(p_i) \quad (13)$$

$$p_i = \begin{cases} p, & y = 1 \\ 1 - p, & \text{其他} \end{cases} \quad (14)$$

其中, y 表示目标实际类别, 值为 0 或 1, p 为目标预测类别, 值为 $[0, 1]$ 。Focal Loss 引入两个权重参数 α_i 、 γ_c , 用于控制正负样本及难易分类样本的权重。其中 α_i 用于控

制正负样本的权重, γ_c 用于控制难易分类样本的权重。Focal Loss 可以降低负样本对检测结果的影响, 还能够使模型更加关注较难分类样本, 提高模型的训练效果。

4 实验与分析

4.1 实验环境及评价指标

为了验证本文所提算法的有效性, 在自建的风机叶片缺陷图像数据集的基础上设计了消融实验, 并通过对比实验进一步评估算法性能。本实验平台的操作系统为 Windows10, CPU 为 AMD Ryzen 7 5800H 3.2 GHz, 内存 16 GB, 显卡为 NVIDIA GeForce RTX 3060 Laptop GPU, 显存 8 GB。本次实验使用 Anaconda 环境, 深度学习框架使用 Pytorch-GPU 2.0.1, 编程语言为 Python3.9, 训练过程中的参数设置如表 2 所示。

表 2 实验参数设置

Table 2 Experimental parameter settings

训练参数	数值
训练迭代次数	500
批次大小	4
初始学习率	0.01
动量系数	0.9
权重衰减系数	0.000 1

风机叶片数据集来源 Kaggle 官网数据集, 数据集共 1 704 张图像。将缺陷种类分为 3 种: 叶片涂层表面出现的不规则缺陷(coating), 如涂层脱漆、因盐雾空气造成的涂层表面腐蚀等; 对风机叶片结构影响较大的裂纹缺陷(crack); 运行过程中出现的脏污缺陷(dirt)。利用标注软件对数据集中的缺陷进行标注, 生成标注文件, 包含缺陷类别、预测框坐标信息, 选取 3 类典型缺陷, 标注效果如图 7 所示。将图像数据集按 8 : 1 : 1 的比例分为训练集、验证集和测试集。

目标检测模型的性能指标主要有准确率(precision, P)、召回率(recall, R)、平均精度(mean average precision, mAP), 评价模型推理速度的指标为 FPS, 代表每秒检测得的图片数量。各指标的计算原理如式(15)~(18)所示。

$$Precision = \frac{TP}{TP + FP} \quad (15)$$

$$Recall = \frac{TP}{TP + FN} \quad (16)$$

$$AP = \int_0^1 P(R) dR \quad (17)$$

$$mAP = \frac{1}{N} \sum_{i=0}^n AP_i \quad (18)$$

其中, TP 指预测为目标实际也为目标的数量, FP 表示预测为目标但实际被误检的数量, FN 代表缺陷未被检测出的目标数量, N 表示类别数量。准确率表示预测为真




图 7 3 类典型缺陷标注效果图

Fig. 7 Three typical defect labeling renderings

值的样本中实际为真值的比例,用于衡量模型精确性。召回率计算预测出来的真值占实际真值样本的比例。计算不




图 9 不同特征提取网络热力图对比

Fig. 9 Comparison of different feature extraction network heat maps

为验证所改进的特征提取网络对模型优化的能力,在 EfficientDet-D2^[33] 的基础上设计了消融实验,数据如表 3

同召回率下最高的精确率可绘制 $P-R$ 曲线,该曲线所围面积即为该类别的 AP 值,所有类别的 AP 值求均值即可得到 mAP 。

4.2 模型测试与分析

图 8 为训练过程中训练集和验证集的损失值收敛曲线,经过 500 个轮次的训练后,最终训练集和验证集的回归损失下降至 0.8 左右,分类损失下降至 0.5 左右,收敛效果较好。其中分类损失用于监督类别分类,回归用于监督检测框的回归,表示预测框与标定框之间的误差。




图 8 模型损失收敛曲线

Fig. 8 The loss convergence curve of the model

为了直观表示改进特征提取网络的有效性,本文选取不同的叶片缺陷图像,在相同实验环境下分别使用 ResNet50、EfficientNet-B2 替换特征提取网络并与本文算法对比,通过 Grad-CAM^[32] 算法生成热力图并作为评价指标。热力图中,特征提取时感兴趣的部位会使用较暖的颜色表示,而贡献不大的部位会使用较冷的颜色表示,表达网络对图像关注的区域。由图 9 可得,本文算法比基线模型更关注海上风机叶片表面的缺陷区域,可证明本文算法的有效性。

时得到的平均精度值, mAP_{50-95} 指交并比从 0.5 开始间隔 0.05 一直取值到 0.95 分别计算出平均精度值均值。对比实验 1 和实验 2 可知, 在骨干网络引入非对称卷积后, 增强了卷积核的骨架信息, 准确率和召回率有所提升, mAP_{50} 值增加了 2.2%。由实验 1 和实验 3 对比可知, 在特征融合模块引入混合注意力机制能够有效提升叶片表面缺陷的检测能力, mAP_{50} 值增加了 2.5%, 说明改进后的注意力机制通过聚合空间注意力和通道注意

力, 能够获得更丰富的特征信息, 进而提升对风机表面缺陷的检测能力。对比实验 4、6、7 可知, 单独对损失函数部分进行改进对算法整体提升效果并不明显, 与特征提取网络或特征融合网络改进部分结合才能发挥优势。由表 3 消融实验数据可知, 本文所提出的算法与基线算法对比有明显提升, 准确率和召回率分别提高了 3.9%、4.5%, mAP_{50} 值提高了 5.0%, 验证了本文所提策略的有效性。

表 3 消融实验结果对比
Table 3 Comparison of ablation experimental results

序号	骨干网络改进	特征融合改进	损失函数改进	$P/\%$	$R/\%$	$mAP_{50}/\%$	$mAP_{50-95}/\%$
1				92.8	89.1	92.6	75.9
2	✓			93.7	91.6	94.8	77.2
3		✓		94.3	91.2	95.1	77.4
4			✓	93.5	90.9	94.1	76.6
5	✓	✓		95.8	93.0	96.7	79.2
6	✓		✓	95.3	92.7	96.4	78.8
7		✓	✓	94.9	92.2	95.9	78.1
8	✓	✓	✓	96.7	93.6	97.6	80.0

注: ✓ 代表使用了该策略

4.3 对比试验

为了进一步验证算法的性能, 在相同配置及数据集的情况下, 比较了本文所提方法和其他主流目标检测算法如 Faster R-CNN、SSD 及 EfficientDet-D2 算法的表现, 实验结果如表 4 所示。图 10 为测试集上的部分检测效果对比图, 包含涂层缺陷 (coating)、裂纹缺陷 (crack)、脏污 (dirt) 3 种缺陷。从表 4 中可以看出, 与这些网络相比, 本文所提算法虽然检测速度没有达到最优, 但在检测精度上效果最

佳, 取得了最高的精确度和 mAP 值。

表 4 对比实验结果
Table 4 Results of comparative experiments

Model	$P/\%$	$R/\%$	$mAP_{50}/\%$	FPS
Faster R-CNN	88.7	84.1	86.3	11.4
SSD	86.2	83.9	85.4	39.7
EfficientDet-D2	92.8	89.1	92.6	71.8
本文算法	96.7	93.6	97.6	69.4




图 10 检测结果对比图
Fig. 10 Comparison of test results

从图 10 中对比发现 4 种模型都成功检测出 crack 缺陷,且取得了较高的置信度,这是由于 crack 目标相对于叶片颜色差异明显。coating 缺陷目标往往尺寸大小不一,对比第 2 张图片的检测结果能够发现 Faster R-CNN 和 SSD 对于尺寸较小的涂层缺陷检测效果较差,有许多漏检和误检的情况。dirt 缺陷往往出现在叶片前缘部位,脏污点分散且分布不均匀,因此标注范围较大。对比第 3 张图片的检测结果,Faster R-CNN 出现了 dirt 目标漏检的情况,SSD 算法和 EfficientDet-D2 算法虽然检测出了 dirt 目标,但预测框与实际缺陷位置偏差较大,置信度也较低。对比表 4 实验数据及图 10 的检测对比结果能够发现,本文所提出的算法对于小尺度缺陷检测的精度明显优于其他算法,如图 10(d)所示,不仅能够准确检测出缺陷的位置,还取得了较高的置信度,同时在速度和精度上达到了综合最优。

5 结 论

针对海上风机叶片早期缺陷目标检测时缺陷尺寸小、检测精度低、检测速度慢导致缺陷检测效率低下的问题,本研究设计了一种基于 EfficientNet 的改进缺陷检测算法。首先采用 EfficientNet 作为特征提取网络,引入非对称卷积替换 EfficientNet 中的 3×3 卷积,能够有效提升特征提取网络对小目标缺陷特征的提取能力,提高风机叶片早期缺陷的检测精度;提出一种混合空间通道注意力机制,加入到 BiFPN 特征融合网络处,优化对海上风机叶片缺陷的检测性能;损失函数部分,选择 Focal-EIOU 损失函数和 Focal Loss 损失函数计算预测框的位置损失和分类损失,不仅可以降低负样本对检测结果的影响,还能够使模型更加关注较难分类样本,提高模型的训练效果。

实验表明,本研究所提出的一种海上风机叶片早期缺陷检测算法能够有效提升缺陷识别的精度和速度,同时降低模型的参数量,减少计算成本,与其他主流算法相比具有更好的表现。未来将在该模型基础上继续研究改进网络模型,考虑海上复杂环境的情况下提高对叶片缺陷的检测能力。

参考文献

- [1] 崔峰波,蒋斌兵,冉文华,等. 风能玻璃钢产品耐盐雾腐蚀性能研究[J]. 玻璃纤维, 2022(4): 26-30.
- [2] 陈煌,靳交通,李诚亮,等. 海上风电叶片前缘雨蚀防护材料研究[J]. 船舶工程, 2020, 42(1): 558-559, 563.
- [3] 史凯特,李雨欣,任正奎,等. 基于多尺度局部对比度的海上风电风机叶片异常点检测[J]. 电工技术, 2023(12): 84-87.
- [4] 时伟. 海上风机叶片缺陷检测及分类[D]. 哈尔滨: 哈尔滨理工大学, 2023.
- [5] GAO R X, MA Y F, WANG T F. Early stage damage detection of wind turbine blades based on UAV images and deep learning [J]. Journal of Renewable and Sustainable Energy, 2023, 15 (4). DOI: 10.1063/5.0157624.
- [6] 汤占军,史小兵,肖遥,等. 基于深度学习模型的风机叶片结冰故障诊断[J]. 噪声与振动控制, 2023, 43(4): 96-103.
- [7] 张朋,张玉,崔锟,等. 基于修正热弹性应力分析的风机叶片热红外温度检测[J]. 激光与光电子学进展, 2023, 60(15): 211-218.
- [8] 张晨辉. 基于空时联合处理与深度学习的风机叶片故障声学检测[D]. 杭州: 浙江大学, 2023.
- [9] 王洪金,杜旭,赵丽劫,等. 引入人员反馈的风机叶片红外缺陷测量技术[J]. 中国测试, 2024, 50(1): 32-38.
- [10] 郑浩,周丽婷,王湘明,等. 电磁超声检测风机叶片缺陷的有限元仿真研究[J]. 电子测量技术, 2021, 44(23): 84-87.

- 24-29.
- ZHENG H, ZHOU L T, WANG X M, et al. Finite element simulation study on electromagnetic ultrasonic detection of wind turbine blade [J]. *Electronic Measurement Technology*, 2021, 44(23):24-29.
- [11] 何赟泽,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.
- [12] 刘传洋,吴一全,刘景景. 基于视觉的输电线路金具锈蚀缺陷检测方法研究进展[J]. *仪器仪表学报*, 2024, 45(3):286-305.
- LIU CH Y, WU Y Q, LIU J J. Research progress of vision-based rust defect detection methods for metal fittings in transmission lines[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(3):286-305.
- [13] GIRSHICK R. Fast R-CNN[C]. *IEEE International Conference on Computer Vision (ICCV)*, 2015: 1440-1448.
- [14] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6):1137-1149.
- [15] 唐心亮,刘子剑,于平平. 面向多尺度多方向螺栓的检测算法[J]. *电子测量与仪器学报*, 2023, 37(10): 221-231.
- TANG X L, LIU Z J, YU P P. Detection algorithm for multi-scale and multi-directional bolts[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(10):221-231.
- [16] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2016:779-788.
- [17] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. *Computer Vision-ECCV 2016*, 2016:21-37.
- [18] 刘琼,史诺. 基于改进 YOLOv5 的飞机蒙皮表面缺陷检测方法[J]. *国外电子测量技术*, 2023, 42(12):1-7.
- LIU Q, SHI N. Aircraft skin surface defect detection based on improved YOLOv5 [J]. *Foreign Electronic Measurement Technology*, 2023, 42(12):1-7.
- [19] 贾君霞,史珂鑫. 改进型 SSD 道路行人目标检测算法[J]. *国外电子测量技术*, 2022, 41(12):26-32.
- JIA J X, SHI K X. Modified SSD road pedestrian target detection algorithm [J]. *Foreign Electronic Measurement Technology*, 2022, 41(12):26-32.
- [20] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6):84-90.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. *Computer Vision and Pattern Recognition*, 2014.
- [22] HE K M, ZHANG X Y, REN SH Q. Deep residual learning for image recognition [C]. *2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2016:770-778.
- [23] TAN M X, LE Q V. Rethinking model scaling for convolutional neural networks [J]. *ArXiv preprint arXiv:1905.11946*, 2019.
- [24] DING X H, GUO Y CH, DING G G, et al. ACNet: Strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks [J]. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019: 1911-1920. DOI: 10.1109/ICCV.2019.00200.
- [25] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2017:936-944.
- [26] LIU SH, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018:8759-8768.
- [27] GHIASI G, LIN T Y, LE Q V. NAS-FPN: Learning scalable feature pyramid architecture for object detection[C]. *IEEE/CVF Conference on Computer Vision and Pattern 2019 Recognition(CVPR)*, 2019: 7029-7038.
- [28] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and efficient object detection[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR)*, 2020:10781-10790.
- [29] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2018:7132-7141.

[30] TIAN Y J, SU D, LAURIA S, et al. Recent advances on loss functions in deep learning for computer vision[J]. Neurocomputing, 2022, 497:129-158.

[31] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]. IEEE International Conference on Computer Vision, 2017:2980-2988.

[32] WANG J W, XU CH, YANG W, et al. A normalized Gaussian wasserstein distance for tiny object detection [EB/OL]. (2022-06-14)[2024-07-31]. <https://arxiv.org/abs/2110.13389>.

[33] 辛彦, 吴国新, 左云波. 基于 EfficientDet 的风机叶片缺陷检测方法[J]. 电子测量技术, 2022, 45(5):124-131.

XIN Y, WU G X, ZUO Y B. Defect detection method of wind turbine blade based on EfficientDet [J]. Electronic Measurement Technology, 2022, 45(5):

124-131.

作者简介

付军军(通信作者), 硕士研究生, 主要研究方向为智能电网运维和图像处理。

E-mail:1947208670@qq.com

陈林, 硕士研究生, 主要研究方向为电网调控与运行。

E-mail:864882864@qq.com

童华敏, 硕士研究生, 主要研究方向为电网调控与运行。

E-mail:1824557854@qq.com

舒征宇, 博士, 副教授, 主要研究方向为电力系统保护与控制、电力系统运行与调度控制等。

E-mail:2946595258@qq.com

王灿, 博士, 副教授, 主要研究方向为新能源发电、微电网协调控制与优化运行、综合能源系统运行等。

E-mail:2115231241@qq.com