

DOI:10.19651/j.cnki.emt.2108468

基于 EfficientDet 的风机叶片缺陷检测方法 *

辛彦 吴国新 左云波

(北京信息科技大学现代测控技术教育部重点实验室 北京 100192)

摘要:受工作环境恶劣等原因影响,风机叶片常会出现裂纹、凹坑等缺陷。针对当前常用目标检测算法对风机叶片小尺寸缺陷检测准确率低的问题,提出一种基于 EfficientDet 算法的风机叶片缺陷检测方法。首先采集图像数据并建立 Pascal VOC 格式的风机叶片缺陷图像数据集,然后对 EfficientDet 算法中的主干特征提取网络进行改进,减少向下采样次数并调整有效特征层从而增强主干特征提取网络对小尺寸缺陷的检测能力,同时为特征融合网络增加融合路径提升算法的多尺度特征融合能力,选用 FReLU 作为激活函数实现像素级空间信息建模,并通过 Mosaic 数据增强和 Focal Loss 损失函数增加小尺寸缺陷样本对于检测器的贡献。在建立的风机叶片缺陷图像数据集上的测试结果表明改进后的算法模型平均类别精度达到了 96.15%,相较于原版的 EfficientDet 提升了 3.77%,对小目标的检测性能有明显提升。

关键词:深度学习;目标检测;EfficientDet;图像处理;风机叶片

中图分类号: TP391.41; TN957.52 文献标识码: A 国家标准学科分类代码: 510.4050

Defect detection method of wind turbine blade based on EfficientDet

Xin Yan Wu Guoxin Zuo Yunbo

(The Ministry of Education Key Laboratory of Modern Measurement and Control Technology, Beijing Information Science & Technology University, Beijing 100192, China)

Abstract: Affected by the poor working environment and other reasons, the fan blades often have defects such as cracks and pits. Aiming at the low accuracy of the current common target detection algorithms for the detection of small-size defects of the fan blades, a fan blade defect detection method based on the EfficientDet algorithm is proposed. First collect image data and establish a wind turbine blade defect image data set in Pascal VOC format, and then improve the backbone feature extraction network in the EfficientDet algorithm to reduce the number of downsampling and adjust the effective feature layer to enhance the backbone feature extraction network for small-size defects detection capability. At the same time, the multi-scale feature fusion capability of the fusion path enhancement algorithm is added to the feature fusion network. The algorithm uses FReLU as the activation function to achieve pixel-level spatial information modeling, and uses Mosaic data enhancement and Focal Loss loss function to increase small-size defect samples for Contribution of the detector. The test results on the established defect image data set of fan blades show that the improved algorithm model has an average category accuracy of 96.15%, which is 3.77% higher than the original EfficientDet, and the detection performance of small targets has been significantly improved.

Keywords: deep learning; object detection; EfficientDet; image processing; wind turbine blade

0 引言

风能具有储量大、分布广、可再生等优势,风力发电逐渐成为了最具开发规模和发展前景的发电方式之一^[1]。但由于叶片加工、安装过程中的损伤以及工作环境恶劣等原因,叶片常会出现裂纹、凹坑等缺陷,这些缺陷会降低风机

的风能转化率和机组寿命^[2]。目前风场对叶片缺陷检测主要依靠望远镜观察,这种人工判读的方式主观性大、检测效率低,不利于叶片健康状态客观检测与评估。

过去几年间,随着深度学习理论发展和硬件设备算力提升,许多目标检测算法被提出并在公共数据集上得到验证。目前主流的目标检测算法按照设计原理可以分为双阶

收稿日期:2021-11-29

* 基金项目:国家重点研发计划(2020YFB1713200)、北京市教委科研计划(KM202011232001)项目资助

段目标检测算法和单阶段目标检测算法两类。前者先为特征图中的检测点生成一系列候选框再通过卷积神经网络对样本进行分类,常见算法包括如 Fast R-CNN^[3]、Faster-RCNN^[4];后者直接通过神经网络提取特征并预测物体种类,常见的包括 YOLOv4^[5]、SSD^[6]、EfficientDet^[7]等。上述算法的提出和应用为风机叶片的缺陷检测提供了新的思路,但由于叶片缺陷中的凹坑、裂纹缺陷尺寸往往较小,常规目标检测器常出现漏检情况。

本文针对常规目标检测算法对于风机叶片小尺寸缺陷检测精度低的问题,结合深度学习和计算机视觉技术提出了基于 EfficientDet 的风机叶片缺陷检测算法,建立风机叶片缺陷图像数据集并对算法进行实验验证分析。

1 数据采集与离线增强

本文构建了 VOC 格式的风机叶片缺陷图像数据集,数据集来源于团队在河北某风场采集的风机叶片图像数据。数据集共 420 张图片,包含存在缺陷的风机叶片图像的正样本和正常风机叶片的负样本两种数据,缺陷的形式为裂纹、凹坑、油污共 3 种。

采集的图像分辨率为 3 000 pixel×4 000 pixel,制作数据集时将裂纹、凹坑、油污缺陷的数量进行平衡,使得不同类别的样本数量接近。

通过 LabelImg 标注工具对图像进行 Pascal VOC 格式数据集标注,每一张图片都精确标注缺陷目标的缺陷类别和具体位置,标注效果如图 1 所示。标注后的数据集中共包含裂纹缺陷 116 处、凹坑缺陷 102 处、油污缺陷 110 处。

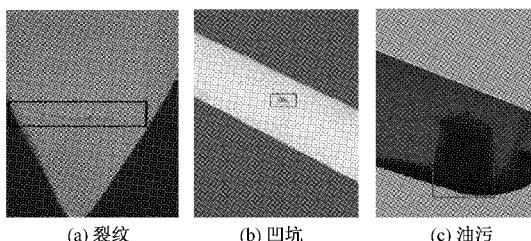


图 1 标注效果图

针对数据集样本较少会导致过拟合的问题,对数据集进行了数据增强包括翻转、缩放、多种滤波操作和色域变换,利用有限的数据产生更多价值,提高训练效果。经过扩充后得到最终数据集中共包含裂纹缺陷 1 160 处、凹坑缺陷 1 020 处、油污缺陷 1 100 处。缺陷的平均宽高为 194 pixel 和 179 pixel,平均面积占原图面积 0.289 4%,多属于小尺寸缺陷,具体缺陷尺寸分布如图 2 所示。

2 算法

EfficientDet 单级目标检测器参数数量少、计算效率高、准确率高,在有限资源范围内达到了 SOTA,是当前最佳的目标检测算法。EfficientDet 可分成 D0~D7 共 8 个版

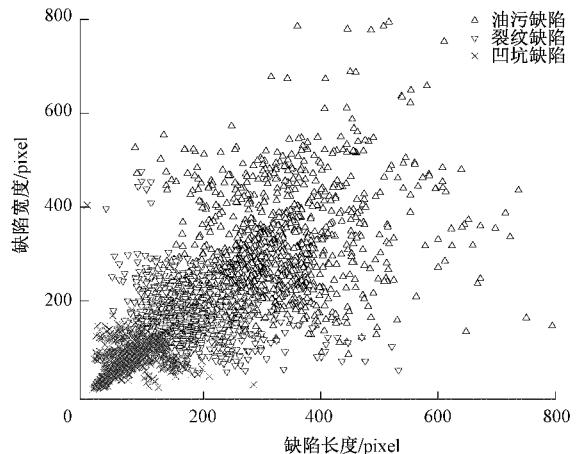


图 2 缺陷尺寸分布散点图

本,分别与 EfficientNet 的 B0~B7 的 8 个版本对应,不同版本的 EfficientDet 检测能力不同,对计算资源的要求也不同。为了在准确性和计算资源消耗方面实现适当平衡,本文选择对 GPU 要求相对较低的 EfficientDet-D2 版本作为基础模型,并对其进行改进,实现了风机叶片小尺寸缺陷的有效检测。

算法总体流程如下:

1) 选用改进的 EfficientNet-B2 作为主干特征提取网络进行初步特征提取,得到向下采样 1~5 次的 5 个特征层 {P1、P2、P3、P4、P5}。

2) 串联改进的 BiFPN 使多个特征层进行自上而下和自下而上的双向多尺度特征融合,得到 5 个有效特征层。

3) 将融合后得到的 5 个有效特征层传入 EfficientHead 中的 Class Prediction Net 和 Box Prediction Net,实现对先验框分类并对先验框位置进行调整得到预测框。

改进后的 EfficientDet 算法网络架构如图 3 所示。

2.1 适用于小尺寸缺陷的 EfficientNet

小尺寸目标经过多次卷积之后特征容易消失,因此越深的特征层越适合大目标的检测,越浅的特征层越适合小目标的检测^[8]。风机叶片缺陷图像数据集中的裂纹缺陷和凹坑缺陷多是相对尺寸小于 0.12% 的小尺寸缺陷,而 EfficientNet 特征提取网络的 7 次向下采样会损失很多对于风机叶片缺陷检测的有效信息,导致小尺寸缺陷无法被分类和定位。

为了增强 EfficientNet 主干特征提取网络对于小目标特征的提取能力和目标检测算法对小尺寸缺陷的检测能力,本文将 EfficientNet 中负责高语义信息提取的 P6 和 P7 两个特征层删减,并用提取低语义信息能力更强的 P1 和 P2 两个特征层代替 P6、P7 特征层,使主干特征提取网络对于低语义信息更为敏感,以降低网络提取高语义信息能力为代价增强其对于裂纹、凹坑此类小尺寸缺陷的检测能力。以一处 128 pixel×128 pixel 的小尺寸缺陷目标举例,经过原始版本 EfficientNet 特征提取后在输出的 5 个特征层尺

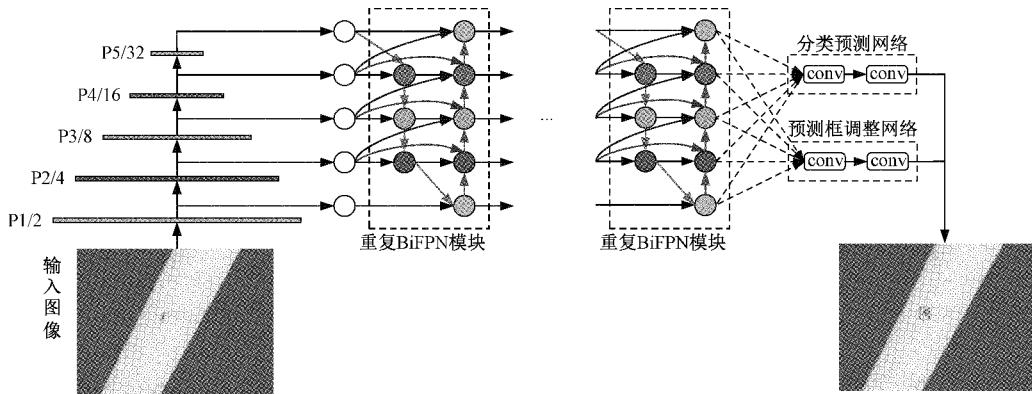


图3 改进的 EfficientDet 算法架构图

寸分别是 $16 \text{ pixel} \times 16 \text{ pixel}$ 、 $8 \text{ pixel} \times 8 \text{ pixel}$ 、 $4 \text{ pixel} \times 4 \text{ pixel}$ 、 $2 \text{ pixel} \times 2 \text{ pixel}$ 、 $1 \text{ pixel} \times 1 \text{ pixel}$, 很难提取到有效信息。经过改进后的 EfficientNet 网络进行特征提取后得到的尺寸则为 $64 \text{ pixel} \times 64 \text{ pixel}$ 、 $32 \text{ pixel} \times 32 \text{ pixel}$ 、

$16 \text{ pixel} \times 16 \text{ pixel}$ 、 $8 \text{ pixel} \times 8 \text{ pixel}$ 、 $4 \text{ pixel} \times 4 \text{ pixel}$, 相对保留了更多信息。

改进的 EfficientNet 由 1 个 Stem 和 16 个 Efficient Block 模块组成, 其结构和具体参数如表 1 所示。

表1 EfficientNet 结构和参数

模块\具体参数	卷积核尺寸	输入通道数	输出通道数	步长	重复次数	输出尺寸	输出特征层
Stem				2	1	$256 \times 256 \times 32$	
Efficient Block	3×3	32	16	1	1	$256 \times 256 \times 16$	P1
Efficient Block	3×3	16	24	2	2	$128 \times 128 \times 24$	P2
Efficient Block	5×5	24	40	2	2	$64 \times 64 \times 40$	P3
Efficient Block	3×3	40	80	2	3	$32 \times 32 \times 80$	
Efficient Block	5×5	80	112	1	3	$32 \times 32 \times 112$	P4
Efficient Block	5×5	112	192	2	4	$16 \times 16 \times 192$	
Efficient Block	3×3	192	320	1	1	$16 \times 16 \times 320$	P5

EfficientBlock 具体实现过程如下:

- 1) 输入 $512 \times 512 \times 3$ 的图像并通过 1×1 卷积升维。
- 2) 通过 3×3 或 5×5 的深度可分离卷积核进行深度可分离卷积。
- 3) 先进行全局平均池化, 然后通过一个通道数较小的卷积压缩特征, 再通过一个通道数较大的卷积扩张特征, 最后将这两个卷积后的结果和原始的特征层相乘, 完成通道注意力的施加。
- 4) 通过 1×1 卷积进行降维并将降维后的结果与大残差边进行组合, 得到输出结果, 完成 EfficientBlock 模块的构建。

具体实现如图 4 所示。在得到 P1~P5 特征层后将其作为 EfficientNet 主干特征提取网络的输出, 输入到 BiFPN 网络中进行特征融合, 从而进一步利用 P1~P5 共 5 个特征层的中低语义有效信息。

2.2 改进的 BiFPN

目标检测主要难点之一是对多尺度特征进行有效表示和处理。为解决此问题, 近年来出现了 FPN^[9]、PANet^[10] 和 NAS-FPN^[11] 等跨尺度特征融合的网络结构。

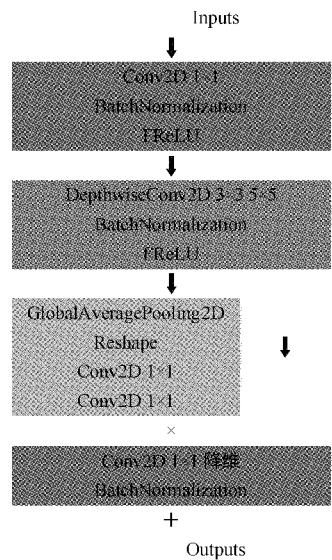


图4 EfficientBlock 实现流程

本文选用 BiFPN 作为加强特征提取网络并对其进行改进使之更适合小尺寸缺陷检测工作。

改进的 BiFPN 是一个加强版的 FPN,与普通的 FPN 相比,首先它去掉了对融合不同层级特征贡献较小的只有一条输入边的节点,然后将处于同一层的原始输入和输出增加一条额外的边、将处于上下两层的原始输入和输出增加一条额外的边分别相连接,最后重复每条自顶向下和自底向上的双向路径实现更高级别的特征融合。同时还设置了通道注意力机制来平衡不同特征层的权重,此前的特征融合方法都一视同仁地对待所有的输入特征,但是不同的输入特征在不同的分辨率下对于输出特征的贡献是不同的,为此 BiFPN 为每个输入添加了一个权重,让网络判断不同输入的重要性。同时为了提高效率,BiFPN 还使用了深度可分离卷积进行特征融合,并在每次卷积后加入了批处理归一化和激活函数处理,增强 BiFPN 融合低语义信息的能力,改进后的 BiFPN 结构如图 5 所示。

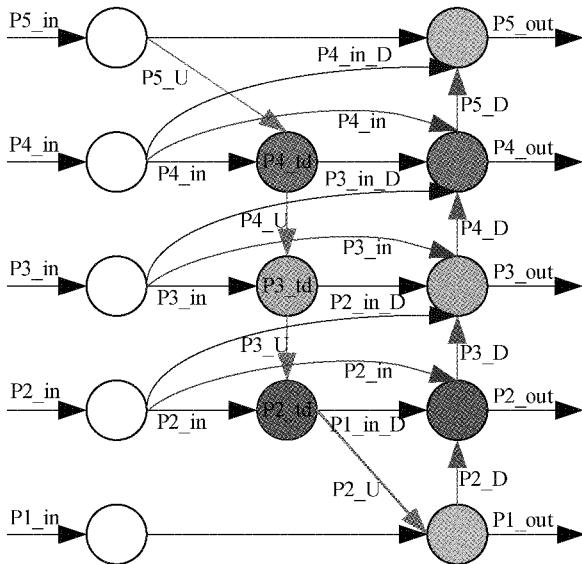


图 5 改进后的 BiFPN 网络

最终 BiFPN 通过双向跨尺度连接和快速归一化融合实现了不同尺度特征融合并且平衡了不同尺度的特征信息。作为一个具体例子,如式(1)、(2)所示是第 4 级特征融合公式。

$$\mathbf{P}_4^{id} = \text{Conv} \left(\frac{\omega_1 \cdot \mathbf{P}_4^{in} + \omega_2 \cdot \text{Resize}(\mathbf{P}_5^{in})}{\omega_1 + \omega_2 + \epsilon} \right) \quad (1)$$

$$\mathbf{P}_4^{out} = \text{Conv} \left(\frac{\omega'_1 \cdot \mathbf{P}_4^{in} + \omega'_2 \cdot \mathbf{P}_4^{id} - \omega'_3 \cdot \text{Resize}(\mathbf{P}_3^{out}) - \omega'_4 \cdot \text{Resize}(\mathbf{P}_3^{in})}{\omega'_1 + \omega'_2 - \omega'_3 + \omega'_4 + \epsilon} \right) \quad (2)$$

其中, \mathbf{P}_4^{id} 是由顶向下路径上第 4 级的中间特征, \mathbf{P}_4^{out} 是第 4 级的输出特征。

2.3 Mosaic 数据增强

常见数据增强方法有 Mixup^[12]、Cutout^[13]、CutMix^[14] 等。其中 CutMix 数据增强先随机将样本中的部分区域剪裁掉,然后随机填充训练数据集中其他数据的区域像素

值,分类的结果按照比例进行分配。

本文采用的 Mosaic 数据增强参考 CutMix 数据增强,在理论上类似,但是 Mosaic 数据增强利用 4 张图片进行随机填充。在实际使用过程中,首先从总图像数据集中取出一个 batch 的数据,每次从中随机选出 4 张图片进行随机位置的剪裁、缩放、色域变化后重新拼接为一张新图片,将这个操作重复 batch size 次后得到 batch size 张经过 Mosaic 数据增强的图片,最终将 Mosaic 数据增强后的数据输入神经网络完成在线数据增强。Mosaic 数据增强的巨大优势在于随机缩放为数据集增加了非常小尺寸缺陷,让网络对于风机叶片中小尺寸缺陷的检测性能更好,并且对 4 张图片进行拼接间接的提高了 batch size,在进行 batch normalization 时也会同时计算 4 张图片,一个 GPU 就可以达到比较好的训练效果。考虑到数据集中已就有很多的小目标,经过 Mosaic 数据增强会使小目标变得更小,从而导致模型的泛化能力变差,因此先对数据集中的缺陷目标进行筛选,如果相对尺寸小于 0.12%,则不对其进行 Mosaic 数据增强。增强后的图像如图 6 所示。

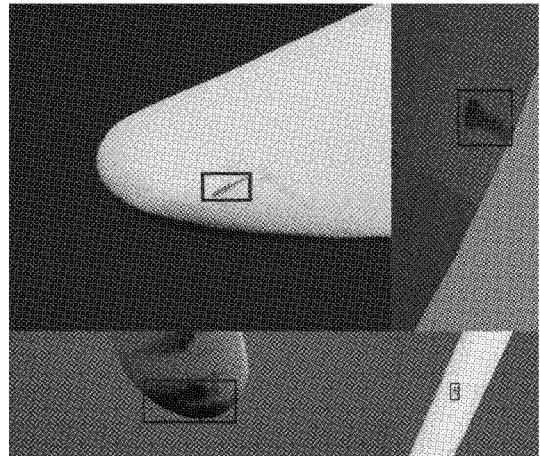


图 6 Mosaic 数据增强后的图片

2.4 激活函数选择和 Loss 计算

1) FReLU 激活函数

算法选用 FReLU^[15] 作为激活函数,能够实现像素级空间信息建模。其在目标检测、语义分割、目标识别任务上的表现优于 ReLU、PReLU^[16]、Swish^[17] 等激活函数,且具有较强迁移能力。

在卷积层添加复杂模块来提升算法对于小尺寸缺陷的检测能力往往会对检测速度造成较大影响,为此本文使用 FReLU 激活函数进行非线性补充。FReLU 激活函数对每个像素提取周边信息后进行加权求和,仅通过添加较少的空间条件就可将 ReLU 和 PReLU 扩展为二维激活函数,从而实现简单高效的空间上下文特征提取。FReLU 的工作原理如图 7 所示。

相较于传统 ReLU 激活函数,FReLU 将条件部分更换为了漏斗条件 $T(x)$,利用 $\max(\cdot)$ 操作获得 x 和条件

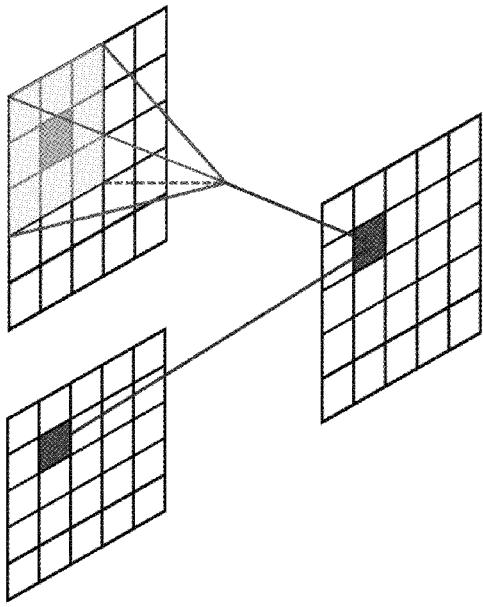


图 7 FReLU 工作原理

之间的最大值,具体来说,如式(3)、(4)所示,FReLU 的定义为:

$$f(x_{c,i,j}) = \max(x_{c,i,j}, T(x_{c,i,j})) \quad (3)$$

$$T(x_{c,i,j}) = x_{c,i,j}^{\omega} \cdot p_c^{\omega} \quad (4)$$

式中: $x_{c,i,j}$ 表示以二维空间位置 (i,j) 上第 c 个通道的非线性激活函数 $f(\cdot)$ 的输入像素为中心的参数池化窗口; 函数 $T(\cdot)$ 表示漏斗条件; p_c^{ω} 表示此窗口上在同一通道中共享的系数。

2) Loss 计算

算法 Loss 分为 Focal Loss^[18] 和 Smooth L1 Loss 两部分。Smooth L1 Loss 获取所有正标签的框的预测结果的回归 Loss, Focal Loss 获取所有未被忽略的种类的预测结果的交叉熵 Loss。为了保证在目标检测中预测框和 ground truth 差别过大时梯度值不至于过大、预测框与 ground truth 差别很小时又能满足梯度值足够小,本文选择 Smooth L1 Loss 作为回归 Loss, 式(5)为其具体形式。

$$\text{Smooth}_{L1}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & \text{其他} \end{cases} \quad (5)$$

式(6)中 Smooth L1 Loss 对 x 的导数:

$$\frac{d\text{Smooth}_{L1}}{dx} = \begin{cases} x, & |x| < 1 \\ \pm 1, & \text{其他} \end{cases} \quad (6)$$

由式(6)可知 Smooth L1 Loss 在 x 较小时,对 x 的梯度也会变小;而在 x 很大时,对 x 的梯度的绝对值会到达上限 1,并不会太大以至于破坏网络参数。

一张图像输入网络后会产生众多的候选框,但是其中只有很少一部分包含有目标,因此存在目标的正样本数量往往远小于没有目标的负样本数量。同时对于本文目标检测器来说,油污缺陷属于易于被识别和分类的简单样本,而裂纹、凹坑则属于难以被分类的困难样本,他们对于

模型的优化能力是不同的。Focal Loss 降低了大量简单负样本在训练中所占的权重解决了单级目标检测器中正负样本比例失衡的问题。它通过两个主要特点:1)控制正负样本权重;2)控制容易分类和难分类的样本的权重。其具体公式如式(7)~(9)所示。

$$FL(p_t) = -(1-p_t)^{\gamma} \log(p_t) \quad (7)$$

其中,

$$p_t = \begin{cases} p, & x = 1 \\ 1-p, & \text{其他} \end{cases} \quad (8)$$

$$L_{focal}(x) = \begin{cases} -(1-x')^{\gamma} \log x', & x = 1 \\ -x'^{\gamma} \log(1-x'), & x = 0 \end{cases} \quad (9)$$

3 实验与结果分析

为了对本文算法的性能进行评估,本文设计了对比试验进行验证,并通过消融实验对算法中的改进部分进行了有效性分析。测试数据集选用自建风机叶片缺陷图像数据集。训练基于 TensorFlow2 框架,计算机操作系统为 64 位 Windows10,内存 16 G 3 200 MHz,处理器为 Intel(R) Core(TM) i7-10870H CPU @ 2.20 GHz,显卡为一块 NVIDIA RTX 3070 Laptop 显存 8 G。训练参数方面,Batch size 设置为 4,初始学习率设置为 0.001,当迭代次数达到 2 000 和 5 000 次时,分别将学习率降低为 0.000 1 和 0.000 01,实现进一步收敛。算法训练过程中的损失值的收敛曲线如图 8 所示。

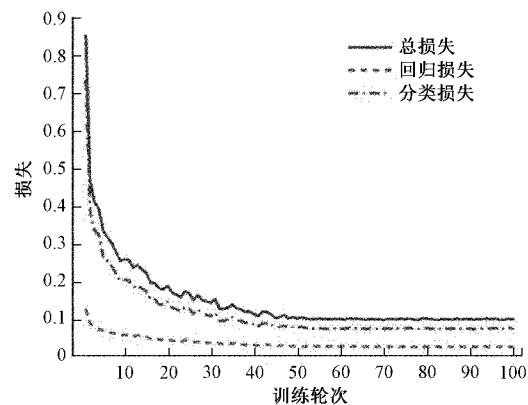


图 8 损失收敛曲线

经过 50 个 Epoch 的迭代后,各项参数区域稳定,最终的 Regression Loss 下降至 0.02 左右、Classification Loss 下降至 0.06 左右、Total Loss 下降至 0.08 左右。从收敛情况分析可知改进后的 EfficientDet 算法的训练结果较为理想。

3.1 算法评价指标

目标检测网络常用的评价指标包括精度(precision)、召回率(recall)、平均精确率(average precision, AP)、平均精确率均值(mean average precision, mAP)等。其中 mAP 被认为是目标检测领域对算法进行评价的最重要指标,因

此本文选用 mAP 作为评价指标。

召回率表示分类器认为是正样本并且确实是正样本的部分占所有正样本的比例,计算公式如式(10)所示。

$$R = \frac{X_{TP}}{X_{TP} + X_{FN}} \quad (10)$$

精度表示分类器认为是正样本并且确实是正样本的部分占分类器认为是正样本的比例,计算公式如式(11)所示。

$$P = \frac{X_{TP}}{X_{TP} + X_{FP}} \quad (11)$$

式中: X_{TP} 表示被正确分类的正样本数; X_{FN} 表示被错误分类的正样本数; X_{FP} 为被错误分类的负样本数。

AP 指某一类别 P-R 曲线下的面积,用来衡量该类别的平均分类精确率,计算公式如式(12)所示。

$$AP = \int_0^1 P(R) dt \quad (12)$$

mAP 指多个类别的 AP 值的均值,用来衡量分类器对所有类别的分类精度,计算公式如式(13)所示。

$$mAP = \frac{\sum_{n=0}^N AP_n}{N} \quad (13)$$

3.2 结果与分析

1) 消融实验

改进后的 EfficientDet 目标检测算法主要通过调整 EfficientNet 主干特征提取网络输出的特征层、增加 BiFPN 通道路径和 Mosaic 数据增强来提升算法对于小目标缺陷的检测能力,为了评估这些改进对于算法性能的提升效果,开展如表 2 所示的消融实验。

表 2 消融实验结果比较

组成\算法名	算法 1	算法 2	算法 3	算法 4	算法 5	EfficientDet-D2
Modified-EfficientNet	✓	✓	✓		✓	
Modified-BiFPN	✓	✓		✓		
Mosaic 数据增强	✓		✓	✓		
Stain AP/%	100	100	100	100	100	100
Crack AP/%	96.77	94.51	96.01	94.11	94.23	91.35
Pit AP/%	91.87	88.95	91.23	87.22	88.17	85.79
mAP/%	96.15	94.48	95.74	93.77	94.13	92.38

可以看到原版的 EfficientDet-D2 对于油污缺陷此类中型尺寸缺陷检测能力强,对于裂纹缺陷和凹坑缺陷此类小尺寸缺陷的检测能力稍弱。算法 5 在其他参数不变只修改 EfficientNet 网络向下采样次数的情况下,对于裂纹缺陷和凹坑缺陷的 AP 指标分别上升了 2.85% 和 2.38%,说明融合浅特征层提取的低语义特征对于提升 EfficientDet 算法的小目标检测能力有明显作用;在同时改进 EfficientNet 和 BiFPN 网络的情况下,算法 2 相较于仅改善向下采样次数的算法 5 的裂纹缺陷和凹坑缺陷的 AP 指标只上升了 0.28% 和 0.78%,说明添加新的 BiFPN 网络通道路径对于融合不同层级之间特征的能力提升有限,也不能大幅提升算法对于小目标缺陷的检测能力。算法 2 基础上添加了 Mosaic 数据增强的算法一在裂纹缺陷和凹坑缺陷的 AP 指标分别上升了 2.26% 和 2.92%,说明经过

Mosaic 数据增强后数据中增加了大量的小尺寸缺陷使得算法对于小目标缺陷检测能力有明显提升。值得一提的是,虽然同时进行了 BiFPN 网络通道路径的改进和 Mosaic 数据增强,但是算法 4 检测能力提升却并不明显,说明只有调整 EfficientNet 下采样次数和 Mosaic 数据增强同时使用时才能让 Mosaic 数据增强的优势得以发挥。

2) 对比试验

为了更好地评估改进后 EfficientDet 算法的性能,本文进行了一组对比实验,实验对比了 4 个当前主流的目标检测模型,包括 Faster R-CNN、YOLOv4、SSD 和 EfficientDet-D2,训练和测试过程均使用同一实验平台。表 3 为实验结果对比,图 9 为检测效果对比图。综合对比发现,虽然本文在检测速度不是最优,但是在检测精度上获得了最佳成绩,特别是小尺寸缺陷的检测性能大幅优于其他算法。

表 3 不同算法目标检测结果的对比

模型	本文算法	Faster R-CNN	YOLOv4	SSD	EfficientDet-D2
Stain AP/%	100	35.44	100	32.88	100
Crack AP/%	96.77	11.25	90.26	16.29	91.35
Pit AP/%	91.87	0	83.22	5.08	85.79
mAP/%	96.15	15.56	91.16	18.08	92.38
FPS/(f·s ⁻¹)	25	11	62	48	24
训练时间/(s·Epoch ⁻¹)	40	159	65	47	43

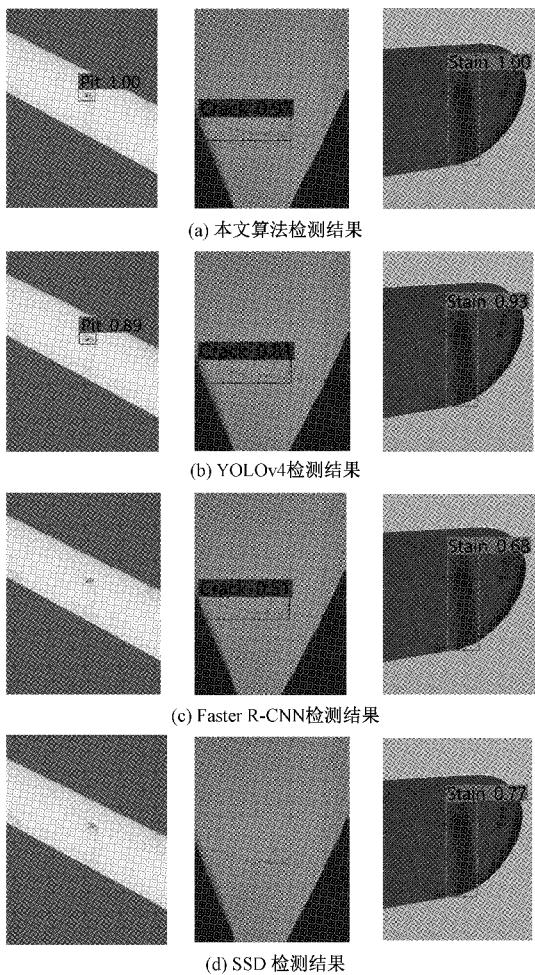


图9 各目标检测算法检测效果图

作为当前精度最高的目标检测算法, EfficientDet 已经实现了 SOTA, 实验中可以看出, 原版的 EfficientDet-D2 相比于双阶段目标检测器 Faster R-CNN 和单阶段目标检测器 SSD 有大幅提升, 尤其是在小尺寸缺陷上的表现。Faster R-CNN 和 SSD 对于裂纹缺陷和凹坑缺陷的小尺寸目标的检测能力很差, 基本无法识别到图像中的小尺寸缺陷。YOLOv4 算法虽然在中等尺寸缺陷上的检测能力优秀, 但是在小尺寸缺陷上的表现仍然不如原版 EfficientDet-D2, 而本文算法利用改进主干特征提取网络和特征融合网络实现了进一步提升, 在中等尺寸缺陷检测能力不发生下降、小幅牺牲训练时间和检测速度的条件下相较于 YOLOv4 算法的裂纹缺陷和凹坑缺陷的 AP 指标分别上升了 6.51% 和 8.65%。

4 结 论

本文基于 EfficientDet 目标检测算法针对风机叶片小尺寸缺陷进行改进。首先调整 EfficientNet 主干特征提取网络下采样次数和输出特征层, 更加有效的利用了图像中精细的低语义信息。然后为 BiFPN 添加新的融合路径增

强算法的特征融合能力, 对多尺度特征进行了有效表示和处理。选用 FReLU 为激活函数完成像素级空间信息建模, 使用 Mosaic 数据增强方法增加了数据集中小尺寸缺陷的数量, 使小尺寸缺陷对算法的贡献上升。最后通过 Focal Loss 控制正负样本权重和易分类与难分类样本权重, 解决算法中样本失衡的问题。实验结果表明, 改进后的 EfficientDet 算法检测效果优秀, 相较于原版 EfficientDet 和其他目标检测算法的 mAP 均有明显提高。

本文仅针对风机叶片部分类型缺陷进行研究, 诸如后缘开裂、胶衣破损等缺陷并未涉及, 下一步将会采集更多风机叶片缺陷图像, 并对算法进行进一步改进。

参 考 文 献

- [1] 徐红运, 徐小力, 左云波, 等. 复杂背景下的风力机组叶片图像分割方法研究[J]. 电子测量技术, 2018, 41(22):60-65.
- [2] 曾军, 陈艳峰, 杨萍, 等. 大型风力发电机组故障诊断综述[J]. 电网技术, 2018, 42(3):849-860.
- [3] GIRSHICK R. FAST R-CNN [C]. 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015.
- [4] REN S, HE K, 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, 2016, 39 (6): 1137-1149.
- [5] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[C]. IEEE conference on Computer Vision and Pattern Recognition (CVPR), Seattle, America, 2020.
- [6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C]. European Conference on Computer Vision, Springer, Cham, 2016.
- [7] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection[C]. 2020 Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, America, 2020.
- [8] 李红光, 于若男, 丁文锐. 基于深度学习的小目标检测研究进展[J/OL]. 航空学报, 2021;1-19[2021-06-01].
- [9] LIN T, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]. Computer vision and pattern recognition, Hawaii, America, 2017.
- [10] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]. Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, America, 2018: 8759-8768.

- [11] GHIASI G, LIN T Y, LE Q V. Nas-fpn: Learning scalable feature pyramid architecture for object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 7036-7045.
- [12] ZHANG H, CISSE M, DAUPHIN Y N, et al. Mixup: Beyond empirical risk minimization [C]. Proceedings of the International Conference on Learning Representations, 2017.
- [13] DEVRIES T, TAYLOR G W. Improved regularization of convolutional neural networks with cutout[J]. ArXiv, 2017, DOI:10.48550/arXiv.1708.04552.
- [14] YUN S, HAN D, OH S J, et al. Cutmix: Regularization strategy to train strong classifiers with localizable features[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, Seoul, Korea, 2019.
- [15] MA N N, ZHANG X Y, SUN J. Funnel Activation for Visual Recognition [C]. European Conference on Computer Vision, 2020.
- [16] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1026-1034.
- [17] AVENASH R, VISWANATH P. Semantic segmentation of satellite images using a modified CNN with hard-swish activation function[C]. 14th International Conference on Computer Vision Theory and Applications, 2019.
- [18] LIN T, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]. Proceedings of the IEEE International Conference on Computer Vision, Hawaii, America, 2017.

作者简介

辛彦,硕士研究生,主要研究方向为图像处理、计算机视觉。
E-mail:786395071@qq.com