

安全隐患^[2]。定期对绝缘子进行巡检,及时发现绝缘子的异常并采取相应的解决办法可以显著降低电力事故的频率。

近年来,深度学习算法在图像识别和目标检测方面取得了巨大的成就^[3],基于图像处理的深度学习方法已经在绝缘子缺陷检测领域得到了广泛应用^[4]。深度学习方法在目标检测方面又可分为双阶段和单阶段的目标检测方法^[5]。王卓等^[6]使用全卷积(full convolution network, FCN)初步分割出绝缘子区域,将其传输给 YOLOv3 网络模型,实现双阶段绝缘子目标检测,提高了模型的检测精度。Tao 等^[7]为了定位和检测绝缘子中的缺陷,提出了一种新型的深度卷积神经网络(convolutional neural network, CNN)级联架构,有效提高了绝缘子缺陷检测的鲁棒性。虽然双阶段目标检测方法对绝缘子缺陷检测的精度较高,但其网络模型具有庞大的参数量,在训练过程中需要很多的计算资源,且检测速度缓慢难以真正应用与实际之中。相对于双阶段目标检测方法而言,单阶段目标检测模型参数量小,检测速度快,容易在移动设备上部署。目前单阶段目标检测的代表性算法有单次多框检测器(single shot multibox detection, SSD)系列和你只看一次(you only look once, YOLO)系列。王建烽等^[8]为了快速实现绝缘子自爆检测,提出轻量级 PL-MFSSD 模型,同时加入 k-means 聚类算法进行优化,提高了绝缘子自爆故障的检测精度,但是 SSD 的多尺度特征图设计决定了其架构的复杂性,其计算复杂性还是太高。He 等^[9]提出了一种基于 YOLOv8s-SwinT 的检测方法,结合 Swin Transform 和卷积神经网络,提升了对绝缘子微小缺陷的检测能力,Chen 等^[10]提出一种基于 YOLOv8 的改进算法 Insu-YOLO,通过引入 GSConv 模块和轻量级 CARAFE 结构,提高了在复杂环境下识别绝缘子破损的精度。上述两种方法的计算复杂性较低,但它们都是基于 YOLOv8s 模型而改进得到的,其参数量仍然很大,计算复杂度还有降低的空间。

为了解决上述文献中所面临的问题,进一步优化绝缘子缺陷检测算法,本文提出一种基于 YOLOv8n^[11]网络而改进得到的 YOLOv8-GCS 模型,在保证检测精度的同时,进一步降低模型的参数量,并保证减少对绝缘子缺陷检测的漏检率和错检率。本文主要贡献如下:首先,将 YOLOv8n 中的 C2f 模块换成更轻量级的 Ghost 卷积^[12]模块,减少骨干网络中的冗余结构,从而大幅度降低模型的参数量和计算量;其次,在 YOLOv8n 的 backbone 末尾处和第二个检测头处加入了 CoordAtt 模块^[13]以提高模型在绝缘子及其缺陷部件上的特征表达能力;最后,在骨干网中引入一个 SPD-Conv 模块^[14],让网络模型在二倍下采样的过程中无重要信息的损失,增强网络模型对重要特征的学习率,从而进一步提高模型的鲁棒性。最后,就本文所提出的改进算法进行了许多的消融和对比实验,以验证本算法在

压缩了参数量的情况下依然能保持较高的精度。

1 基线 YOLOv8 模型

YOLOv8 检测算法是 2023 年由 Ultralytics 公司发布的,是一种先进的单阶段目标检测算法,并用 width_multiple、depth_multiple 和 max_channels 三个参数来控制整体模型的大小,将模型分为了 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x 五个版本。考虑到轻量化的问题,本文决定选取参数量最少的 YOLOv8n 作为基线模型,如图 1 所示,该网络由主干网络(Backbone)、特征增强网络(Neck)和检测头(Head)三部分构成。

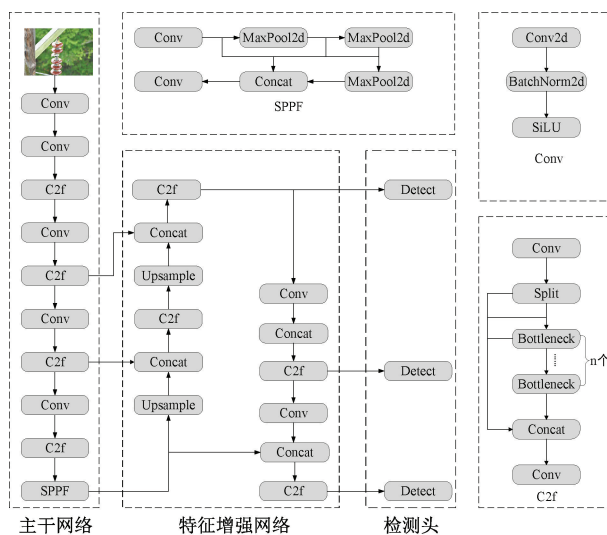


图 1 YOLOv8n 网络结构图

Fig. 1 YOLOv8n network structure

YOLOv8n 的主干网络和特征增强网络都借鉴了 YOLOv7ELAN 的设计理念^[15],使用了 FPN-PAN 的结构进行采样,利用最近邻差值法放大特征图,再将不同大小的特征图信息进行融合利用,使网络模型可以有效捕捉待检测目标的详细信息;YOLOv8n 在不同的网络层级上使用不同的检测头,每一个检测头只负责预测一个指定大小的边界框,使得 YOLOv8n 网络可以很好的捕捉不同大小的目标信息。

虽然 YOLOv8n 算法是当前最先进的目标检测算法之一,但是如果直接在户外用于绝缘子的缺陷检测会存在很多问题。首先,虽然 YOLOv8n 模型框架是最小的,但其任然有三百多万的参数量,在低功耗设备上部署仍有一定难度。其次,无人机户外拍摄的大部分绝缘子图像背景复杂,且受光照影响较大、遮挡问题严重导致模型的检测精度下降,漏检、错检等问题严重。最后,在 YOLOv8n 的主干网络下采样时,可能会有重要特征信息的损失,影响模型的鲁棒性。因此对 YOLOv8n 模型进行改进是非常有必要的。

2 改进 YOLOv8n 模型

2.1 改进的 YOLOv8-GCS 模型

针对上节中提到的 YOLOv8n 算法的不足,本文提出了一种轻量化的 YOLOv8-GCS 模型。该网络模型框架如图 2 所示。

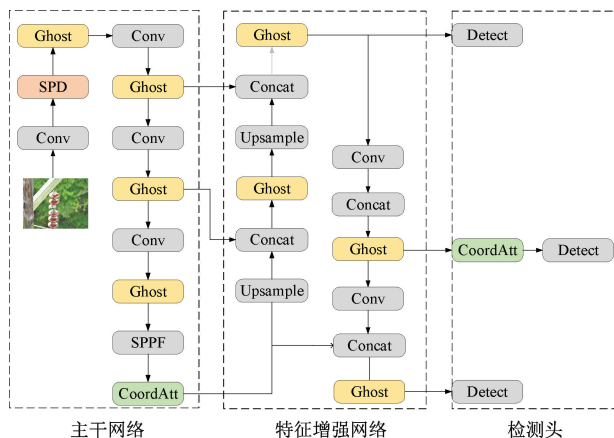


图 2 YOLOv8-GCS 网络结构图

Fig. 2 YOLOv8-GCS network structure

对算法的改进如下:首先,将网络中的 C2f 模块换成了更轻量级的 Ghost 卷积模块,减少了网络中的冗余结构从而大幅度降低了模型的参数量。其次,在主干网络 (Backbone) 的末端和检测头 (Head) 部分各加入一个 CoordAttn 模块,提高了模型在绝缘子及其缺陷部件上的特征表达能力,最后,在主干网络 (Backbone) 里引入一个 SPD-Conv 模块,让网络模型在二倍下采样的过程中无重要信息的损失,增强网络模型对重要特征的学习率,进一步提高模型的检测性能。

2.2 Ghost 卷积模块

如图 3 所示,传统的卷积运算是通过特征映射 (feature map) 提取特征信息,其缺点是计算量庞大且不适用于算力较弱的设备,而 YOLOv8n 算法中包含了大量的传统卷积,尤其是 C2f 中包含了大规模的卷积层并且进行了大批的卷积运算,这就导致 YOLOv8 网络中含有很多的冗余信息且参数量过大。




图 3 传统卷积层

Fig. 3 Convolutional layer

考虑到降低参数量和计算复杂度的问题,本文决定将 YOLOv8 网络中所有的 C2f 模块换成更加轻量级的 Ghost 卷积模块来降低模型的计算量和参数量。Ghost 卷积模块结构如图 4 所示。




图 4 Ghost 卷积

Fig. 4 Ghost module

输入特征图经过传统卷积得到的特征映射, Ghost 卷积模块可以分 3 个步骤来得到与之相同的特征映射,并且可以大幅度降低参数量和计算量。首先,输入的特征图经过普通的卷积滤波器产生尺寸较小的特征映射,然后经过一系列的线性运算 Φ 来增强特征并提高通道数产生 Ghost 特征图,最后将 Ghost 特征图和前一步产生的特征映射进行合并就可以产生和传统卷积一样大小的特征图。

下面通过公式计算来比较二者在计算量和参数量上的差距,假设输入特征图的大小为 $w \times h \times c$, 输出特征图大小为 $w' \times h' \times c'$, 其中 w, h, c 分别代表输入特征图的宽、高和通道数,传统卷积运算时使用卷积核的个数为 n , 大小为 $k \times k$, s 代表 Ghost 特征图的数量,线性运算时使用的卷积核平均大小为 d , 注意: $s \ll c, d \approx k$ 。

则输入特征图经过传统卷积后得到新的特征映射时的计算量为:

$$f_1 = c' \times h' \times w' \times c \times k \times k \quad (1)$$

而使用 Ghost 卷积模块时的计算量为:

$$f_2 = \frac{c'}{s} \times h' \times w' \times c \times k \times k + (s-1) \times \frac{c'}{s} \times h' \times w' \times d \times d \quad (2)$$

将二者的计算量相比可得:

$$\frac{f_1}{f_2} = \frac{s \times c \times k \times k}{c \times k \times k + (s-1) \times d \times d} \approx \frac{s \times c}{c + s - 1} \approx s \quad (3)$$

同理可得模型的压缩比为:

$$G_c = \frac{n \times c \times k \times k}{\frac{n}{s} \times c \times k \times k + (s-1) \times \frac{n}{s} \times d \times d} \approx s \quad (4)$$

由式 (3)、(4) 可知在输出相同特征图大小的情况下, Ghost 卷积的计算量仅是传统卷积计算量的 $1/s$, 同时参数量也被压缩了 s 倍, 所以为了实现 YOLOv8n 模型的轻量化, 将 C2f 模块换为 Ghost 卷积模块可以有效降低模型的计算量和参数量。

2.3 CoordAtt 注意力模块

注意力机制是计算机视觉中一种常见且重要的方法,其在神经网络中的作用是增强模型对输入图片的关注度,经常被用来模拟人类的视觉或感知系统的工作原理。因为绝缘子经常在复杂多变的外部环境下工作,并且其缺陷检测属于小目标检测,为了提高模型在绝缘子缺陷部件上的特征表达能力,本文决定在绝缘子缺陷算法中引入一种全新的坐标注意力机制(coordinate attention, CA),其结构如图 5 所示。

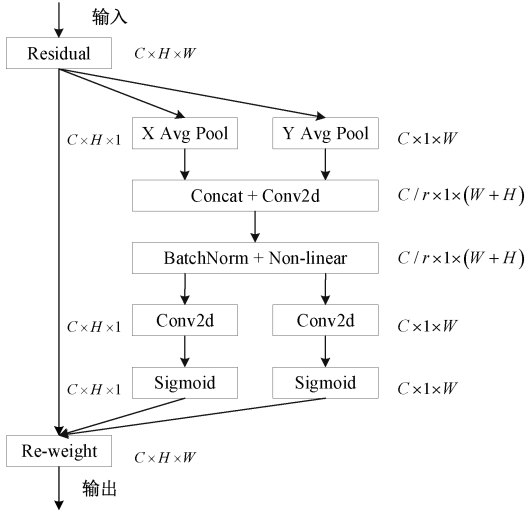


图 5 CA 注意力机制结构

Fig. 5 Structure diagram of CA mechanism

CA 模块是一种创新高效且轻量化的注意力机制,它不仅可以捕获各个通道之间的信息还可以获得不同位置之间的关联信息。首先将输入的特征图在高度和宽度两个方向上分别进行全局平均池化操作,从而获得在高度和宽度两个不同方向上的特征图,再将两个特征图通过普通的堆叠操作将其合并得到一个新的特征图,然后进行卷积操作以获取宽度和高维度之间的联系,再经过批量归一化(BatchNorm)和非线性激活函数(non-linear)进一步处理特征图来增强模型的特征提取能力,继续将此时的特征图再次分开获得高度和宽度两个方向的特征图并将其转置以恢复原有的高、宽的维度,随后通过 1×1 的卷积运算来调整通道数为下一步计算做准备,接着应用 Sigmoid 激活函数获取宽、高两个维度上的注意力分数,其中注意力分数越高代表越重要,最后将原始特征图和两个维度上的得分相乘得到最终的输出结果。引入 CoordAtt 模块可以有效抑制复杂背景对绝缘子缺陷部位的影响从而提高模型的检测精度。

2.4 SPD-Conv 模块

在 YOLOv8 的算法框架中不可避免的会使用一些步长大于 1 的卷积或池化操作,这将导致检测绝缘子缺陷时会丢失一些细粒度信息,并且表示重要特征的学习率低下,

这意味模型对绝缘子的检测精度会受到很大的负面影响,这也是传统卷积神经网络中常见且致命的缺陷。为了解决这一问题,本文决定在 YOLOv8n 的主干网络中引入一个 SPD-Conv 模块,该模块由两部分组成,一个是空间到深度(SPD)层另一个是非跨步卷积(Conv)层,它可以替代卷积神经网络中的每一个卷积步长和池化,因此可以避免上述缺陷。

SPD-Conv 模块结构如图 6 所示,其中 SPD 层可以按指定系数 $scale$ 对特征图进行下采样操作。图 6(a)表示标准的输入特征图 I , 其大小为 $S \times S \times C_1$, $scale = 2$, 图 6(b)是间隔采样特征图,表示特征图 I 按照每行每列隔一个像素点的方式进行采样,采样后将得到 4 个子特征图如图 6(c)其大小为 $(S/2, S/2, C_1)$, 再将 4 个子特征图沿着通道维度进行拼接,从而得到一个中间特征映射 I' 如图 6(d)所示,其大小为 $(S/2, S/2, 4C_1)$, 与原图 I 相比,其空间维度缩小了一半而通道维度扩大了 4 倍,最后中间特征映射 I' 会再经过一个非跨步卷积(Conv)层,得到最终的特征图 I'' 如图 6(e)所示,其大小为 $(S/2, S/2, C_2)$ 。非跨步卷积和普通的步长卷积不同,对于分辨率较低的图像,使用步长大于 1 的卷积在特征图上移动会导致一些细粒度信息的丢失,这对小目标检测的精度会产生较大的负面影响,而使用非跨步卷积($stride = 1$)不会在特征图上直接移动,而是对每一个像素点进行卷积操作,尽可能地保留所有可以判别特征的信息,直观的看,SPD-Conv 模块相当于对原图进行了跨步处理并改变了通道数,但是它保留了所有像素点的信息,有助于提高模型的检测精度。

3 实验结果与分析

3.1 实验环境及参数配置

为了验证本文算法在绝缘子缺陷检测上的有效性,本文使用了如表 1 所示的计算机配置及超参数进行网络模型的训练和测试。

3.2 评价指标

为了更好的分析本文的实验结果,本文采用的精度评价指标有:查全率(Precision)、召回率(Recall)、平均精度 AP(average precision)和平均类别精度(mean average precision, mAP)。模型大小的评价指标有:参数量(Parameters)和浮点数运算量(GFLOPs)。它们的定义式为^[16]:

$$Precision = \frac{TP}{TP + FN} \times 100\% \quad (5)$$

$$recall = \frac{TP}{TP + FP} \times 100\% \quad (6)$$

$$AP = \int_0^1 P(R) dR \quad (7)$$

$$mAP = \frac{\sum_{i=0}^n AP(i)}{n} \quad (8)$$




图 6 SPD 结构模型
Fig. 6 SPD structure model

表 1 实验环境配置

参数	配置
CPU	Intel Core i7-10700k@2.90 GHz
GPU	NVIDIA GeForce RTX 3060Ti
操作系统	Windows 10
CUDA	12.2
Python	3.11.5
Torch	2.0.0
图片尺寸	640
训练周期	400
批量大小	32
学习率	0.01
衰减系数	0.000 5

式中: $P(R)$ 代表 P - R 曲线的函数表达式; TP 表示正确检测的数量, FP 表示错误检测的数量, FN 表示未被检测的数量; mAP 表示 n 个类别的平均精度。

3.3 数据集构建

本文采用采用的数据集由两部分组成,一部分是从网上下载,另一部分是从公共数据集上整理得到,原始图片分辨率在 900 万左右,因为模型设置图片尺寸的参数量为 640,为了加快模型的训练速度,本文将在模型训练前将图片大小压缩至 640,其中绝缘子图片主要包括两类缺陷破损和闪络,如图 7(a)、(b)所示。

使用 YOLO 模型训练时需要大量数据集进行训练以减少过拟合的问题,所以本文对数据集进行了扩充,采取的数据增强方法有:旋转、饱和度调整、图形上下翻转、平移等操作将数据集扩充至 1 600 张,同时,使用 Labelme 工具对数据集进行标注,标注类别分别为 insulator、broken、




图 7 两种不同类型的缺陷
Fig. 7 Two different type of defects

pollution-flashover,最后将绝缘子数据集分为训练集、验证集和测试集,划分比例为 7 : 2 : 1。

3.4 消融实验

为了验证基于 YOLOv8n 网络模型改进得到的全新算法 YOLOv8-GCS 对绝缘子缺陷检测的有效性和合理性,本文决定在原网络模型的基础上依次添加改进模块,进行消融实验以验证各个模块对原网络模型的影响。实验数据如表 2 所示,表中“√”代表在网络中添加了该模块。

由表 2 可知,实验 1 是原始网络 YOLOv8n 模型。实验 2 是将 YOLOv8n 网络模型中所有的 C2f 模块换成了更加轻量级的 Ghost 卷积模块,虽然模型精度有所下降,但是模型参数量降低了 26.7%,并且保存结果的权重文件大小减少了 1.7 MB,这对于模型的运行效率和户外部署是非常有利的。实验 3 是在实验 1 的基础上添加了注意力机制,使得基础模型的 Recall、Precision、mAP50 分别提高了 2.7%、0.3%、0.5%,且对绝缘子的缺陷 AP⁵⁰ 都有一定的提升。实验 4 是在 YOLOv8 的主干网络中单独引入了一个 SPD-Conv 模块,让网络模型在二倍下采样的过程中无重要信息的损失,同时增强网络模型对重要特征的学习率,使得基础网络模型的 mAP50 提高了 4%。实验 5 是在

表 2 消融实验比较

Table 2 Ablation experimental

实验	Ghost	CA	SPD-Conv	Parameter/M	Weight/MB	AP ⁵⁰ 闪络	AP ⁵⁰ 破损	Recall	Precision	mAP50
1				3.0	6.3	77.6%	90.5%	82.8%	92.6%	89.2%
2	✓			2.2	4.6	73.6%	85.9%	84.2%	86.9%	86.3%
3		✓		3.0	6.3	78.1%	91.1%	85.5%	92.9%	89.7%
4			✓	3.0	6.4	85.7%	94.6%	89.9%	91.7%	93.2%
5	✓	✓		2.2	4.7	77.3%	90.4%	85.2%	89.9%	89.2%
6	✓		✓	2.2	4.8	84.0%	90.1%	86.2%	89.7%	91.2%
7	✓	✓	✓	2.2	4.8	85.7%	94.5%	87.5%	93.9%	93.2%

实验 2 的基础上添加了 CA 注意力模块,与基础模型相比,其大幅度降低了模型的参数量及权重文件大小同时又保持了模型的预测性能。实验 6 是在实验 2 的基础上再添加一个 SPD-Conv 模块,使得基础网络模型的参数量降低了 26.7%,权重文件降低了 1.5 MB,Recall 和 mAP50 分别提高了 3.4%和 2%。实验 7 是在实验 6 的基础上再添加一个 CA 注意力模块,使得基础模型精度进一步提升,绝缘子

的闪络和破损缺陷的 AP⁵⁰ 分别提高了 8.1%和 4%, Recall、Precision、mAP50 分别提高了 4.7%、1.3%、4%。

综上所述,本文添加的改进模块对原始网络的性能提升均是有效的。为了直观感受基线 YOLOv8n 模型与改进后模型的差别,本文将两种模型 Recall 和 mAP50 的结果可视化,如图 8(a)、(b)所示。从可视化对比图中可以看出本文改进策略可以大幅提高模型的检测精度。

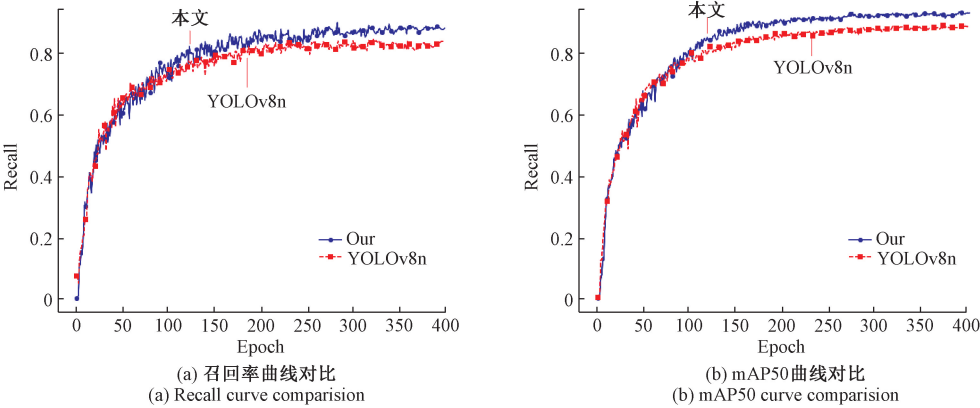


图 8 不同模型训练结果比较

Fig. 8 Comparison of training results of different models

3.5 对比实验

消融实验只能证明本文的改进方法与原始算法相比是有提升的,但是改进后的算法与其他经典的目标检测算法相比是否仍然具有优势还有待证明。因此,本文在相同的实验条件下,将改进后的算法与现阶段常用的目标检测算法进行对比,对比算法包括:YOLOv3-tiny、YOLOv5、GBH-YOLOv5^[17]、YOLOv7-tiny、DGW-YOLOv8^[18]。实验结果如表 3 所示。

由表 3 的数据可知,与现阶段已有最新改进的 YOLO 算法 GBH-YOLOv5 和 DGW-YOLOv8 以及其他主流 YOLO 系列的小目标检测算法相比,本文提出的 YOLOv8-GCS 模型的 Recall、Precision、mAP 值均是最高的。为了直观体现本文算法的有效性,将上述模型的 mAP50 可视化对比曲线图画出来,如图 9 所示,从图中可以看出本文算法的 mAP50 值明显高于其他算法。

表 3 不同模型性能比较

Table 3 Performance comparison of different models

模型	Recall	Precision	mAP50
YOLOv3-tiny	77.8	86.5	81.0
YOLOv5n	84.6	90.0	88.2
GBH-YOLOv5	87.5	93.0	91.8
YOLOv7-tiny	86.2	90.4	89.5
YOLOv8n	82.8	92.6	89.2
DGW-YOLOv8	86.6	89.9	91.9
本文	87.5	93.9	93.2

因此本文提出的 YOLOv8-GCS 模型可以达到预期效果,即在大幅度压缩参数量的情况下,其检测精度仍然高于最新已有改进的 YOLO 算法,同时也说明本文算法非常




图 9 不同模型训练结果比较

Fig. 9 Comparison of training results of different models

适合在户外部署并进行绝缘子的缺陷检测任务。

为了更进一步的验证本文算法的鲁棒性和泛化性,本文将在测试集中挑选一些在复杂环境下具有微小缺陷的绝缘子图像进行对比实验。实验结果如图 10 所示。通过对比分析图像可知,本文提出的改进算法不仅能准确识别复杂环境中的一些绝缘子目标而且能更好的识别绝缘子中的微小缺陷。

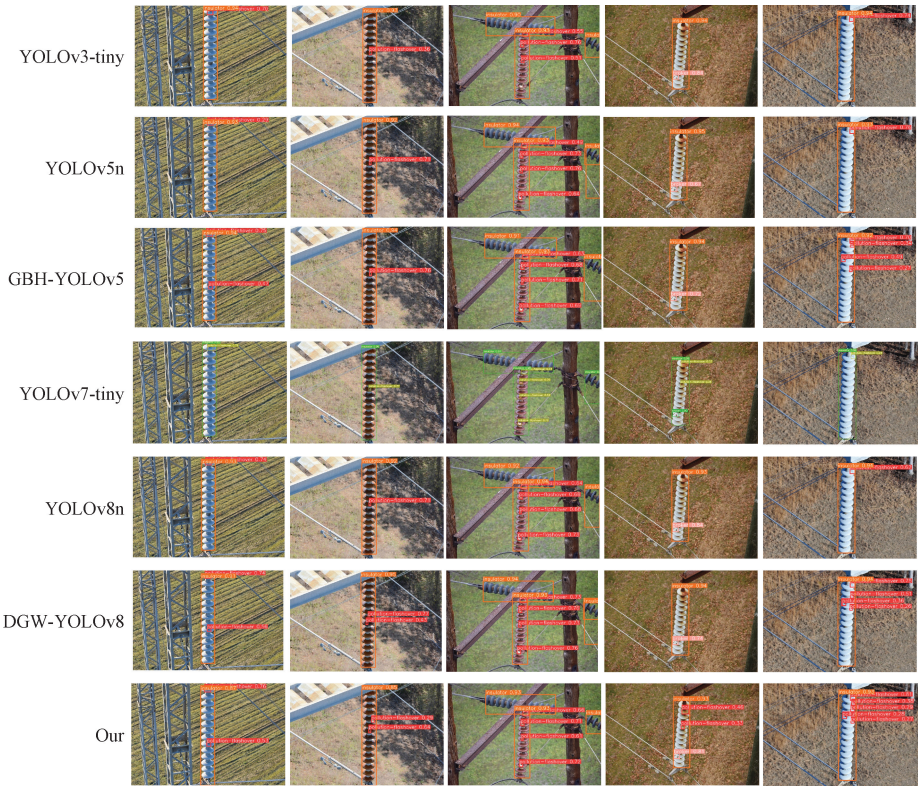


图 10 不同模型可视化对比结果

Fig. 10 Visual comparison results of different models

4 结 论

本文针对绝缘子所处位置背景复杂、缺陷微小而现有的检测模型参数量庞大不适合户外部署等问题,提出了一种全新算法 YOLOv8-GCS。消融实验可知,本文算法与基线 YOLOv8n 模型相比,参数量大小降低了 26.7%,并且 Recall、Precision 和 mAP 值分别提高了 4.7%、1.3%和 4%。通过对比实验可知,本文算法与现阶段小目标检测算法 YOLOv3-tiny、YOLOv5n、GBH-YOLOv5、YOLOv7-tiny 和 DGW-YOLOv8 相比,YOLOv8-GCS 具有更高的检

测精度,更适合在户外部署并进行绝缘子的缺陷检测任务。

由于本文使用的数据集中绝缘子的缺陷都是外部轮廓损伤,尚无绝缘子内部裂纹的图像数据集,因此本文算法还有提升的空间,因此本文的后续工作是继续完善数据集并进一步提高模型的鲁棒性和泛化性。

参考文献

[1] PARK K C, MOTAI Y, YOON J R. Acoustic fault detection technique for high-power insulators [J]. IEEE Transactions on Industrial Electronics, 2017,

- 64(12): 9699-9708.
- [2] 王韵琳,冯天波,孙宁,等.融合注意力与多尺度特征的电力绝缘子缺陷检测方法[J].高电压技术,2024,50(5):1933-1942.
WANG Y L, FENG T B, SUN N, et al. A defect detection method for power insulators by fusing attention and multiscale features[J]. High Voltage Technology, 2024, 50(5): 1933-1942.
- [3] 冯晗,姜勇.使用改进 Yolov5 的变电站绝缘子串检测方法[J].智能系统学报,2023,18(2):325-332.
FENG H, JIANG Y. Insulator string detection method for substations using improved Yolov5[J]. Journal of Intelligent Systems, 2023, 18(2): 325-332.
- [4] 张剑锐,魏霞,张林鎔,等.改进 YOLOv7 的绝缘子检测与定位[J].计算机工程与应用,2024,60(4):183-191.
ZHANG J R, WEI X, ZHANG L X, et al. Improvement of insulator detection and localization by YOLOv7[J]. Computer Engineering and Application, 2024, 60(4): 183-191.
- [5] 刘传洋,吴一全.基于深度学习的输电线路视觉检测方法研究进展[J].中国电机工程学报,2023,43(19):7423-7446.
LIU CH Y, WU Y Q. Research progress of vision detection methods based on deep learning for transmission line[J]. Proceedings of the CSEE, 2023, 43(19): 7423-7446.
- [6] 王卓,王玉静,王庆岩,等.基于协同深度学习的二阶段绝缘子故障检测方法[J].电工技术学报,2021,36(17):3594-3604.
WANG ZH, WANG Y J, WANG Q Y, et al. A two-stage insulator fault detection method based on cooperative deep learning [J]. Journal of Electrotechnology, 2021, 36(17): 3594-3604.
- [7] TAO X, ZHANG D, WANG Z, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 50(4): 1486-1498.
- [8] 王建烨,续欣莹,谢刚,等.改进 SSD 模型的绝缘子自爆故障检测[J].现代电子技术,2022,45(14):115-121.
WANG J Y, XU X Y, XIE G, et al. Improved SSD modeling for insulator self-detonation fault detection[J]. Modern Electronic Technology, 2022, 45(14): 115-121.
- [9] HE Z D, YANG W B, LIU Y J, et al. Insulator Defect Detection Based on YOLOv8s-SwinT[J]. Information, 2024, 15(4): 206.
- [10] CHEN Y F, LIU H Y, CHEN J H, et al. Insu-YOLO: An insulator defect detection algorithm based on multiscale feature fusion[J]. Electronics, 2023, 12(15): 3210.
- [11] REIS D, KUPEC J, HONG J, et al. Real-time flying object detection with YOLOv8 [J]. ArXiv preprint arXiv:2305.09972, 2023.
- [12] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [13] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [14] SUNKARA R, LUO T. No more strided convolutions or pooling: A new CNN building block for low-resolution images and small objects [C]. Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2022: 443-459.
- [15] WANG C Y, BOCHKOVAKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [16] 霍超,谷晓钢,黄玲琴,等.基于 YOLO v4 优化的航拍绝缘子缺陷图像检测模型[J].电子测量技术,2023,46(9):175-181.
HUO CH, GU X G, HUANG L Q, et al. Aerial insulator defect image detection model based on YOLO v4 optimization [J]. Electronic Measurement Technology, 2023, 46(9): 175-181.
- [17] LI L, WANG Z, ZHANG T. Gbh-yolov5: Ghost convolution with bottleneckcsp and tiny target prediction head incorporating yolov5 for pv panel defect detection[J]. Electronics, 2023, 12(3): 561.
- [18] HU D, YU M, WU X Y, et al. DGW-YOLOv8: A small insulator target detection algorithm based on deformable attention backbone and WIoU loss function [J]. IET Image Processing, 2024, 18(4): 1096-1108.

作者简介

熊炜,博士,副教授,硕士研究生导师,主要研究方向为数字图像处理与计算机视觉。

E-mail: xw@mail. hbut. edu. cn

黄玉谦(通信作者),硕士研究生,主要研究方向为计算机视觉、图像处理在电力系统中的应用与设计。

E-mail: 2607584693@qq. com