

DOI:10.19651/j.cnki.emt.2210118

基于改进 YOLOv5 的输电线路绝缘子识别方法^{*}

王素珍 赵霖 邵明伟 葛润东

(青岛理工大学信息与控制工程学院 青岛 266520)

摘要: 针对输电线路绝缘子识别准确率低、识别花费时间长的问题,提出一种改进的 YOLOv5 绝缘子识别方法。首先,通过引入超分辨率卷积网络提升数据集中图像样本质量;其次,通过引入 k3-Ghost 结构替换原始网络 BCSP 模块中的普通卷积,减少模型主干网络参数量,在主干网络尾部引入 SENet 注意力模块,加强模型对于通道信息的关注提升目标检测性能;在颈部网络引入 DC-BiFPN 结构替换原始结构,对不同尺度特征赋予不同权重以使多尺度特征进行更好的融合,提升绝缘子识别效果。最后,使用 CIOU 作为回归损失函数,加快网络收敛速度。实验结果表明,本文提出的方法在保证绝缘子识别准确率的同时拥有更高的识别速度,检测准确率达到 89.5%,检测速度达到 35.7 FPS,验证了改进方法的有效性。

关键词: 绝缘子检测;YOLOv5;超分重建;Ghost;SE;DC-BiFPN

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 510.1050

Insulator identification method of transmission line based on improved YOLOv5

Wang Suzhen Zhao Lin Shao Mingwei Ge Rundong

(School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266520, China)

Abstract: To solve the problems of low accuracy and long identification time of insulators in transmission lines. An improved method for identification of YOLOv5 insulators is proposed. Firstly, the quality of image samples in the dataset is improved by introducing super-resolution convolutional network. Secondly, by introducing k3-Ghost structure to replace common convolution in BCSP module of original network, the number of parameters in main network of model is reduced, the SE attention module is introduced in the tail of the trunk network to strengthen the model's attention to channel information and improve the performance of target detection; In the neck network, DC-BiFPN structure was introduced to replace the original structure, and different weights were assigned to different scale features to make better fusion of multi-scale features, so as to improve the insulator recognition effect. Finally, CIOU is used as regression loss function to speed up network convergence. The experimental results show that the proposed method has a higher recognition speed while ensuring the accuracy of insulator recognition, with detection accuracy up to 89.5% and detection speed up to 35.7 FPS, which verifies the effectiveness of the improved method.

Keywords: insulator detection; YOLOv5; super-resolution reconstruction; Ghost; SE; DC-BiFPN

0 引言

绝缘子作为输电线路中防范事故发生至关重要的一环,电力操作人员日常对于绝缘子的维护自然必不可少,由于人工巡检方式耗费大量时间且效率低下,使得借助无人机拍摄采集图像、识别绝缘子并定位检测其故障成为主流方式。

传统的绝缘子识别方法主要是基于颜色特征、边缘特

征及应用红外热成像技术等。刘国特等^[1]提出一种改进级联 Gentel Adaboost 分类器的红外绝缘子识别方法,通过计算 haar-like 特征值得到级联分类器,实现红外图中支柱绝缘子的准确识别。彭向阳等^[2]提出一种从无人机红外影像中自动识别绝缘子的方法,通过拉普拉斯边缘提取、沿线强度直方图探测影像中的纹理特征等方法实现了绝缘子自动识别并定位的功能。朱邵成等^[3]通过进行不同空间的阈值分割,然后利用频率调谐方法计算出不同空间的显著性信

收稿日期:2022-05-25

*基金项目:山东省自然科学基金(ZR2020QF101)项目资助

息,融合得到绝缘子显著图像,并实验证明该方法对于背景复杂的绝缘子的识别准确性。文献[1]和[2]只是适用于对红外图像中的绝缘子进行识别,泛化性较差,不能应用于日常电力巡检中。文献[3]只使用 100 张航拍绝缘子图像进行实验,数据集样本不足且精确识别率只有 78%,并不能满足日常巡检中对于绝缘子识别的要求。

近年来,深度学习理论的出现为基于视觉的目标检测注入了新的活力,Han 等^[4]提出了一种改进的 Tiny-YOLOv4 绝缘子破损识别算法,通过引入自注意力机制降低噪声信息的比例,并在特征融合层引入 ECA 网络来增强模型特征提取能力,改进方法降低了原 YOLOv4 算法的复杂度,检测速度得到提升。刘行谋等^[5]提出一种改进的 YOLOv4 电力绝缘子缺陷检测方法,通过在平衡交叉熵中引入一个权重系数以增加损失函数的贡献程度,并通过增加空间金字塔结构前后的卷积层来加深网络深度,实验证明了改进方法能够很好的识别电子绝缘子缺陷。赵文清等^[6]提出一种注意力机制和 Faster-RCNN 相结合的绝缘子识别方法,使识别精度得到提升,但是由于网络参数量增加导致模型检测速度降低。Yao 等^[7]提出一种 GIOU-YOLOv3 绝缘子检测定位的方法。使用 GIOU 损失函数代替原损失函数,在不增加模型尺寸的情况下,提高了绝缘子的检测精度。但是测试结果中绝缘子目标漏检情况比较。宋万潼等^[8]提出一种基于先验知识的 Faster-RCNN 改进方法,通过引入混合注意力模块提高主干网络特征提取能力,加入航拍绝缘子的先验知识提升网络性能,实验证明改进模型在检测精度与识别速度上均有提升,但检测速度只有略微提升,远达不到实时检测绝缘子的要求。易继禹等^[9]在原始 Faster RCNN 网络上调整滑动窗口产生的候选区域比例并引入检测困难样本对手生成策略提高绝缘子检测效率,但改进模型绝缘子检测速度只有 1.2FPS。文献[10]提出一种基于改进 YOLOv3 的绝缘子识别算法,将 YOLOv3 与稠密块相结合,优化特征提取网络,使用多级特征映射模块来提升网络特征融合性能。实验证明改进模型检测精度高出对比模型 2.8%,在检测速度方面虽达到实时检测要求,但相较于 YOLOv5 仍然有很大提升空间。文献[11]只考虑到绝缘子的识别精确度,在识别速度方法并没有做出改进。

针对以上问题,本文提出一种改进的 YOLOv5 绝缘子检测算法。从数据集角度,引入超分辨率图像重建算法,对数据集中样本进行图像质量增强。从模型网络结构角度,引入 k3-Ghost 结构替换 BCSP 模块中普通卷积以减少主干网络计算量,加快模型推理速度,并在主干网络尾部引入轻量化注意力模块 SE,以增加少量网参数量的代价提高目标识别准确率。引入 DC-BiFPN 结构替换原始 PAN 结构,使用多尺度绝缘子特征得以更有效的融合,减少模型参数量的同时提升模型对于空间布局的鲁棒性,达到提升绝缘子识别准确率的效果。最后,使用 CIOU_Loss 作为回归损

失函数,来保证网络的收敛速度。

1 YOLOv5 模型

YOLOv5 模型主要由 Backbone 主干网络、Neck 特征融合模块和 Head 预测部分组成。主干网络由 Focus 模块、BCSP 模块、SPP 模块等组成; Neck 部分采用 PAN 结构。

Head 部分主要是网络的预测端,通过非极大值抑制对需检测目标框进行有力筛选,然后对图像特征进行预测并且生成边界框以及预测其类别。YOLOv5 整体模型结构^[12]如图 1 所示,其中 BCSP 代表 BottleneckCSP 结构。

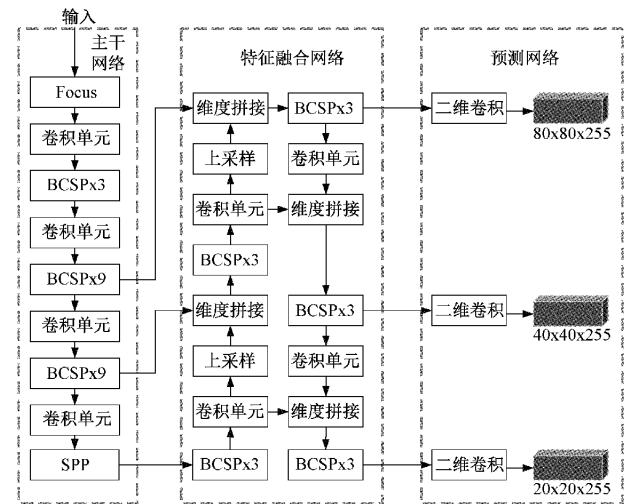


图 1 YOLOv5 网络结构图

YOLOv5 是一个高性能、通用的目标检测模型,但为了实现特定场景下的目标检测,需要对 YOLOv5 整体网络结构进行相应的调整和改进。本文选用 YOLOv5 模型中参数量和网络复杂度最低的 YOLOv5s 模型为基础模型,并基于 YOLOv5s 模型对主干网络部分和颈部网络进行改进。

2 改进的 YOLOv5 算法

2.1 数据集样本超分辨率重建

由于本文数据集通过无人机、手机相机等不同设备拍摄所获得,故得到的图片样本质量并不一致,本文采用 SRCNN^[13]对原始样本进行超分辨率重建,提升数据集中图像质量,超分辨率重建算法流程如图 2 所示:

从图 2 可以看出,重建网络由三层卷积神经网络组成,分别用 9×9 、 5×5 和 5×5 大小的卷积核依次作为三层网络的卷积尺寸,超分重建具体实现过程如下:

在图像特征提取阶段,使用双三次插值方法获得原始图像低分辨率样本 Y ,之后通过网络训练得到对应的映射图像 $F(Y)$ 。在第一层网络中,从低分辨率样本 Y 中提取图像块,通过卷积操作将提取到的图像块表示为多维向量,将得到的特征向量组成特征矩阵,处理过程如式(1)所示。

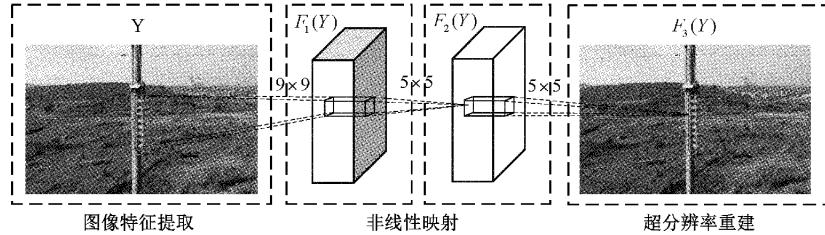


图 2 SRCNN 超分重建过程

$$F_1(Y) = \max(0, W_1 \times Y + B_1) \quad (1)$$

其中, W_1 和 B_1 分别代表重建网络第一层卷积核尺寸和偏置, $\max(0, x)$ 代表卷积后使用 ReLU 激活函数。

在非线性映射部分, 具体操作是将第一层卷积网络输出的特征向量通过卷积操作映射到第二层非线性映射层中, 处理过程如式(2)所示。

$$F_2(Y) = \max(0, W_2 \times F_1(Y) + B_2) \quad (2)$$

式中: W_2 和 B_2 代表网络第二层的卷积核尺寸和偏置, 第二层卷积核大小设置为 5×5 。

重建网络的最后一层为重建网络的输出层, 作用是输出最终的高分辨率图像, 卷积处理过程如式(3)所示。

$$F_3(Y) = W_3 \times F_2(Y) + B_3 \quad (3)$$

式中: W_3 和 B_3 代表网络最终输出层的卷积核尺寸和偏置, 所用卷积核大小为 5×5 , 第三层网络不使用激活函数。

文献[14]中指出使用更多数量的卷积核虽然会降低算法速度, 但能够得到更好的实验效果, 故本文设定三个卷积层的卷积核尺寸分别为 $9 \times 9, 5 \times 5, 5 \times 5$, 特征维度分别为 64 和 128, 升级因子设置为 2。

2.2 k3-Ghost Module

为减少绝缘子检测网络参数量以提升目标检测速度, 本文使用 3×3 大小的卷积核作为 Ghost 结构^[15]中深度卷积部分所用卷积核, 改进的深度卷积部分称为 k3-Ghost, 改进模块称为 k3-Ghost Module, 改进后的结构如图 3 所示。

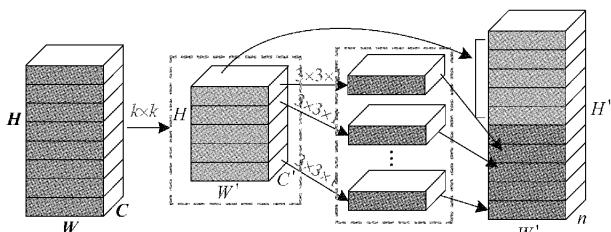


图 3 k3-Ghost Module

首先利用 $k \times k$ 大小的卷积核对输入特征 $C \times H \times W$ (C 代表通道数, H 和 W 代表输入特征高度和宽度)进行标准卷积操作, 达到缩减通道数的目的, 并得到输入特征图的集中特征 $C' \times H' \times W' \times m$ ($C' < C, H'$ 和 W' 代表标准卷积输出特征图的高度和宽度, m 是集中特征的数量, $m < n$), $k \times k$ 卷积的参数量 P_1 的计算如式 4 所示。

$$P_1 = C \times m \times k \times k \quad (4)$$

为得到最终 n 个特征图, 使用深度卷积结构对上一步得到的特征图进行分组卷积, 以获得所需的 $n - m$ 个特征图, 具体操作是将输入的集中特征分为 m 组 (通道数均为 1), 每组进行独立的卷积运算, 采用 $3 \times 3 \times 1$ 大小的卷积核对不同通道分别进行卷积操作, 得到尺寸为 $H' \times W' \times (n - m)$ (n 是需生成特征图的数量和) 输出特征图, 然后和第一步得到的集中特征进行 Concat 操作得到尺寸为 $n \times H' \times W'$ 的最终输出特征图。深度卷积部分参数量的计算如式(5)所示。

$$P_2 = (n - m) \times 3 \times 3 \quad (5)$$

$$\text{Parame} = C \times k \times k \times n \quad (6)$$

$$\begin{aligned} \text{Parameter} &= \frac{C \times k \times k \times n}{P_1 + P_2} \approx \\ &\frac{C \times n}{C \times m + (n - m)} \approx \frac{C \times n}{C \times m + m} \approx \frac{n \times C}{m(C + 1)} \approx \frac{n}{m} \end{aligned} \quad (7)$$

出于提升模型检测速度的考虑, 本文使用 3×3 大小的卷积核进行生成新特征部分的运算, 将 k3-Ghost 结构与标准卷积结构参数量进行比较, 得出本文主干部分替换后的模型提升程度, 计算过程如式(7)所示, 式(6)为标准卷积操作参数量。从式(7)中可以看出, 标准卷积的参数量是改进结构的 $\frac{n}{m}$ 倍 ($m < n$)。本文根据 k3-Ghost Module 结构设计出新的 k3-BCSP 模块替换原始网络中 BCSP 模块, 作为改进模型主干网络和颈部的主要模块, 其结构如图 4 所示。

2.3 SE 注意力机制

改进后的主干网络由于大量采用 k3-BCSP 结构使得检测模型准确率有所下降, 为弥补精度损失, 在主干网络中添加压缩激励 (squeeze and excitation, SE) 注意力模块^[14], 由于注意力模块的加入也存在增加主干网络参数量的问题, 故只在主干网络最后一层添加 SE 模块, 其后不与其他结构相连。

SE 注意力模块结构如图 5 所示, 首先输入图像 $X \in R^{H \times W \times C}$ 在特征层进行自适应全局平均池化, 得到 $1 \times 1 \times C$ (C 为平均池化后的特征图的通道数) 的特征图 Y_e 。接着对 Global pooling 层的输出进行两次全连接操作, 获取到各通道的权重, 然后将全连接后的输出使用 Sigmoid 激活函数固定到 0~1 之间, 此时得到一组 $1 \times 1 \times C$ 大小的权

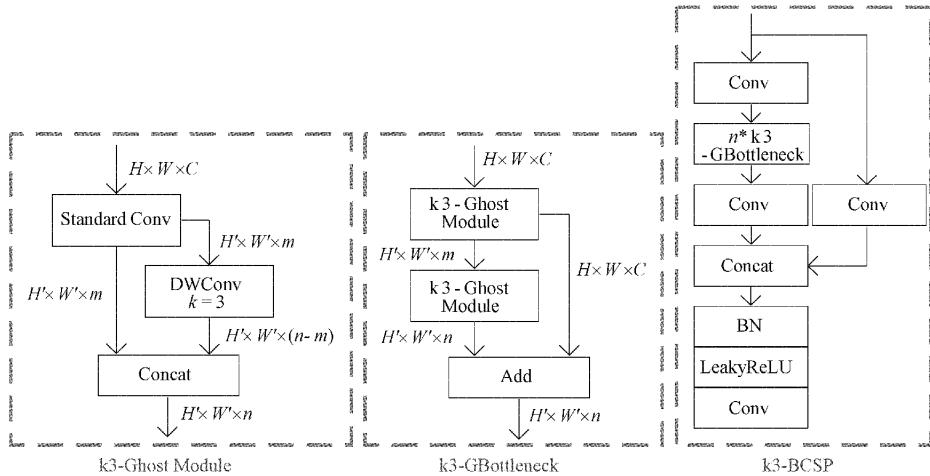


图 4 k3-BCSP 结构图

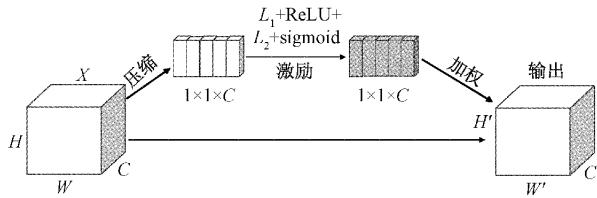


图 5 SE 注意力模块

重系数 $S = [s_1, s_2, \dots, s_c]$ 。

$$Y_c = F_{sq}(X_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j) \quad (8)$$

$$S = F_{ex}(Y_c) = \text{Sigmoid}(L_2[\text{ReLU}(L_1(Y_c))]) \quad (9)$$

式中： L_1 是第一次全连接过程， L_2 是第二次全连接过程，Sigmoid 和 ReLU 是使用的激活函数。在获得输入各通道权重后，将其加权到输入后得到注意力机制的输出。

在原始模型主干网络最后一层之后引入压缩激励注意力模块，通过在通道之间建立特征映射关系，使网络充分利用全局特征，增加特征层中有用信息所占有的比例，以提升绝缘子识别准确率，减少模型检测中的误检情况。模型性能提升如图 6 所示，左侧为基模型检测结果，图中出现多处误检情况，右侧为主干网络尾部引入 SE 注意力模块检测效果图，可以看出，相比于基模型，误检情况得到较大改善。

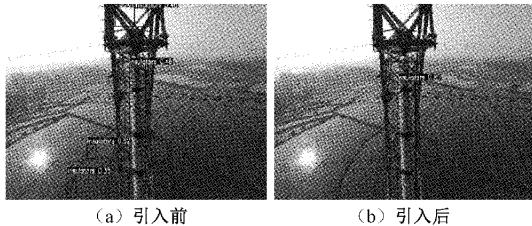


图 6 引入 SE 模块前后检测效果对比

2.4 DC-BiFPN

YOLOv5 网络当中使用 PANet 结构^[16]作为颈部的特

征融合模块，由于该结构没有考虑到特征融合时不同特征层输入的 feature map 包含不同的语义信息，无法充分利用不同尺度间的特征，导致检测网络的精度提升受到限制。针对 PANet 存在的不足，BiFPN 结构(图 7)^[17]对不同尺度的绝缘子特征赋予不同的权重，以提升重要信息特征在特征融合时所占的比例，具体做法是引入一种快速归一化特征融合机制，如式(11)所示，式(10)为 PANet 结构的特征融合方法。

$$Out = \sum_i I_i \quad (10)$$

$$Out = \sum_i \frac{\omega_i \times I_i}{\epsilon + \sum_j \omega_j} \quad (11)$$

式中： ω_i 代表模型学习到的不同权重参数， I_i 是不同层的输入特征向量， ϵ 是一个远小于 1 的数，目的是防止分母变 0。

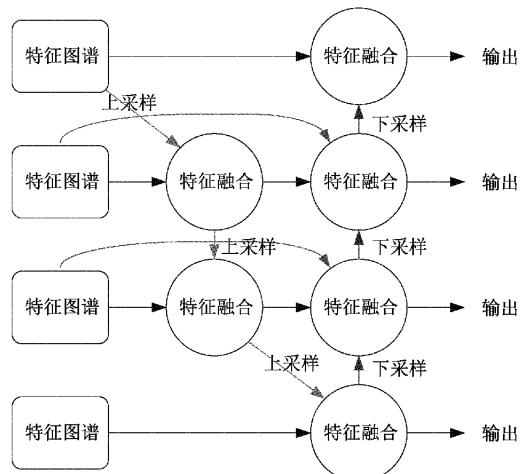


图 7 BiFPN 结构

考虑到 BiFPN 结构的加入会增加模型参数量，降低模型推理速度，故本文在此基础上设计了一种新的特征融合模块，改进方法称为 DC-BiFPN。具体做法是使用深度卷

积模块 DWConv^[18]替换原始 BiFPN 结构中的标准卷积模块, 使用 ReLU 激活函数替换原始结构中激活函数。DWConv 是一种轻量化的卷积结构, 通过将普通卷积操作分成深度卷积部分和逐点卷积部分来减少卷积计算量。具体实现如下图所示。图 8 为输入输出通道数均为 3 的 DWConv 结构图。

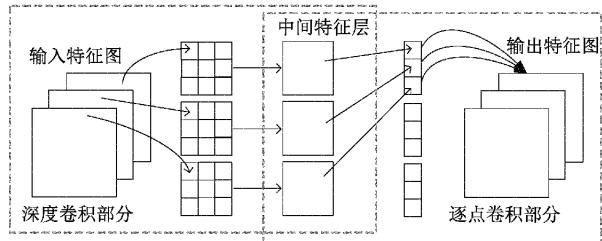


图 8 DWConv 结构图

颈部替换 DC-BiFPN 结构后的检测结果如图 9 所示, 图 9(a)为基模型检测结果, 在左侧位置漏检了一个绝缘子目标, 图 9(b)为替换 DC-BiFPN 结构后的检测结果, 可以看出原始模型和改进后的模型均能识别出图中的绝缘子目标, 但是原始模型漏检了一个遮挡较大的目标, 可见替换后的特征融合网络提高了模型的识别准确率。

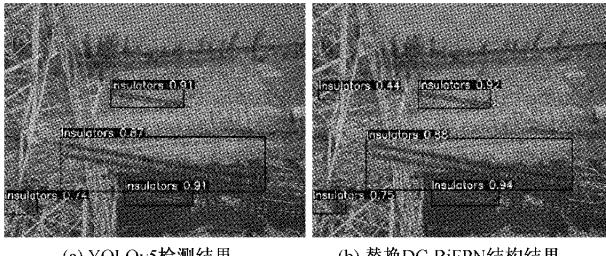


图 9 改进 DC-BiFPN 模块前后效果图

2.5 损失函数

YOLOv5 基模型中采用 GIOU 作为回归框定位损失函数。GIOU 存在预测框被包含在人工标注框中且真实框与预测框大小固定时, 计算方式退化为 IOU 的问题。故本文引入 CIOU^[19]代替 GIOU 作为定位损失函数, 在标注框与预测框中心点之间距离、两框长宽比例以及重叠面积上分别进行考虑, 如式(12)所示。

$$\begin{aligned} v &= \frac{4}{\pi} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \\ \alpha &= \frac{v}{1 - \text{IOU}(B_{pr}, B_{gt}) + v} \\ \text{CIOU}(B_{pr}, B_{gt}) &= \text{IOU}(B_{pr}, B_{gt}) - \frac{\rho^2(B_{pr}, B_{gt})}{c^2} - \alpha v \end{aligned} \quad (12)$$

式中: $\rho^2(B_{pr}, B_{gt})$ 表示绝缘子标注框中心点与预测框中心点距离的平方, c^2 为同时能框住标注框和预测框的最小框的对角线距离的平方, v 表示预测框与标注框长宽比例

差值的归一化结果, 部分计算出来的值在 $0 \sim \frac{\pi}{4}$ 之间。 α 为平衡因子, 权衡 IOU 部分的损失与长宽比例部分的损失。

与原模型所用损失函数相比, 改进的损失函数在损失项中加入长宽比例部分以及标注框与预测框距离部分的惩罚项, 旨在使绝缘子识别网络达到更快的收敛速度, 提升检测网络对绝缘子目标的回归定位精度。

2.6 改进模型整体网络结构

本文改进算法的网络结构如表 1 所示。

表 1 中“来源”表示本层来自哪一层的输出, -1 代表来自上一层的输出; 参数设置中包括本层所用模块的输入通道数、输出通道数、卷积核尺寸及步长等信息。

3 实验与结果分析

3.1 实验数据集与环境配置

本文数据集由包含不同类型绝缘子的 1 513 张输电线图像构成。数据集中图像通过无人机、相机等不同设备所拍摄, 以山地、农田、城市郊外为主要图像背景。数据集统一采用 LabelImg 工具的矩形框标注法进行标注, 并按照 9 : 1 的比例划分为训练集和测试集。

本文实验在交互计算平台 jupyterlab 上进行, CPU 为 Intel(R) Xeon(R) CPU E5-2670 v3, GPU 为 8 GB 显存的 GeForce RTX3060Ti, 实验框架选用 Pytorch。初始学习率为 0.001, 每次传入模型图片数量为 8, 使用的数据加载器数量为 8, 训练轮数为 100 轮, 训练和测试图像尺寸均为 640×640 , 其他实验超参数设置如表 2 所示。

3.2 评价指标

本文使用的评价指标包括准确率(Precision)、平均精度 mAP@0.5(mean Average Precision)、模型体积大小和每秒检测速率帧(frame per second, FPS)。准确率是用来衡量所用模型分辨出来的目标的确是否为目标的能力, 即查准率; FPS 指标作用是衡量模型每秒处理图像数量的能力; mAP@0.5 是指以 $\text{IOU}=0.5$ 时所计算的 mAP 值, 其中 IOU 为交并比。上述评价指标计算公式如下:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (13)$$

$$AP = \int_0^1 P_{smooth}(r) dr \quad (14)$$

$$mAP = \frac{\sum_{i=1}^C AP_i}{C} \quad (15)$$

式中: 分母 $TP + FP$ 是正样本预测出正样本数量加负样本预测出正样本数量; $P_{smooth}(r)$ 表示将 PR 曲线经过平滑处理, 再对其进行积分即曲线所围成的面积; C 为类别数; p_i 为第 i 个类别的精确率; 本文类别数 $C = 1$ 。

3.3 训练结果

本文改进算法与原始算法在相同环境下分别训练 100 轮后, 平均精度($\text{IOU}=0.5$)对比如图 10 所示。图中虚线

表 1 改进网络整体结构

编号	来源	参数量	模块名称	参数设置
01	-1	3 520	Focus	[3,32,3]
02	-1	18 560	Conv	[32,64,3,2]
03	-1	11 360	k3-BCSP	[64,64,1]
04	-1	73 984	Conv	[64,128,3,2]
05	-1	45 520	k3-BCSP	[128,128,3]
06	-1	295 424	Conv	[128,256,3,2]
07	-1	177 056	k3-BCSP	[256,256,3]
08	-1	1 180 672	Conv	[256,512,3,2]
09	-1	656 896	SPP	[512,512,[5,9,13]]
10	-1	627 648	k3-BCSP	[512,512,1,False]
11	-1	32 768	SE	[512,512]
12	-1	131 584	Conv	[512,256,1,1]
13	-1	0	upsampling	[None,2]
14	[-1,6]	773	DC-BiFPN	[256,256]
15	-1	158 176	k3-BCSP	[256,256,1,False]
16	-1	33 024	Conv	[256,128,1,1]
17	-1	0	Upsampling	[None,2]
18	[-1,4]	389	DC-BiFPN	[128,128]
19	-1	40 176	k3-BCSP	[128,128,1,False]
20	-1	295 424	Conv	[128,256,3,2]
21	[-1,6,14]	773	DC-BiFPN	[256,256]
22	-1	158 176	k3-BCSP	[256,256,1,False]
23	-1	1 180 672	Conv	[256,512,3,2]
24	[-1,10]	1 541	DC-BiFPN	[512,512]
25	-1	627 648	k3-BCSP	[512,512,1,False]

表 2 模型训练的超参数

超参数	具体数值
初始学习率	0.001
终止学习率	0.2
批次大小	8
warmup 初始化动量	0.9
权重衰减系数	0.000 5

为改进算法, 实线为原始算法, 通过观察可知, 原始算法和改进算法都能够接近 70 轮迅速收敛并达到稳定, 并且两种算法的平均精度都达到了很高的水平, 改进算法相较原始算法略有提升。

3.4 横向对比实验

为验证本文改进模型性能, 使用 YOLOv5s-EfficientLite0、YOLOv5s-Mobilenetv3Small 以及 YOLOv5s-Shffule 与本文改进模型进行横向对比实验, 上述所用模型均是在 YOLOv5s 模型基础上替换目前主流的轻量化网络结构, 比较改进算法与上述模型在检测准确率、平均精度均值、及 FPS 等客观评价指标, 实验结果如表 3 所示。

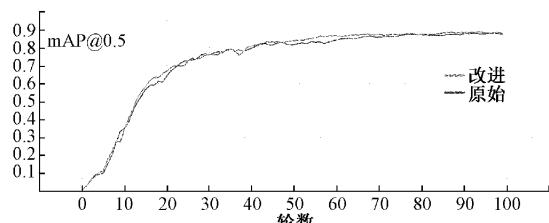


图 10 mAP@0.5 曲线对比

表 3 模型横向对比实验

所用方法	Precision	mAP@0.5/%	FPS
YOLOv5s-EfficientLite0	0.872	0.786	43.6
YOLOv5s-Mobilenetv3s	0.895	0.803	40.5
YOLOv5s-Shffule	0.868	0.795	40.2
Proposed method	0.961	0.895	35.7

从表 3 中可以看出, 本文改进算法综合性能最好, 准确率和检测平均精度分别达到 96.1% 和 89.5%, 达到了很高检测精度水平, 模型检测速度达到 35.7 FPS, 高于实

时检测的要求。与其他模型比较,改进模型检测速度相较 YOLOv5s-Shffule、YOLOv5s-Mobilenetv3s、YOLOv5s-EfficientLite 分别慢 4.5、4.8 和 7.9 FPS,但是本文改进模型准确率相比于其他模型分别高出 9.3%、6.6% 和 8.9%;平均精度分别高出 10%、9.2% 和 10.9%,证明改进模型在保证实时检测速度的同时具有很高的检测准确率。

3.5 纵向对比实验

为进一步验证本文所提方法的有效性,在相同实验环境下,将本文改进方法与 YOLOv3、YOLOv4、SSD、YOLOv5 等目标检测模型进行对比实验,测试绝缘子识别精度和识别速度等评价指标,实验性能对比如表 4 所示。

表 4 纵向对比实验

所用方法	Precision	mAP@0.5	模型大小	FPS
YOLOv3	0.901	0.758	235	21.3
YOLOv4	0.862	0.813	244	16.7
SSD	0.865	0.779	90.6	31.6
YOLOv5s	0.923	0.887	15.8	23.8
Proposed method	0.961	0.895	11.5	35.7

由表 4 中数据可以看出。首先,原始 YOLOv5s 模型和本文改进模型是纵向对比实验中绝缘子识别精度最

高的两种方法,分别达到了 88.7% 和 89.5%,YOLOv3 算法识别精度最低,仅为 75.8%,本文改进算法的准确率达到了 96.1%,同样达到了对比实验中最好的性能,满足输电线路绝缘子识别的精度要求。其次,本文算法在模型轻量化方面相较于 SSD、YOLOv3、YOLOv4 有着明显优势,本文算法模型大小仅为 11.5 MB,相较于 SSD 体积缩小了 87.3%,相较于 YOLOv3 和 YOLOv4 体积更是缩小了 95.1% 和 95.3%。本文改进模型和 SSD 模型是纵向对比实验中检测速度最快的两个模型,分别达到了 35.7 和 31.6 FPS,但 SSD 模型的识别精度太低,准确率为 86.5%、平均精度为 77.9%,无法满足实时输电线路绝缘子检测的精度要求,本文算法的检测速度达到 35.7 FPS,相较于原模型提升了 1.5 倍,相较于 YOLOv3 和 YOLOv4 提升了 1.7 倍和 2.1 倍。综上分析,本文改进模型通过在主干网络中引入 k3-BCSP 结构和 SE 注意力模块,在颈部使用 DC-BiFPN 模块替换原始特征提取网络使得绝缘子识别速度得到了很大的提升,精度方面也略有提升,能够满足日常检测绝缘子的精度和速度要求。图 11 为改进算法的检测结果,从图中可以清晰看出,原始算法与改进算法均能识别出不同类别的绝缘子目标,但在中间检测图中原始算法出现了误检情况,改进算法则表现出良好的效果,可见改进算法在识别准确率上略高于原始算法,且能有效改善模型误识别的问题。

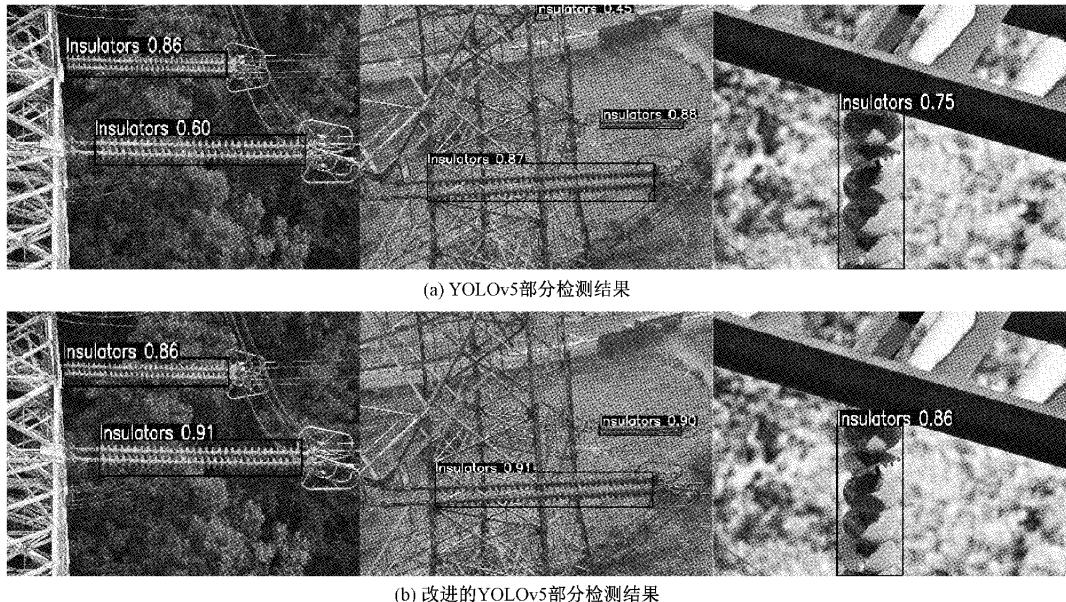


图 11 绝缘子检测结果对比图

4 结 论

针对输电线路中绝缘子识别精度低且识别速度慢的问题,提出一种改进的 YOLOv5 算法。将数据集中质量较差的图像样本通过超分辨率算法进行图像质量提升。使用 k3-BCSP 模块替换原始网络中的 BCSP 模块,减少模型

参数量,并在主干网络尾部引入 SE 注意力模块,保证模型检测精度。通过引入 DC-BiFPN 结构替换颈部网络的 PANet,提升模型对于空间布局的鲁棒性,以提升绝缘子目标检测效果。通过上文实验说明改进算法相较于原算法,检测速度得到很大提升,达到了 35.7FPS,在保证检测速度的同时,检测精度略有提升达到 89.5%。为下一步对

于绝缘子开裂、断串等故障进行缺陷检测提供了保证。

参考文献

- [1] 刘国特,伍伟权,郭芳,等.基于改进级联 Gentle Adaboost 分类器的支柱绝缘子红外图像 AI 识别[J].高电压技术,2022,48(3):1088-1095.
- [2] 彭向阳,梁福逊,钱金菊,等.基于机载红外影像纹理特征的输电线路绝缘子自动定位[J].高电压技术,2019,45(3):922-928.
- [3] 朱邵成,高清维,卢一相,等.基于频率调谐的绝缘子识别与定位[J].电工技术学报,2018,33(23):5573-5580.
- [4] HAN G J, HE M, ZHAO F, et al. Insulator detection and damage identification based on improved lightweight YOLOv4 network[J]. Energy Reports, 2021,7:187-197.
- [5] 刘行谋,田浩,杨永明,等.复杂环境背景下绝缘子缺陷图像检测方法研究[J].电子测量与仪器学报,2022,36(2):57-67.
- [6] 赵文清,程幸福,赵振兵,等.注意力机制和 Faster RCNN 相结合的绝缘子识别[J].智能系统学报,2020,15(1):92-98.
- [7] YAO L, QIN Y Y. Insulator detection based on GIOU-YOLOv3 [C]. 2020 Chinese Automation Congress(CAC), IEEE, 2020:5066-5071.
- [8] 宋万潼,李冰锋,费树岷.基于先验知识的航拍绝缘子检测方法[J].计算机工程,2021,47(8):301-307,314.
- [9] 易继禹,陈慈发,龚国强.基于改进 Faster RCNN 的输电线路航拍绝缘子检测[J].计算机工程,2021,47(6):292-298.
- [10] LIU C Y, WU Y Q, LIU J J, et al. Improved YOLOv3 Network for Insulator Detection in Aerial Images with Diverse Background Interference [J]. Electronics, 2021,10(7):771.
- [11] 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.
- [12] 胡根生,吴继甜,鲍文霞,等.基于改进 YOLOv5 网络的复杂背景图像中茶尺蠖检测[J].农业工程学报,2021,37(21):191-198.
- [13] 郝帅,马瑞泽,赵新生,马旭,文虎,安倍逸.基于超分辨率深度残差网络的玻璃绝缘子自爆故障检测算法[J].高电压技术,2022,48(5):1817-1825.
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020,42(8): 2011-2023.
- [15] 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.
- [16] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:8759-8768.
- [17] TAN M, PANG R, LE Q, et al. EfficientDet: Scalable and efficient object detection[J]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [18] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017:1251-1258.
- [19] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020,34(7):12993-13000.

作者简介

- 王素珍,博士,副教授,主要研究方向为计算机应用技术。
E-mail:417322899@qq.com
- 赵霖(通信作者),硕士研究生,主要研究方向为人工智能与图像处理。
E-mail:zhaolin28328@163.com
- 邵明伟,博士,讲师,主要研究方向为计算机视觉。
E-mail:373851680@qq.com
- 葛润东,硕士研究生,主要研究方向为图像处理。
E-mail:2061130584@qq.com