

DOI:10.19651/j.cnki.emt.2211208

基于深度学习的绝缘子故障检测研究

张彦生 王成龙 刘远红

(东北石油大学电气信息工程学院 大庆 163318)

摘要: 绝缘子是架空线路中重要组成部分之一,当出现故障时,影响电网安全运行。为实现绝缘子故障快速、精准的识别,提出了一种基于改进YOLOv3-Tiny的绝缘子故障检测方法。首先,为了增强小目标检测能力,对浅层特征图与第二检测层之前特征图进行同维拼接构建第三预测层。随后,该网络采用Ghost模块替换主干网络中的卷积层,降低模型的参数量。然后,设计了一个新的注意力模块MECA,不仅能够多尺度信息融合,还能使网络专注绝缘子的显著特征。最后,提出了新的交并比IoU作为边框回归损失函数,更好的定位目标位置。实验结果表明,改进的YOLOv3-Tiny在绝缘子故障检测中平均准确率(MAP)高达96.1%,较原始YOLOv3-Tiny算法MAP提高了17%。

关键词: 深度学习;卷积神经网络;YOLOv3-Tiny;绝缘子故障识别

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

Research on insulator fault detection based on deep learning

Zhang Yansheng Wang Chenglong Liu Yuanhong

(School of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163318, China)

Abstract: Insulator is one of the important components of overhead lines. When there is a fault, it will affect the safe operation of power grid. In order to realize rapid and accurate identification of insulator fault, an insulator fault detection method based on improved YOLOv3-Tiny is proposed. Firstly, in order to enhance the small target detection ability, the shallow feature map and the feature map before the second detection layer are spliced in the same dimension to construct the third prediction layer. Then, the network uses Ghost module to replace the convolution layer in the backbone network and reduce the parameters of the model. Then, a new attention module MECA (multiscale efficient channel attention) is designed to enable the network to focus on the salient characteristics of insulators. Finally, a new effective intersection over union (IoU) is proposed as the frame regression loss function to better locate the insulator position. The experimental results show that the average accuracy (MAP) of the improved YOLOv3-Tiny algorithm in insulator fault detection is as high as 96.1%, which is 17% higher than that of the original YOLOv3-Tiny.

Keywords: deep learning;convolutional neural network;YOLOv3-Tiny;insulator fault identification

0 引言

绝缘子需要长期的暴露在恶劣的环境中,输电线路上的绝缘子容易出现烧伤、破损等故障,会降低绝缘性能,严重影响电网的安全稳定运行^[1]。

随着智能电网的发展,使用无人机对输电线路进行巡检逐渐被人们关注^[2]。但是,采集到的图片和视频还需人工进行查阅,当前主要查阅方式是人眼观察,长时间工作会造成视觉疲劳和精力萎靡,容易发生故障遗漏、故障误报等问题^[3-4]。正是由于这个原因,许多学者提出了一些绝缘子的缺陷检测方法。

传统的绝缘缺陷检测方法主要是通过绝缘子图片的颜

色特征、外形轮廓等方法。文献[5]采用GrabCut算法对绝缘子进行分割,最后引入形态学处理方法对绝缘子缺陷进行识别。文献[6]使用轮廓特征和灰度相似度匹配的方法,能够对轮廓提取和绝缘子的各瓷片的分离,通过计算瓷片间距和灰度相似度来区分正常绝缘子和缺陷绝缘子。文献[7]采用HOG和SVM相结合的方法对绝缘子识别和定位。以上传统方法虽然可以对绝缘子进行识别,但是存在稳定性差、泛化能力弱、精度低等缺点。

近年来,随着深度学习的发展,在计算机视觉技术上取得了突出的成就^[8]。目前,主流的目标检测模型均是基于深度学习的方法,现有的比较具有代表性的目标检测算法有YOLO^[9],Fast R-CNN^[10],SSD^[11]等。将目标检测技术

应用到巡检图像中可以减少很大的人工肉眼识别的工作量,提高巡检效率,减少误判和漏检情况的发生^[12]。李发光等^[13]在 CenterNet 模型基础上用轻量级网络 EfficientNet 替代原始特征提取网络 ResNet,提高了模型对绝缘子缺陷的检测速度,但是精度略有下降,对小目标检测效果不是很好。马耀名等^[14]提出添加具有注意力机制动态选择机制网络,提高了检测精度,然而,检测速度相比于快速检测仍存在一定的差距。高伟等^[15]针对绝缘子缺陷样本问题,联合 SR-GAN 网络和 YOLOv4 算法用于绝缘子缺陷检测,提高了模型的泛化能力和检测精度。但是网络结构过于复杂,对计算机硬件要求更高。上述方法虽然能提高检测精度,但是具有实时性差、参数量大等缺点,很难部署于嵌入式设备。同时航拍绝缘子图片受一些因素影响,例如拍摄角度、拍摄距离、强光照、绝缘子所处环境复杂等。导致上述方法很难达到预期效果。

目前,YOLO 系列算法包含 YOLOv1-YOLOv5,虽然 YOLOv4^[16]和 YOLOv5 检测精度上表现较好,但网络结构复杂,对设备性能要求高。YOLOv3-Tiny 是 YOLOv3^[17]的简化版本,具有模型小和检测速度快等特点,更方便实际应用和大规模部署,但存在检测精度低和漏检等问题。

因此,本文以 YOLOv3-Tiny 为基础,针对存在的问题,提出了一种基于改进 YOLOv3-Tiny 的绝缘子故障检测方法。通过构建第三检测层,解决图片中小目标检测困难问题。提出一种新注意力模块,加入到特征提取网络中,使模型着重学习绝缘子重要特征,提高检测效果。通过采用轻量化模块替换原有的主干网络,降低计算复杂度,更好的适应于低性能设备。引入一种新的交变比函数,提高了检测精度和模型收敛速度。

1 YOLOv3-Tiny 网络简介

YOLOv3-Tiny 缩减了 YOLOv3 部分网络结构,具有模型结构简单,速度快等特点。YOLOv3-Tiny 网络主要包括 3 部分:特征提取网络,特征金字塔^[18]预测网络(feature pyramid networks,FPN)。特征提取网络主要由卷积层、BN 层和池化层组成,卷积核尺寸为 3×3 ,步长为 1,每个卷积层后面是池化层,尺寸为 2×2 ,步长为 2。FPN 特征金字塔对特征进行融合,原理是将特征提取网络输出的 13×13 特征图进行上采样后和 26×26 特征图进行同维拼接。最后输出的 13×13 和 26×26 特征图送入检测网络,进行目标的预测和定位。网络结构如图 1 所示。

2 改进的 YOLOv3-Tiny 网络

2.1 整体网络结构

对绝缘子数据集分析可知,航拍绝缘子图片受拍摄距离、背景复杂等影响,为提升网络对绝缘子检测的效果,以 YOLOv3-Tiny 网络结构为基础,本文提出了图 2 改进的 YOLOv3-Tiny 网络结构,改进如下:

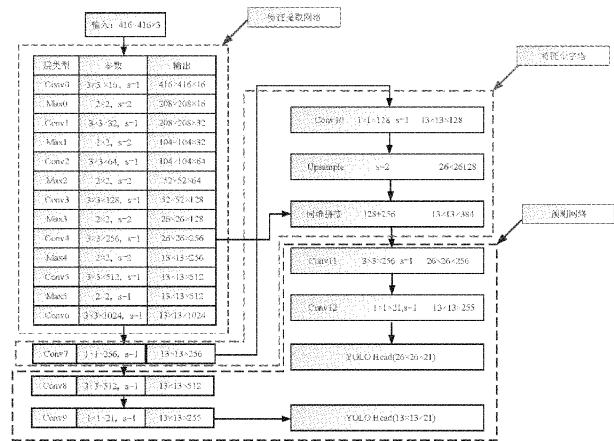


图 1 YOLOv3-Tiny 网络结构

- 1) 在特征提取网络部分加入 MECA 注意力机制模块,使网络不仅能够丰富绝缘子的特征信息,还能关注每个特征图的重要性,提高了特征图的表现能力。
- 2) 采用 Ghost 模块替换特征提取网络的卷积层,减少了模型的参数量和计算量。
- 3) 在原有的两分支检测层的基础上,构建了第三检测层,使模型能够更好的适用于小目标物体的检测。

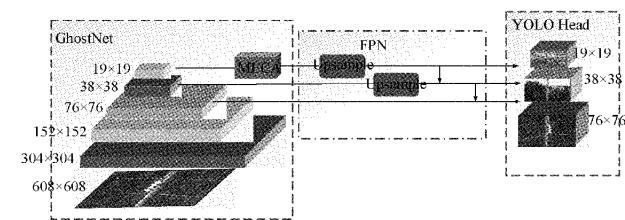


图 2 改进的 YOLOv3-Tiny 网络结构

2.2 融合浅层特征信息构建第三预测层

针对小目标检测,浅层网络提取的特征具有更好的定位能力,但是语义的表征能力比较弱;深度网络提取的特征包含丰富的语义信息,但是却容易丢失小目标的定位信息^[19]。YOLOv3-Tiny 网络的输入网络图像尺寸为 416×416 ,有 13×13 和 26×26 两种目标检测尺度,其中 13×13 的检测层适合对大目标进行检测, 26×26 目标进行检测。航拍的绝缘子图片,由于受拍摄距离等因素,绝缘子离无人机拍摄距离越远,会造成绝缘子在全景图中显示较小,很容易出现漏检现象。针对上述问题,本文将输入网络图像尺寸调整为 608×608 ,同时来自于浅层信息的特征与第 2 层同维拼接作为第 3 层。模型能够包含更多的浅层信息,提高对小目标的检测能力,最终检测尺度分别为 19×19 , 38×38 和 76×76 。

2.3 GhostNet 网络

GhostNet 网络具有保持图像相似性特征和减少卷积参数量的优势,由于绝缘子有许多相似特征信息,用 GhostNet 网络替换原有特征网络,不仅可以保持检测精度,同时还能降低模型的参数量。本文采用 GhostNet^[20]替

换 YOLOv3-Tiny 主干网络, 通过删减一部分的冗余特征图, 用来降低特征图的冗余信息, 使模型轻量化。

GhostNet 网络的核心思想主要分为 3 部分:

- 1) 采用卷积操作对输入特征图进行压缩。
- 2) 对压缩特征图进行线性变换获得一部分特征图。
- 3) 对压缩特征图和线性变换得到的特征图采用同维拼接操作。

Ghost 模块原理如图 3 所示。

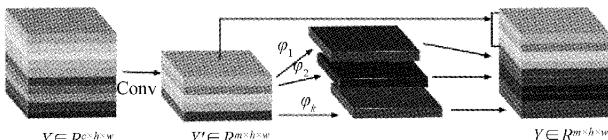


图 3 Ghost 模块原理

具体公式如下:

$$Y' = X \times f' \quad (1)$$

其中, $X \in R^{c \times h \times w}$ 表示卷积输入的特征图, 通道数为 c , 尺寸为 $h \times w$, $f' \in R^{c \times k \times k \times m}$ 表示为 m 个尺寸为 $k \times k$ 的卷积核, 其中每个卷积核的通道数为 c 。

$$Y_{ij} = \varphi_{ij}(Y'_i), i \in [1, m], j \in [1, s] \quad (2)$$

其中, $Y' \in R^{h \times w \times m}$, Y'_i 表示 Y' 中的第 i 张特征图, Y_{ij} 是 i 张特征图通过线性变换 φ_{ij} 生成的第 j 张特征图, s 是每张特征图通过线性变换生成特征图的个数。

假设输入特征图的尺寸 $h \times w$, 通道数为 c , 标准卷积尺寸为 K , GhostNet 第 1 部分卷积核尺寸为 K' , 第 2 部分卷积核尺寸为 K'' , 输出特征图为 $h' \times w' \times n$ 。

标准卷积为参数量约为:

$$K \times K \times c \times n \quad (3)$$

GhostNet 模块卷积为参数量约为:

$$K' \times K' \times c \times \frac{n}{2} + K'' \times K'' \times 1 \times \frac{n}{2} \quad (4)$$

2.4 MECA 注意力模块

在卷积神经网络中嵌入注意力模块可以提高对显著特征的提取能力^[21], 由于绝缘子数据集受拍摄距离和拍摄角度的影响, 航拍绝缘子图片中存在大量的无用信息。针对这个问题, 本文提出一种 MECA 注意力模块, 不引入大量计算量的同时提高模型的检测精度。

MECA 注意力模块主要分为 4 部分实现:

- 1) 通过 SPC 模块, 在输入特征图上获得具有多尺度特征信息的特征图。
- 2) 多尺度特征信息的特征图经过 ECA 模块, 提取含有不同尺度特征信息的重要特征。
- 3) 采用 Softmax 函数校准通道方向的注意向量, 获得重新校准权重。
- 4) 具有多尺度特征信息的特征图被校准后作为输出的特征图。

其中, H 和 W 是为特征图的高和宽, C 为通道数, 其

中 n 代表特征图被分裂成的个数, $\frac{C}{n}$ 是一个整数。

如图 4 所示, 是 MECA 注意力模块的整体网络结构图。在 MECA 模型中, SPC 模块用于实现输入特征图的多尺度的信息提取, SPC 模块运用多分支思想, 采用四个分支进行提取输入特征图的空间信息, 并且采用并行方式进行对不同尺度的特征图进行操作, 能够获得多尺度的特征信息。为了能够加强重要特征信息, 在 SPC 模块后引入注意力机制, 能够自适应关注重要区域, 从而提高模型识别绝缘子缺陷精度, 最后还采用 Softmax 激活函数, 进行通道方向校准, 获得多尺度通道校准权重, 最终每张特征图能够获得更丰富的特征信息。

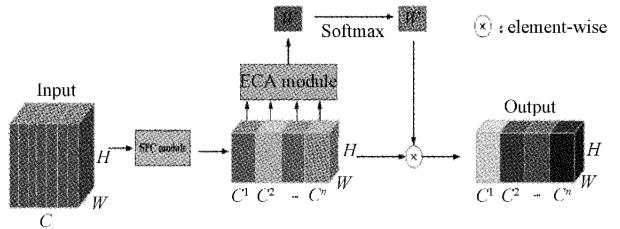


图 4 MECA 网络结构

SPC 模块的具体操作为: 首先对特征图进行 Split 操作, 把特征图分裂成几部分, 随后采用不同尺寸和组数的卷积核, 获取多尺度的特征信息, 最终采用同维拼接操作获得多尺度特征图。本文对特征图分裂成 4 部分, 卷积核尺寸分别采用 3, 5, 7, 9, 组数分别为 1, 4, 8, 16。图 5 是 SPC 模块的结构。

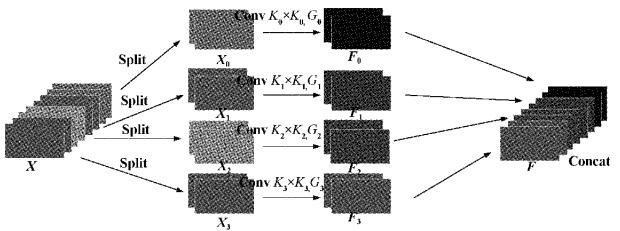


图 5 SPC 模块结构

图 5 中, X_i 为第 i 部分的特征图, K_i 为第 i 部分的卷积核尺寸, G_i 为第 i 部分的分组卷积的组数。

如图 6 所示是 ECA 注意力模块。

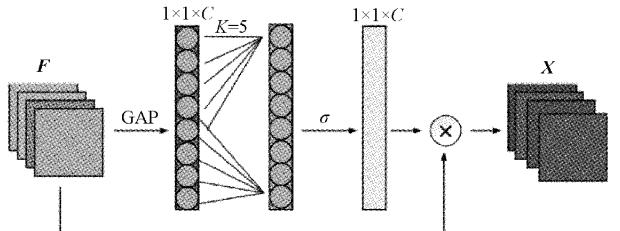


图 6 ECA 注意力模块

ECA 模块^[22]能够沿着通道维度产生注意力权重

$W \in R^{1 \times 1 \times c}$, 关注哪张特征图更有意义, 具体实现过程如下:

1)采用全局平均池化, 获得空间上的重要特征, 第 n 张特征图的全局池化操作为:

$$\mathbf{v}_n^{\text{ave}} = \frac{1}{h \times w} \sum_{i=1}^h \sum_{j=1}^w F_n(i, j) \quad (5)$$

式中: c 代表通道数, h 和 w 分别代表特征图的高度和宽度, $\mathbf{v}_n^{\text{ave}}$ 是第 n 张特征图的全局平均池化向量, (i, j) 表示特征图中某个点的坐标。

2)ECA 采用尺寸为 K 的 1D 卷积, 建立通道之间的相关性, 相比于大多数注意力模块, 采用全连接操作, ECA 注意力模块能够共享参数, 在降低计算量的同时, 保持高性能。具体公式如下:

$$W = \sigma(f_{1 \times 1}(\mathbf{v}^{\text{ave}})) \quad (6)$$

其中, $f_{1 \times 1}$ 是 1D 卷积操作, σ 是 Sigmoid 激活函数

3)最终获得的特征图为:

$$X = F \times W \quad (7)$$

式中: 输入特征图 $F \in R^{c \times h \times w}$, 输出特征图 $X \in R^{c \times h \times w}$ 。

2.5 EIoU 损失函数设计

YOLOv3-Tiny 模型中使用的是交变比 IoU (intersection over union), IoU 被广泛的应用在大多数目标检测算法中, 作为边框回归损失函数^[23]。但存在一些问题:

1)当预测框与真实框没有相交 $\text{IoU}=0$, 此时梯度无法计算。

2)存在预测框和真实框相交情况不同, 但是 IoU 却相等, 导致无法反映出预测框和真实框的实际情况。

针对上述问题, 提出了一个新的损失函数 EIoU, 同时考虑 3 个重要因素: 重叠区域, 中心点距离, 长宽的一致性。具体公式如下:

$$L_{\text{EIoU}} = 1 - \text{IoU} + \frac{\rho^2(\mathbf{b}, \mathbf{b}^{\text{gt}})}{c^2} + \beta \frac{\rho^2(w, w^{\text{gt}})}{C_w^2} + \gamma \frac{\rho^2(h, h^{\text{gt}})}{C_h^2} \quad (8)$$

其中, \mathbf{b} 、 \mathbf{b}^{gt} 分别为预测框和真实框的中心点, ρ 代表计算欧氏距离, c 代表预测框和真实框最小的外接矩形的对角线距离, w, w^{gt} 分别是预测框和真实框的宽, h, h^{gt} 分别是预测框和真实框的高。 C_w 和 C_h 分别代表预测框和真实框最小的外接矩形的宽和高。 β 和 γ 是平衡系数, 具体公式如下:

$$\beta = \frac{\frac{\rho^2(w, w^{\text{gt}})}{C_w^2}}{(1 - \text{IoU}) + \frac{\rho^2(w, w^{\text{gt}})}{C_w^2}} \quad (9)$$

$$\gamma = \frac{\frac{\rho^2(h, h^{\text{gt}})}{C_h^2}}{(1 - \text{IoU}) + \frac{\rho^2(h, h^{\text{gt}})}{C_h^2}} \quad (10)$$

引入 β 和 γ , 能够使重叠区域调节具有较高的优先级,

当 IoU 小的时候, 在 EIoU 损失函数中, 中心点距离调节起到主要调节作用, 这能够倾向于预测框和真实框重叠区域增多方向优化。

3 实验和结果分析

本文实验采用的操作系统是 Windows10 系统, CPU 是 intel core i7-6850K, GPU 是 Nvidia TITAN Xp 显卡, 深度学习框架 Pytorch1.8, 另安装环境 CUDA11.0 + OpenCV。实验采用绝缘子数据集, 数据集标签分别为 true、defect 两类。训练集和验证集按照 9 : 1 划分, 训练前, 采用了旋转、灰度化等操作对数据集进行处理。在训练过程中采用了 Mosaic 数据增强方法, 初始学习率 0.001, 权重衰减为 0.0005, 动量值为 0.937, 批尺寸设置为 6, 最大训练轮数为 300, IoU 阈值 0.5。

3.1 数据处理

原始数据集是由 2 000 张无人机拍摄的高清图片构成, 其中全部为 35 kV 所用的陶瓷绝缘子, 图 7 为无人机现场采集的绝缘子图片, 图 7(a)为正常绝缘子, 图 7(b)为缺陷绝缘子。现场拍摄的正常绝缘子 1 400 张, 缺陷绝缘子 30 张。之后采用了灰度化、旋转操作, 生成一部分图片作为数据集, 生成图片如图 8 所示。最终训练集包含 2 700 张绝缘子图片。验证集由 300 张图片组成, 训练集中所有图片采用 labelImg 标注软件进行标注, 所有标签格式均采用 VOC2007 格式。

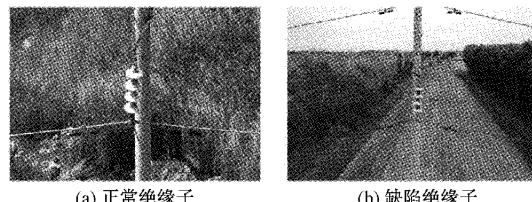


图 7 无人机现场采集的绝缘子图片

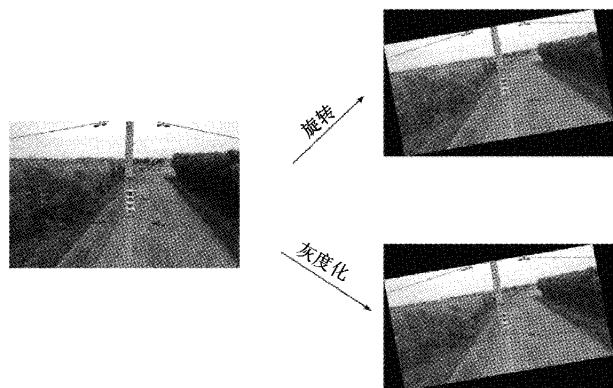


图 8 缺陷绝缘子图片生成

3.2 Mosaic 数据增强

Mosaic 数据增强是对 4 张图片进行拼接, 同时每张图片上仍然具有目标对应的真实框的信息, 然后将 4 张图片

拼接成新的图片,作为网络的训练数据。Mosaic 大大丰富了训练数据集,同时缩放图片会增加小目标物体,能够提高模型的鲁棒性。实现过程如图 9 所示。

3.3 训练模型结果分析

实验中采用平均精度均值(mAP)作为评价模型有效性指标。训练所得实验结果如表 1 所示。

GHostNet-1 是主干网络的卷积层全部用 Ghost 模块进行替换。从表 1 结果可以看出,GHostNet-1 能够很好的降低模型的大小,减少参数量,但是检测精度下降严重。因

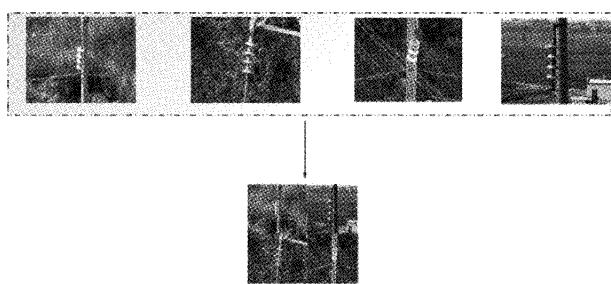


图 9 Mosaic 数据增强

表 1 消融实验结果

模型	Precision/%	Recall/%	mAP/%	mAP 提升/%	模型大小
YOLOv3-Tiny(A)	63.1	82	79.1	0	33.9 M
A+3 检测头(B)	63.3	84.7	80.1	1	35.2 M
B+GHostNet-1	51	66.8	58.9	-20.2	12 M
B+GHostNet-2(C)	58.2	82.2	75.7	-3.4	13.4 M
C+MECA(D)	70.6	86.4	82.7	3.6	24.4 M
D+EIoU(E)	69.9	86.4	84.4	5.3	24.4 M
E+Mosaic	70.4	94.9	96.1	17	24.4 M

此本文只针对主干网络中 512 和 1 024 个数的卷积核进行替换,得到 GHostNet-2 网络结构。GHostNet-2 能够在保证精度的前提下,减少大量参数量。当网络中加入 MECA 注意力模块,mAP 提高了 7%,用 EIOU 损失函数替换原有损失函数,mAP 提高了 1.7%。最终,改进的 YOLOv3-Tiny 比 YOLOv3-Tiny 的 mAP 提升 17 个百分点,模型大小减少了 8.9 M,准确率提升明显,应用在绝缘子缺陷检测上,相比于 YOLOv3-Tiny,能很好的解决准确率低,漏检等问题。

分别对 YOLOv3-Tiny 和改进的 YOLOv3-Tiny 训练得到的模型进行绝缘子图片检测,检测效果如图 10 所示。

在模型检测中,对比两种模型对 3 幅图片的检测效果,图 10(a)是 YOLOv3-Tiny 的效果图,图 10(b)是改进的 YOLOv3-Tiny 的效果图,YOLOv3-Tiny 检测置信度在 0.65~0.75,从第 3 幅图可以看出,由于绝缘子的所处的背景比较复杂,并且缺陷部位比较小,造成 YOLOv3-Tiny 算法出现误检现象,而改进的 YOLOv3-Tiny 模型,通过引入注意力模块,更关注缺陷重要特征信息,从而能很好的解决误检现象,检测置信度在 0.85~0.95,相较于原始 YOLOv3-Tiny,改进的模型在置信度上有所提升,在复杂

环境中和小目标缺陷均有更好的检测效果。

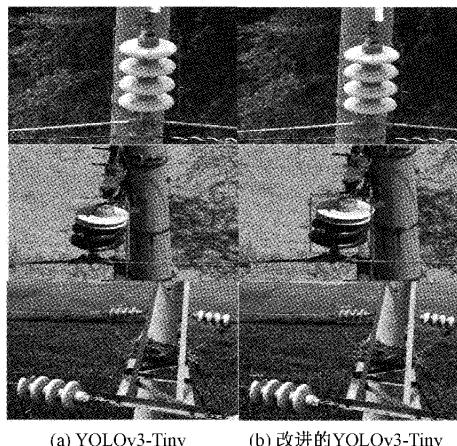


图 10 检测结果对比图

为更好的验证本模型的有效性,本文采用公开绝缘子数据集-中国电力线绝缘子数据集(CPLID)进行实验,同时和实际应用中比较常用的检测算法(YOLOv4-Tiny, YOLOv3)进行对比。实验结果如表 2 所示。

表 2 不同网络效果对比

模型	Precision/%	Recall/%	mAP/%	推理时间/ms	模型大小/M
YOLOv3-Tiny	69.9	93.8	88.3	8.7	33.9
YOLOv3	68.0	100	99.5	50.8	246
YOLOv4-Tiny	74.6	99.3	95.8	8.9	23
本文	77.3	100	97.9	12.9	24.4

由表 2 可知,相较于 YOLOv3-Tiny, YOLOv3 和 YOLOv4-Tiny 算法,改进后 YOLOv3-Tiny 算法,速度和精度大幅度的提升,且模型权重文件较小,相较于 YOLOv3 精度略有降低,但是参数量大大减小。综合考虑检测速度和精度、模型大小等因素,改进后的 YOLOv3-Tiny 算法能更好的适用于绝缘子缺陷的检测。

YOLOv3-Tiny 和改进的 YOLOv3-Tiny 绝缘子图片检测效果如图 11 所示。

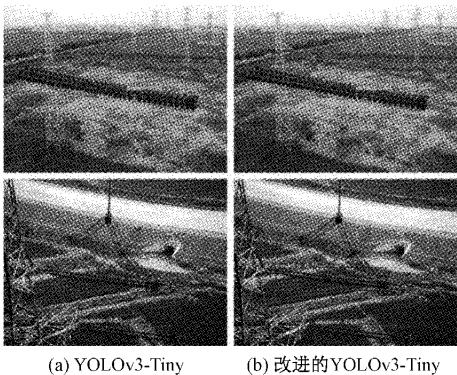


图 11 检测结果对比图

图 11(a)是 YOLOv3-Tiny 的效果图,图 11(b)是改进的 YOLOv3-Tiny 的效果图,从第 2 幅图可以看出 YOLOv3-Tiny 算法在较复杂背景下存在漏检的现象,而改进的 YOLOv3-Tiny 模型,能很好地解决漏检现象,相较于原始 YOLOv3-Tiny,改进的模型检测效果更好,漏检率更低。

4 结 论

本文提出了一种改进 YOLOv3-Tiny 算法用于对绝缘子缺陷的检测。改进后的 YOLOv3-Tiny 使用 Ghost 模块替换主干网络卷积层,大幅度减少模型的参数。在特征提取网络中加入了 MECA 注意力模块,不仅可以提取多尺度特征,还可以专注特征图中有效信息。最后,我们采用 EIOU 改进损失函数,可以增强定位效果。与 YOLOv3-Tiny 的网络相比,改进后的网络的 MAP 提高了 17%。实验结果表明,改进后的 YOLOv3-Tiny 模型检测精度更高,更适合用于绝缘子缺陷检测的实际应用。

参考文献

- [1] 肖粲俊,潘睿志,李超,等.基于改进 YOLOv5s 绝缘子缺陷检测技术研究[J].电子测量技术,2022,45(24):137-144.
- [2] 张海华,陈昊,许驰,等.变电站立体智能巡检新技术研究与应用[J].湖北电力,2021,45(1):41-46.
- [3] 张明路,郭策,吕晓玲,等.改进的轻量化 YOLOv4 用于电子元器件检测[J].电子测量与仪器学报,2021,35(10):17-23.
- [4] 陈文浩,姚利娜,李丰哲.无人机电网巡检中的绝缘子缺陷检测与定位[J].计算机应用,2019,39(S1):210-214.
- [5] 左钰,刘伟,马玉骐,等.基于改进 GrabCut 的绝缘子缺陷检测[J].计算机工程与设计,2021,42(7):2009-2015.
- [6] TAN P, LI X F, XU J M, et al. 基于轮廓特征及灰度相似度匹配的接触网绝缘子缺陷检测(英文)[J]. Journal of Zhejiang University-Science A (Applied Physics & Engineering), 2020, 21(1):64-73.
- [7] 李岩.基于 HOG 特征和 SVM 的绝缘子识别与定位[J].交通运输工程与信息学报,2015,13(4):53-60.
- [8] 高明华,杨璇.基于改进卷积神经网络的交通目标检测方法[J].吉林大学学报(工学版),2022,52(6):1353-1361.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [10] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [11] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [12] 解尧婷,张丕状.基于改进的 YOLOv4 输电线路小目标检测[J].国外电子测量技术,2021,40(2):47-51.
- [13] 李发光,伊力哈木·亚尔买买提.基于改进 CenterNet 的航拍绝缘子缺陷实时检测模型[J].计算机科学,2022,49(5):84-91.
- [14] 马耀名,张雨.基于改进 Faster-RCNN 的绝缘子检测算法[J].计算机应用,2022,42(2):631-637.
- [15] 高伟,周宸,郭谋发.基于改进 YOLOv4 及 SR-GAN 的绝缘子缺陷辨识研究[J].电机与控制学报,2021,25(11):93-104.
- [16] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv:2004.10934.
- [17] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. ArXiv Preprint, 2018, ArXiv:1804.02767.
- [18] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.
- [19] 李晨瑄,钱坤,胥辉旗.基于深浅层特征融合的舰船要害关键点检测算法[J].系统工程与电子技术,2021,

- 43(11):3239-3249.
- [20] 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.
- [21] 杨昆,常世龙,王尉丞,等.基于sECANet通道注意力机制的肾透明细胞癌病理图像ISUP分级预测[J].电子与信息学报,2022,44(1):138-148.
- [22] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020.
- [23] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]. Proceedings of the AAAI Conference on Artificial Intelligence,2020, 34(7): 12993-13000.

作者简介

张彦生,副教授,博士,主要研究方向为机器学习、轴承故障诊断研究。

E-mail:2465020142@qq.com

王成龙(通信作者),硕士研究生,主要研究方向为机器视觉与缺陷检测。

E-mail:1346620166@qq.com