

DOI:10.19651/j.cnki.emt.2211223

基于邻域信息交互的任意角度航拍绝缘子检测^{*}

李冰峰^{1,2} 张家欣^{1,2} 卜旭辉^{1,2}

(1. 河南理工大学电气工程与自动化学院 焦作 454000;

2. 河南理工大学河南省煤矿装备智能检测与控制重点实验室 焦作 454000)

摘要: 航拍绝缘子图像存在背景复杂、绝缘子空间方向多变且其自身具有大长宽比的特点,采用传统水平矩形框目标检测算法对航拍绝缘子进行检测,会引入大量的背景信息,导致定位绝缘子缺陷等后续操作变得更为困难。为此,本文提出了一种基于邻域交互注意力的任意角度航拍绝缘子检测方法。本文方法在现有的绝缘子检测框架中加入了目标边界框的角度预测分支。角度预测分支的引入,使得该方法对网络特征表达能力提出了更高的要求,为此,本文提出了一种邻域信息交互注意力机制,并通过该机制来建模绝缘子空间信息关系,从而实现对航拍绝缘子的精准检测。试验结果表明,本文提出的方法能够精准检测复杂环境中的绝缘子,检测精度达到了93.5%,有效避免了大量背景信息对绝缘子缺陷检测的干扰。

关键词: 目标检测;绝缘子;邻域信息交互;角度预测

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 520.6

Arbitrary angle aerial photography insulator detection based on neighborhood information

Li Bingfeng^{1,2} Zhang Jiaxin^{1,2} Bu Xuhui^{1,2}

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454000, China;

2. Henan Key Laboratory of Intelligent Detection and Control of Coal Mine Equipment, Henan Polytechnic
University, Jiaozuo 454000, China)

Abstract: Aerial insulator images are characterized by complex background, variable spatial direction of insulators and large aspect ratio. A large amount of background information will be introduced to detect aerial insulators using the traditional horizontal rectangular box object detection algorithm, which makes it more difficult to locate insulator defects and other subsequent operations. Therefore, this paper proposes an arbitrary angle aerial insulator detection method based on neighborhood interactive attention. The method in this paper adds the angle prediction branch of the object bounding box to the existing insulator detection framework. The introduction of angle prediction branch makes the method put forward higher requirements for network feature expression ability. Therefore, a neighborhood information interactive attention mechanism is proposed in this paper, and the spatial information relationship of insulators is modeled through this mechanism, so as to achieve accurate detection of aerial insulators. The test results show that the proposed method can accurately detect insulators in complex environments, and the detection accuracy reaches 93.5%, which effectively avoids the interference of a large amount of background information on insulator defect detection.

Keywords: insulator;object detection;neighborhood information interaction;angle prediction microscopic

0 引言

架空输电线路作为电力能源输送的载体,由线路塔杆、导线、绝缘子、线路金具、拉线、塔杆基础、接地装置等构成。

绝缘子作为输电线路中机械支撑和电气绝缘部件,对输电线路安全稳定运行至关重要。但由于绝缘子长期处于恶劣的自然环境中,容易发生掉串、裂纹、破损等故障,导致其机械强度和绝缘性能下降。因此及时对绝缘子进行检测以及

收稿日期:2022-08-30

*基金项目:河南省科技攻关项目(222102210230)、河南理工大学博士基金(B2018-33)项目资助

维护变得至关重要^[1]。早期的绝缘子运行状态及缺陷检测多依赖人工巡检的方式,但其存在检测效率低、危险性高等缺点。随着无人机技术发展、计算机硬件运算能力的提升及人工智能算法研究的深入,基于航拍图像的绝缘子缺陷检测逐渐成为绝缘子巡检的主流,而绝缘子缺陷检测强依赖于绝缘子目标检测^[2]。因此,研究基于航拍图像的绝缘子检测方法具有重要的现实意义。

早期的绝缘子检测算法多是基于传统计算机视觉方式。其流程一般包括:图像预处理、人工设计的特征提取、基于传统机器学习方法的分类或检测。赵振兵等^[3]利用绝缘子串的形状特征,采用边缘检测的方法对绝缘子进行定位。黄宵宁等^[4]利用绝缘子颜色特征和形态学特征,采用最大熵阈值的方法进行图像分割,最后使用连通区域方法标识绝缘子轮廓。该类方法的优点是方法简单且计算负担小。但由于该类算法采用人工设计的特征,其特征表达的泛化能力较差,只能在特定场景下使用,实际航拍图像中绝缘子背景相对较复杂,该类方法很难满足大多数实际工程需求。

随着深度神经网络理论的发展,基于深度学习的目标检测方法已逐渐成为主流。陈庆等^[5]采用卷积神经网络,结合超像素分割和绝缘子轮廓检测,实现对绝缘子检测。刘行谋等^[6]在 YOLOv4^[7]的基础上,利用 K-means 聚类算法对绝缘子图像样本进行聚类,实现了较好的检测效果。李发光等^[8]采用 CenterNet^[9]对输电线路绝缘子进行检测,得到了较高的检测精度。

上述基于深度神经网络的绝缘子检测算法检测效果有所提升,但由于其采用的水平检测框对绝缘子进行检测,对于航拍图像中角度任意、大长宽比的绝缘子来讲,如图 1 中虚线检测框所示,水平检测框无法准确定位绝缘子的位置,导致引入大量复杂背景信息,这在很大程度上增加后续绝缘子缺陷检测等任务的难度甚至出现误判。因此本文采用具有角度信息的倾斜框对绝缘子进行检测,可以实现对绝缘子更为精准的检测,有利于进一步在绝缘子上进行缺陷检测。然而角度信息的引入,提高了其目标检测表达的自由度,同时也对网络的特征提取能力提出了更高的要求。针对上述问题,本文构建了基于邻域信息交互的任意角度航拍绝缘子检测模型。

1 算法框架

1.1 总体框架

本文所提出的任意角度的绝缘子目标检测网络模型主要分为特征提取模块、解码器和检测头 3 个部分,算法整体框架如图 1 所示。其中,特征提取模块用于实现对输入图像的特征提取,以获取图像的高级语义特征,本文采用 Resnet50^[10]作为特征提取网络。解码器部分通过三次反卷积进行上采样,从而得到高分辨率特征图。检测头部分利用热力图对目标的中心点位置进行预测,然后对中心点

位置处的目标类别、位置偏置、目标的尺寸和空间倾斜角度进行关联,最终解析得到绝缘子的预测框。

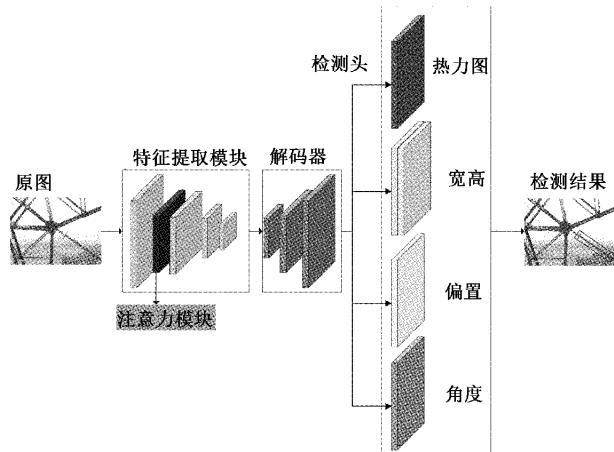


图 1 绝缘子检测模型结构

1.2 角度预测分支

为获取任意角度的矩形边界框,本文在目标检测网络中设计了一个新的边界框角度预测分支,用于实现对其角度的预测。本文采用具有任意角度的矩形边界框来描述绝缘子的位置信息,其表示方法如图 2 所示。该边界框采用 (C_x, C_y, L, B, θ) 五元组来进行描述;其中, (C_x, C_y) 表示边界框的中心点坐标, (L, B) 表示边界框的长和宽, θ 表示边界框的长边与垂直正方向的夹角,边界框顺时针旋转, θ 的取值范围为 $[0, \pi)$ 。

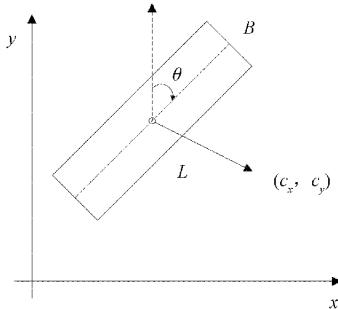


图 2 任意角度矩形边界框

为了获得矩形边界框角度的预测值 $\hat{\theta}$,本文设计了一个轻量化的角度预测分支网络,其结构如图 3 所示。角度预测分支网络以解码器的输出作为输入,然后经过一个卷积核为 3×3 的二维卷积和 ReLU 激活函数,随后将其计算结果送入一个卷积核为 1×1 的二维卷积,即可得到角度的预测图。

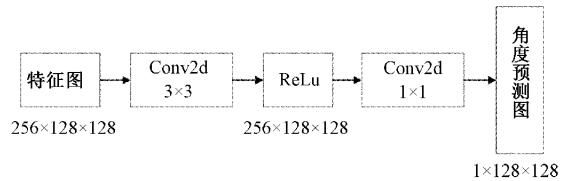


图 3 角度预测分支网络结构

为了获取相应网络的权重参数,本文采用 L_1 损失函数来衡量预测角度与真实角度的差值,并在此基础上进行参数优化。 L_1 损失函数的表达式如式(1)所示。

$$L_{ang} = \frac{1}{N} \sum_{k=1}^N |\hat{\theta}_k - \theta_k| \quad (1)$$

其中, N 表示输入图像中包含的绝缘子的数量。 $\hat{\theta}_k$ 、 θ_k 分别表示表示图像中第 k 个绝缘子角度的预测值和真实值。

1.3 邻域信息交互注意力机制

1) 视觉注意力机制分析

角度预测分支的引入,能实现对绝缘子更为精准的检测,可以有效避免水平检测框引入大量复杂背景信息的干扰,但同时需要网络更好的建模绝缘子空间关系,并提高其特征提取的能力,因此本文提出了邻域信息交互注意力(neighborhood interactive attention, NIA)机制来更加精准的建模绝缘子空间关系,并将它融入在特征提取网络,显著提高了算法的特征表达能力。

视觉注意力机制整体上可分为通道注意力和空间注意力。其中,通道注意力主要目的是对特征图的不同通道施加不同的权重。例如,Hu 等^[11]提出的一种紧凑的挤压激活网络(squeeze-and-excitation, SE)-Net。SE-Net 通过全局平均池化来高效的聚合特征图的二维全局信息,然后通过压缩和扩展操作,来构建通道之间的相互依赖关系。随着注意力机制的不断发展,空间注意力和通道注意力的融合逐渐成为主流。如:Woo 等^[12]提出的注意力机制(convolutional block attention module, CBAM)在构建通道依赖关系的同时引入空间信息编码。

为了在构建通道之间的相互关系的同时,充分考虑到空间位置信息的重要性。Hou 等^[13]提出了一种将位置信息嵌入到通道注意力中的轻量级坐标注意力机制(coordinate attention network, CA-Net)。但 CA-Net 采用 1×1 的二维卷积核在上述两个方向进行卷积运算,其本质仅是进行了通道调整,而无法获取通道和空间邻域交互信息。

2) 邻域信息交互注意力机制网络结构

为尽可能的捕捉每个通道空间相邻位置之间的依赖关系,又可以捕捉到每个空间位置相邻通道之间的依赖关系,本文设计了注意力机制(neighborhood interactive attention, NIA-Net),结合本文的应用场景,NIA-Net 应满足如下 3 个特点:1)尽可能减少参数量,以更好地部署到网络中;2)由于跨通道的空间位置信息之间没有较强的相关性,在捕捉空间邻域位置之间的信息交互时,应避免不同通道之间信息的干扰;3)建立通道之间的依赖关系。NIA-Net 的整体网络结构如图 4 所示。

首先,输入特征图 $X \in \mathbb{R}^{C \times H \times W}$,沿着空间的 H 和 W 方向进行全局平均池化。池化后,第 c 个通道的 H 方向上第 h 位置的特征的表达式如式(2)所示。

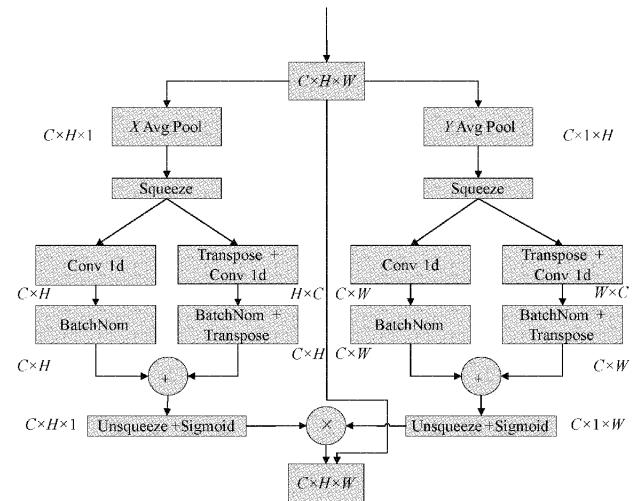


图 4 NIA-Net 注意力机制

$$Z_c^h(h) = \frac{1}{W} \sum_{j=1}^W x_c(h, j) \quad (2)$$

同样的,第 c 个通道的 W 方向上第 w 位置的特征如式(3)所示。

$$Z_c^w(w) = \frac{1}{H} \sum_{i=1}^H x_c(i, w) \quad (3)$$

然后,对式(2)和(3)的结果进行维度挤压,得到两个具有方向感知能力的矩阵 $Z(h) \in \mathbb{R}^{C \times H}$ 和 $Z(w) \in \mathbb{R}^{C \times W}$ 。

实际上,只有在某同一通道的空间邻域信息才具有较强关联性,而将所有通道空间邻域信息进行融合,损失了不同通道空间邻域信息的多样性,这会对空间邻域依赖关系的构建带来很大干扰。

为此,本文分别对 $Z(h) \in \mathbb{R}^{C \times H}$ 和 $Z(w) \in \mathbb{R}^{C \times W}$ 沿着通道维度进行分组一维卷积,分组的个数与通道数 C 相等,分组卷积的运算过程如式(4)所示。

$$\begin{cases} F_s(h) = f_s^{K_s^h}(Z(h)) \\ F_s(w) = f_s^{K_s^w}(Z(w)) \end{cases} \quad (4)$$

其中, $f_s^{K_s^h}$ 和 $f_s^{K_s^w}$ 分别表示在 H 和 W 方向上的一维分组卷积和批归一化(BatchNorm)运算, K_s^h 和 K_s^w 表示对应的卷积核, $F_s(h)$ 和 $F_s(w)$ 表示其对应运算结果,描述了沿着 H 和 W 方向上相邻空间信息的交互。

同时,为了捕捉相邻通道的特征信息的依赖关系,本文对 $Z(h) \in \mathbb{R}^{C \times H}$ 和 $Z(w) \in \mathbb{R}^{C \times W}$ 分别沿着 H 和 W 维度进行分组一维卷积,分组的个数分别为 H 和 W ,分组卷积的运算过程如式(5)所示。

$$\begin{cases} F_c(h) = f_c^{K_c^h}(Z(h)^T) \\ F_c(w) = f_c^{K_c^w}(Z(w)^T) \end{cases} \quad (5)$$

其中, $Z(h)^T$ 和 $Z(w)^T$ 表示 $Z(h)$ 和 $Z(w)$ 的转置运算, $f_c^{K_c^h}$ 和 $f_c^{K_c^w}$ 分别表示对 $Z(h)$ 和 $Z(w)$ 在通道方向上

的一维分组卷积和批归一化(BatchNorm)运算, K_c^h 和 K_c^w 表示对应的卷积核, $\mathbf{F}_c(h)$ 和 $\mathbf{F}_c(w)$ 表示其对应卷积运算结果, 描述了沿着通道方向上相邻信息的交互。

然后, 将空间邻域信息交互与通道邻域信息交互进行融合, 计算过程如式(6)所示。

$$\begin{cases} \mathbf{P}^H = \sigma(\mathbf{F}_s(h) + \mathbf{F}_c(h)) \\ \mathbf{P}^W = \sigma(\mathbf{F}_s(w) + \mathbf{F}_c(w)) \end{cases} \quad (6)$$

其中, $\mathbf{P}^H \in \mathbf{R}^{C \times H}$ 、 $\mathbf{P}^W \in \mathbf{R}^{C \times W}$ 。 σ 表示的是 sigmoid 函数, 其表达式如式(7)所示。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

然后将 \mathbf{P}^H 在 W 方向和 \mathbf{P}^W 在 H 方向进行扩展, 使其转换为 $\mathbf{P}_c^H \in \mathbf{R}^{C \times H \times 1}$ 、 $\mathbf{P}_c^W \in \mathbf{R}^{C \times 1 \times W}$ 。然后在第 i 个通道上, 将 $P_i^H \in R^{H \times 1}$ 和 $P_i^W \in R^{1 \times W}$ 相乘, 并将其结果与 $x_i \in \mathbb{R}^{H \times W}$ 进行点乘, 其公式化表述如式(8)所示。

$$y_i = x_i \otimes (P_i^H \times P_i^W) \quad (8)$$

NIA-Net 注意力机制的最终输出可表示为 $\mathbf{Y} = [y_1, \dots, y_C]$ 。本算法以更少的参数量和计算量有效的捕捉通道依赖关系和空间有效信息。

2 实验结果分析

2.1 实验环境

本文后续实验结果的实验环境描述如下: 硬件平台中 CPU 为 Intel Core i7-8700k, 内存为 32 GB, GPU 为 GTX 1080 Ti(共 2 块, 单卡显存为 16 GB), 操作系统为 Windows10, 深度学习框架采用 PyTorch。本文设计的数据集共包括 3 400 张图像, 在输电线路巡检时由无人机在真实场景下拍摄获得, 随后使用 LabelImg 工具的旋转框标注功能对倾斜绝缘子进行标注, 最后, 随机选取 2 700 张作为训练集, 余下的 700 张作为测试集。

本文所采用的网络结构, 除了增加了角度预测分支和 NIA-Net 部分之外, 其他部分与 CenterNet 完全一致, 在此不再赘述。在训练过程中, 每批次输入图片的张数(batch_size)设置为 4, 迭代次数(epoch)设置为 140, NIA-Net 中通道方向的卷积核大小(kernel_size)设置为 5, 空间方向的卷积核大小(kernel_size)设置为 3。

2.2 消融实验

为了验证 NIA-Net 在通道和空间邻域信息交互的有效性, 本文进行了相关的消融实验, 结果如表 1 所示。其中, SI (space intergrated NIA-Net)、SG(space group NIA-Net) 表示如式(4)所示的空间信息交互注意力机制, 但 SI 未采用分组卷积, 而 SG 则采用了分组卷积。CI(channel intergrated NIA-Net)、CG(channel group NIA-Net) 表示如式(5)所示的通道信息交互注意力机制, 但 CI 未采用分组卷积, 而 CG 则采用了分组卷积。

由表 1 可知, 不论采用空间还是通道的信息交互注意力机制, 网络的检测精度均有提高。同时对输入特征进行

表 1 NIA-Net 消融实验

SI	CI	SG	CG	AP
				91.5
✓				92.7
	✓			92.5
		✓		93.0
			✓	92.6
✓			✓	93.0
	✓	✓		93.1
✓	✓			93.0
		✓	✓	93.5

通道和空间邻域信息交互效果最好。而只对通道信息进行交互, 效果较差, 这是因为模型只能保存一定的空间位置信息, 而无法建立空间邻域信息的依赖关系。这使得网络无法有效地捕捉绝缘子位置信息和角度信息, 以及绝缘子与塔杆等关联物体空间相对关系。如果在进行空间信息交互时, 没有将空间特征按照通道独立性进行分组, 效果也比较差, 并且参数量也会增加, 这是因为空间信息的依赖关系在其特征信息的独立通道中有较强的关联性, 跨通道的空间邻域信息没有较强联系, 这使得模型在捕捉空间邻域信息时候带来较大干扰。

由表 2 可知, 将本文提出的注意力机制加在 layer1 层后效果最好。由于在神经网络的浅层, 网络捕捉的多为粗粒度信息, 此时输出特征信息含有丰富的空间位置信息。本文设计的注意力机制致力于捕捉空间邻域位置信息的依赖关系, 因此将该注意力机制融入特征提取网络的浅层, 可更有效地捕捉绝缘子的空间位置信息和角度信息。

表 2 邻域交互注意力机制加在不同 layer 层的对比

Layer1	Layer2	Layer3	Layer4	AP
✓				93.5
✓	✓			92.4
✓	✓	✓		92.2
✓	✓	✓	✓	92.8
✓			✓	92.2
		✓		92.2
			✓	91.9

2.3 对比试验

本文以 CenterNet 为基本框架, 特征提取部分采用了 ResNet50 模型, 在 ResNet50 的基础上融合本文提出的注意力机制, 该注意力机制为即插即用的轻量化模块。根据将该注意力机制加在网络的不同层的实验结果对比, 同时兼顾训练效率, 本文选择将该注意力机制加在 layer1 层后边。

为了验证本文算法的有效性, 将其与通道注意力

ECA-Net^[14]、SE-Net 以及空间和通道融合注意力 CBAM、CA-Net、SA-Net^[15]算法进行了比较。这些注意力机制加在特征提取网络中的位置均与本文提出的注意力机制所加位置一致,且实验参数设置与本文方法一致,实验结果如表 3 所示。

表 3 与其他注意力模型的对比

算法/阈值	Parameters/M	FLOPs	AP
ResNet50	23.501 9	60.235 9	91.5
ResNet50+ECA-Net	23.508 1	60.236 6	92.2
ResNet50+CA-Net	23.520 8	60.238 8	92.3
ResNet50+CBAM	23.516 6	60.238 2	92.0
ResNet50+SE-Net	23.516 1	60.237 1	91.8
ResNet50+SA-Net	23.508 2	60.236 6	92.8
ResNet50+NIA	23.508 2	60.236 4	93.5

R-CenterNet 与 5 种注意力机制的融合后在本文数据集上的测试结果如表 3 所示。相对于原始的目标检测算法,本文方法在增加忽略不计的参数条件下,对倾斜绝缘子的检测精度提升了 2%。这依赖于本文的注意力机制可以有效的捕捉到绝缘子的空间位置信息,以准确定位到绝缘子所在的目标区域,该机制还可以建模通道特征的依赖关系,这有助于网络对背景、塔杆、输电线等无用信息的抑制。

本文提出的邻域信息交互注意力机制模型相比于 CA-Net、CBAM、SE-Net 等的参数量显著减少,并且精度明显提升。相比于 SE-Net、ECA-Net 只采用全局平均池化来描述特征全局信息,无法对特征信息空间位置关系进行描述,本文对特征空间信息依赖关系也进行了建模。相比于 CA-Net 只是在建模通道依赖关系时保留了一定的空间位置信息,本文方法可以使空间邻域信息进行有效交互。实验表明,本文提出的空间邻域信息交互注意力机制在参数量更少的情况下取得了更好的效果。

2.4 算法性能分析

本文方法与 CenterNet^[8]方法训练时的损失值曲线对比,由图 5 可知本文方法能快速收敛,侧面反应了本文算法的优越性。

为了分析注意力机制对网络提取特征能力的影响,本文对特征提取网络输出层特征图进行可视化输出。本文选用不同倾斜角度的绝缘子以及各类复杂背景的航拍图像为例,并将注意力机制融合在以 Resnet50 为特征提取网络的目标检测算法中。如图 6 所示,特征可视化结果表明融合了邻域信息交互注意力机制的特征提取网络能更有效的提取绝缘子特征,颜色较深的部分更多的集中在绝缘子区域。值得注意的是,融合邻域信息注意力机制的特征提取网络能更有效的区分绝缘子和塔杆,有效避免塔杆的干扰。这表明了本文提出的注意力机制使网络可以更多的关注有效信息,进而更好地提取绝缘子特征。

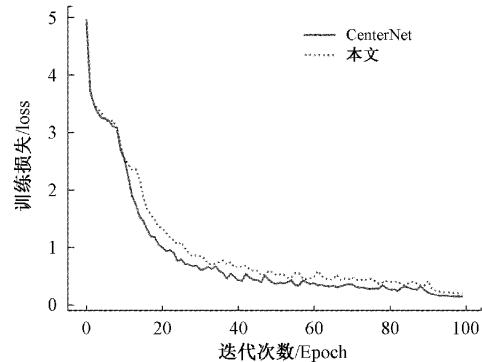


图 5 训练损失曲线

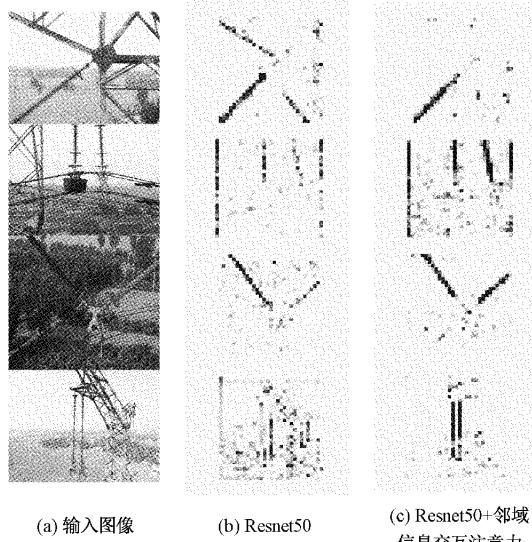


图 6 特征图可视化结果

2.5 检测结果展示

图 7 为不同检测方法的检测结果图。第 1 列为 CenterNet 检测方法的结果;第 2 列为加入角度预测分支的检测方法(R-CenterNet)检测结果;第 3 列为融入了邻域交

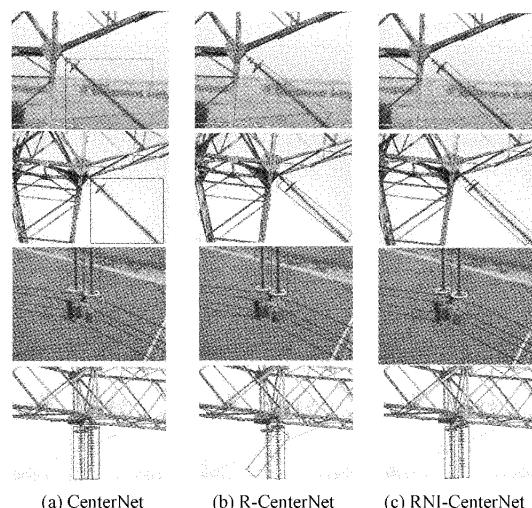


图 7 不同方法的检测结果

互注意力机制的旋转框检测方法(RNI-CenterNet)的检测结果。相较于本文算法,水平框检测算法在检测大长宽比且倾斜的绝缘子时,会将大量的背景信息视为目标,这对进一步在检测结果上进行故障诊断带来很大干扰。本文提出的融入注意力机制的 RNI-CenterNet 算法在绝缘子倾斜角度预测、宽高预测中达到更好的效果,这得益于本文提出的邻域信息交互注意力机制能更好的捕捉绝缘子与背景信息的空间关系。

3 结 论

本文提出一种基于中心点和邻域信息交互的倾斜绝缘子检测算法 RNI-CenterNet,以解决绝缘子具有倾斜、大长宽比以及背景复杂等问题。本文提出的邻域信息交互注意力机制使用较小的代价,有效捕捉空间中任意一点与其相邻位置信息的依赖关系。该机制先沿水平方向和竖直方向的聚合输入特征信息,然后使用一维卷积分别沿着通道和空间方向进行邻域信息的交互。在建模空间邻域信息依赖关系的时候巧妙的使用分组卷积,避免不同通道间的信息干扰,同时减小计算成本。该机制能够有效的捕捉绝缘子与塔杆等的空间位置关系,这有利于目标检测网络识别并定位绝缘子。本文提出一种基于中心点和邻域信息交互的倾斜绝缘子检测算法 RNI-CenterNet,以解决绝缘子具有倾斜、大长宽比以及背景复杂等问题。本文提出的邻域信息交互注意力机制使用较小的代价,有效捕捉空间中任意一点与其相邻位置信息的依赖关系。该机制先沿水平方向和竖直方向的聚合输入特征信息,然后使用一维卷积分别沿着通道和空间方向进行邻域信息的交互。在建模空间邻域信息依赖关系的时候巧妙的使用分组卷积,避免不同通道间的信息干扰,同时减小计算成本。该机制能够有效的捕捉绝缘子与塔杆等的空间位置关系,这有利于目标检测网络识别并定位绝缘子。

参考文献

- [1] 邱志斌,阮江军,黄道春,等.输电线路悬式瓷绝缘子老化形式分析与试验研究[J].高电压技术,2016,42(4):1259-1267.
- [2] 彭向阳,陈驰,饶章权,等.基于无人机多传感器数据采集的电力线路安全巡检及智能诊断[J].高压电技术,2015,41(1):159-166.
- [3] 赵振兵,王乐.一种航拍绝缘子串图像自动定位方法[J].仪器仪表学报,2014,35(3):558-565.
- [4] 黄宵宁,张真良.直升机巡检航拍图像中绝缘子绝缘子图像的提取算法[J].电网技术,2010,34(1):194-197.
- [5] 陈庆,闫斌,叶润,等.航拍绝缘子卷积神经网络检测及自爆识别研究[J].电子测量与仪器学报,2017,31(6):942-953.
- [6] 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.

- [7] BOCHKOVSKIY A, WANG C Y, LIAO H M. Yolov4: Optimal speed and accuracy of object detection [J]. Computer Vision and Pattern Recognition, 2020, 17(9):198-215.
- [8] 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.
- [9] ZHOU X, WANG D, KRÄHENBÜHL P. Objects as points[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2019:474-490.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016:770-778.
- [11] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [12] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018:3-19.
- [13] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. Proceedings of the 2021 IEEE Conference on Computer Vision and Pattern Recognition, 2021.
- [14] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [15] ZHANG Q L, YANG Y. SA-Net: Shuffle attention for deep convolutional neural networks [C]. IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP), IEEE, 2021: 2235-2239.

作者简介

李冰峰,讲师,博士,主要研究方向为迁移学习、计算机视觉、目标检测。

E-mail:libingfeng@hpu.edu.cn

张家欣,硕士,主要研究方向为计算机视觉、目标检测。

E-mail:2438014771@qq.com

卜旭辉,教授,博士,主要研究方向为数据驱动控制、迭代学习控制、网络系统控制。

E-mail:buxuhui@gmail.com