

基于多尺度密集网络的配网架空输电线路绝缘子识别

陈志豪^{1,2*}, 肖业伟^{1,2**}, 李志强¹, 刘洋¹

¹湘潭大学自动化与电子信息学院, 湖南 湘潭 411105;

²湘潭大学智能计算与信息处理教育部重点实验室, 湖南 湘潭 411105

摘要 绝缘子为配网架空输电线路的重要组成部分,对无人机航拍的绝缘子图像进行精准识别是实现其缺陷检测和故障诊断的重要前提。针对图像中绝缘子目标小、背景复杂的问题,提出了一种基于多尺度密集网络的配网架空输电线路绝缘子识别算法。首先,利用 K -means 算法对数据集的目标框进行分析,获取合适的锚框;然后,将基础网络中的残差模块替换为密集连接模块,以增强网络特征信息的复用与融合,同时添加空间金字塔池化模块、优化多尺度特征融合,以对绝缘子进行预测;最后,用融合交叉熵函数和 Focal 损失函数的损失函数替换原始损失函数,构建航拍巡检图像数据集并进行实验。实验结果表明,相比原始算法,本算法的准确率提高了约 12 个百分点,且鲁棒性更强,基本满足电网巡检对绝缘子识别的要求。

关键词 图像处理; 多尺度; 密集网络; 空间金字塔池化; 损失函数

中图分类号 TP391.4; TM769

文献标志码 A

doi: 10.3788/LOP202158.0815003

Insulators Identification for Overhead Transmission Lines in Distribution Networks Based on Multi-Scale Dense Network

Chen Zhihao^{1,2*}, Xiao Yewei^{1,2**}, Li Zhiqiang¹, Liu Yang¹

¹ School of Automation and Electronic Information, Xiangtan University, Xiangtan, Hunan 411105, China;

² Key Laboratory of Intelligent Computing & Information Processing of Ministry of Education, Xiangtan University, Xiangtan, Hunan 411105, China

Abstract Insulators are an essential part of overhead transmission lines in distribution networks. Accurate identification of insulator images by drone aerial photography is an important prerequisite for defect detection and fault diagnosis. Aiming at the problem of small insulator targets and complex backgrounds in images, an algorithm for insulators identification on overhead transmission lines in distribution networks based on multi-scale dense networks is proposed in this paper. First, use the K -means algorithm to analyze the target frame of the dataset to obtain a suitable anchor frame. Second, replace the residual module in the basic network with a dense connection module to enhance the multiplexing and fusion of network feature information. At the same time, add a spatial pyramid pooling module and optimize multi-scale feature fusion to predict insulators. Finally, replace the original loss function with a loss function that combines the cross-entropy function and the Focal loss function to construct an aerial inspection image data set and perform experiments. The experimental results showed that the algorithm accuracy is improved by about 12 percentage points and has a stronger robustness than the original algorithm, which meets the requirements of the grid inspection for insulator identification.

Key words image processing; multi-scale; dense network; space pyramid pooling; loss function

收稿日期: 2020-08-05; 修回日期: 2020-08-29; 录用日期: 2020-09-09

基金项目: 国家自然科学基金(61773330)、湖南省自然科学基金(2017JJ2251)

* E-mail: zhihao630@126.com; ** E-mail: 10802795@qq.com

OCIS codes 100.3008; 150.1135; 100.4996

1 引言

绝缘子作为配网架空输电线路的重要组成部分之一,具有良好的电气绝缘隔离和机械保护支撑作用^[1]。绝缘子长期暴露在户外和恶劣气候环境下,容易出现破裂、污损等缺陷,其结构的完整性直接影响了配网架空输电线路的稳定性和安全性^[2-3]。由于城乡配电网的覆盖区域越来越广,人工巡检线路的工作效率低,且山区、农田、水塘等线路的巡检难度大^[4]。无人机具有安全、高效和准确等特点,已成为配电线路巡检的重要方式^[5]。利用无人机采集绝缘子图像并将计算机视觉技术应用到巡检图像中可以减少人工肉眼识别的工作量,提高巡检效率,也可以避免误判和漏检情况^[6]。应用于配网架空输电线路上的绝缘子有多种类型,如瓷质、悬式绝缘子和复合绝缘子,这些绝缘子的构成材料及外观结构不同,出现的故障类型也有所差异。如悬式绝缘子的自爆、掉串故障;瓷质绝缘子有放电痕迹;复合绝缘子的伞裙破损。因此,如何快速精准地对航拍配网架空输电线路图像中的绝缘子进行识别分类是实现绝缘子运行状态智能检测与故障诊断的基础^[7]。

传统的绝缘子检测技术主要通过手工设计的特征描述符提取图像特征,如支持向量机(SVM)^[8]、可变型部件模型(DPM)^[9]和方向梯度直方图(HOG)^[10]算法。赵俊梅等^[11]提出了一种利用像素统计法对绝缘子图像进行二值分割的算法,Qi等^[12]提出了一种基于轮廓分割的绝缘子检测算法。这些传统算法复杂度高、计算量大、实时性低,且鲁棒性和通用性较差,在工程应用中难以实现。深度卷积神经网络(CNN)具有适用性强、目标检测效率高等优点,自提出后迅速取代了传统算法在图像处理领域中的地位^[13],基于深度学习的模型也逐渐被应用到电网航拍巡检图像的目标检测与缺陷诊断上。李军锋等^[14]将随机森林与CNN相结合,首先用AlexNet对电力设备图像进行特征提取,然后用训练好的随机森林算法对该网络提取的特征进行分类,完成了多类电力设备的检测。程海燕等^[15]直接利用Faster区域卷积神经网络(R-CNN)模型对航拍绝缘子图像数据进行训练和检测,但该算法对较小的绝缘子目标存在漏检等问题。赵振兵等^[16]针对绝缘子遮挡等问题,在R-CNN模型中加入对抗空间网络(ASDN)对特征图部分生成掩码,得到了

更多遮挡的样本,从而提高模型对遮挡样本的检测效果。Wang等^[17]采用一种基于候选区域的单目多框检测(SSD)算法对绝缘子缺陷进行定位和识别。Chen等^[18]利用二级全卷积网络(SOFCN)对绝缘子进行故障检测,该算法在不需特征提取和分类器选择的情况下,能有效抑制复杂背景的干扰,获得较高的识别精度。

对于航拍巡检图像中绝缘子的识别与故障诊断,已有研究多关注高压输电线路绝缘子串的自爆与缺陷检测,对配网架空输电线路上的绝缘子检测研究较少;且航拍配网输电线路上的图像背景复杂,绝缘子目标较小,容易出现漏检和误判。针对上述问题,本文用适用性较强的YOLOv3(You only look once)网络作为基础网络,提出了一种基于多尺度(Multi-scale)密集网络的配网架空输电线路绝缘子识别算法,并构建了航拍配网架空输电线路绝缘子图像数据集进行训练和测试。实验结果表明,本算法能准确识别出巡检图像中的绝缘子,且鲁棒性和实用性较强。

2 YOLOv3 网络模型

航拍巡检数据集的图像背景和形态在不同拍摄角度下是复杂多样的,因此,需要选择一种稳定且高效的目标检测网络对其进行识别。Redmon等^[19]提出的YOLO网络用CNN直接预测不同目标的位置与类别。YOLOv2网络^[20]给所有卷积层(Conv)添加批标准化(BN),可抑制更多的冗余信息,但在目标重叠遮挡情况下的检测效果不佳。YOLOv3网络^[21]通过引入特征金字塔、残差结构以及改变模型结构等操作,使模型性能得到显著提升,其网络结构清晰,能在准确率较高的情况下对目标进行快速分类,可应用于实际工程中。

图1为基于YOLOv3网络的配网架空输电线路绝缘子检测算法原理,首先,将输入图像的尺寸缩放至416 pixel × 416 pixel;然后,将图像划分为S × S个网格后输入神经网络进行训练;最后,检查每个网格的边界框和置信度。YOLOv3网络采用Darknet-53的基础网络对图像进行特征提取,包含了53个卷积层,可获得更深层次的特征,如图2所示;同时借鉴残差网络(ResNet)^[22]的思想,在网络中加入5个残差块(Residual block),每个残差块中包含不同数量的残差单元^[23],并通过CBL

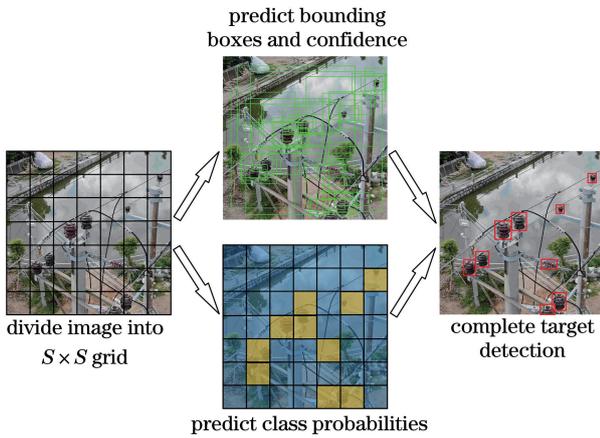


图 1 基于 YOLOv3 网络的绝缘子检测

Fig. 1 Insulator detection based on the YOLOv3 network

	type	filters	size	output
	Conv	32	3 × 3	416 × 416
	Conv	64	3 × 3/2	208 × 208
1 ×	Conv	32	1 × 1	208 × 208
	Conv	54	3 × 3	
	residual block			
	Conv	128	3 × 3/2	104 × 104
2 ×	Conv	64	1 × 1	104 × 104
	Conv	128	3 × 3	
	residual block			
	Conv	256	3 × 3/2	52 × 52
8 ×	Conv	128	1 × 1	52 × 52
	Conv	256	3 × 3	
	residual block			
	Conv	512	3 × 3/2	26 × 26
8 ×	Conv	256	1 × 1	26 × 26
	Conv	512	3 × 3	
	residual block			
	Conv	1024	3 × 3/2	13 × 13
4 ×	Conv	512	1 × 1	13 × 13
	Conv	1024	3 × 3	
	residual block			
	Avgpool		global	
	connect		1000	
	Softmax			

图 2 Darknet-53 的结构

Fig. 2 Structure of the Darknet-53

模块进行残差操作。其中, CBL 模块包括卷积、BN 和带泄露修正线性单元(Leaky ReLU)。基于特征金字塔网络(FPN)^[24]的思想, 本网络增加了多尺度的特征融合, 获得最小特征图后再进行两次上采样, 然后在 13 × 13、26 × 26、52 × 52 三个尺度下进行特征融合与预测。

3 检测算法

航拍配网架空输电线路图像中的绝缘子目标较小且背景复杂, 在实际巡检任务中, 传统目标检测算法存在漏检和误判等情况, 识别精度不高。考虑到

电网巡检任务的应用需求, 选用目前通用性较强、检测精度和实时性较好的 YOLOv3 网络进行改进并测试。首先, 用 K-means 算法对数据集中的目标框进行聚类分析, 获取合适的 anchor; 其次, 将基础网络的残差块替换为自定义的密集连接网络, 以增强图像的特征提取和复用; 然后, 添加空间金字塔池化(SPP)模块、优化多尺度特征融合以对绝缘子进行预测; 最后, 用一种融合交叉熵函数和 Focal 损失函数的损失函数替换原始损失函数, 解决了训练阶段数据集样本类别和复杂度不均衡的问题。

3.1 数据集目标框的改进

原始 YOLOv3 网络定义的 anchor 可适用于 COCO 数据集, 由于航拍巡检数据集中绝缘子目标框的宽高和原始定义不同, 直接使用会影响网络对绝缘子目标的检测速度和精度。合适的 anchor 不仅能消除候选框带来的误差, 还可以加快损失函数的收敛。因此, 利用 K-means 算法对航拍配网架空输电线路数据集中的绝缘子目标框进行聚类分析。

K-means 算法采用欧氏距离作为判别依据, 获得的 anchor 会使大包围框产生的误差比小包围框更大。IOU 为真实框(GT)与预测框(predicted box)的交并比, 可衡量预测边界框的准确性, 可表示为

$$X_{IOU} = \frac{|G \cap P_e|}{|G \cup P_e|}, \quad (1)$$

式中, G 为真实框, P_e 为预测框。重新定义 X_{box} 与 $X_{centroid}$ 之间的距离, 可表示为

$$D(X_{box}, X_{centroid}) = 1 - X_{IOU}(X_{box}, X_{centroid}), \quad (2)$$

式中, X_{box} 为数据集样本的目标框, $X_{centroid}$ 为簇的中心。目标聚类分析的依据为平均重叠度 Avg IOU, 其目标函数 f 可表示为

$$f = \operatorname{argmax} \frac{\sum_{a=1}^k \sum_{b=1}^{n_k} D(X_{box}, X_{centroid})}{n}, \quad (3)$$

式中, n_k 为第 k 个聚类中心的样本个数, n 为样本的总个数, k 为簇的个数, a, b 分别为样本和聚类中心样本的序号。

3.2 密集连接网络

在航拍绝缘子图像中, 受背景和光照的影响, 难以识别有些过度曝光图像中的目标, 且有些绝缘子目标较小。Darknet-53 在每次降采样中只使用较少的维度, 会丢失很多特征信息, 导致检测层特征图上目标信息量不足。本算法借鉴 DenseNet^[25] 的思想, 通过对图像特征的重复利用达到更好的识别效

果。更密集的网络结构,不仅可以进行层与层之间的信息传递,每一个卷积层还可以得到前面所有卷积层的信息,具体网络结构如图 3 所示。该网络与 ResNet 一样可以减轻梯度消失,加强图像特征的传递,泛化能力更好,且一定程度上可以减少参数量,使网络能更好地识别巡检图像中目标较小的绝缘子,获取更细致的特征,达到更好的分类效果。

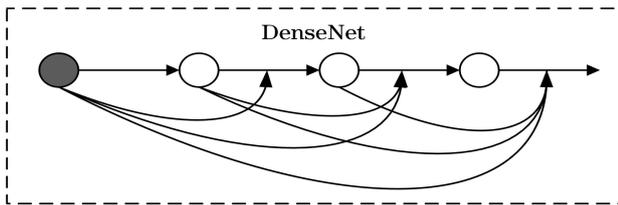


图 3 DenseNet 的结构

Fig. 3 Structure of the DenseNet

将原始 YOLOv3 网络中的残差网络模块替换为自定义的密集连接网络模块,构建一个有紧密连接的网络,使网络在预测之前能接收密集连接块输出的多层特征卷积,实现特征的复用与融合。密集连接块的输出可表示为

$$x_n = H_n[x_0, x_1, \dots, x_{n-1}], n = 1, \dots, 8, \quad (4)$$

式中, x_0 为模块的输入特征图, x_n 为第 n 层的输出, $[x_0, x_1, \dots, x_{n-1}]$ 为输入层到 $n-1$ 层特征图的拼接, 对于一个 n 层网络, 共包含 $n(n+1)/2$ 个连接。 H_n 为第 n 层的卷积结构, 即 CBL。密集连接结构如图 4 所示, 其中每个 Des unit 由两个不同尺寸的 CBL 组成。

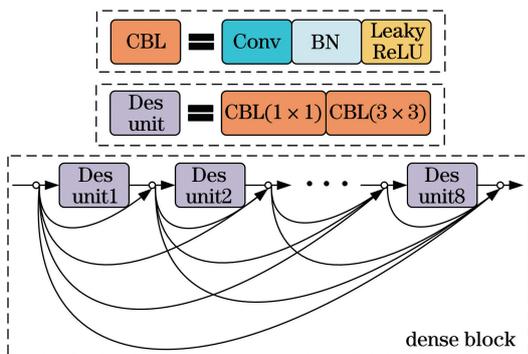


图 4 密集连接网络的结构

Fig. 4 Structure of the densely connected network

3.3 空间金字塔池化

SPP 是一种可以将局部特征映射到不同维度空间并将其融合的池化方法,能产生固定大小的特征向量,使网络结构适应制作数据集过程中裁剪等因素导致的比例、尺寸不同的输入图像。SPP 模块全

部为池化操作,通过步长为 1 的卷积操作和 padding 方式使输入前后特征图的尺寸一致,如图 5 所示。由下往上操作时,分别用步长为 1, 尺寸为 3×3 、 5×5 、 7×7 的卷积核对尺寸为 8×8 的特征图进行池化,得到大小为 6×6 、 4×4 、 2×2 的特征图。然后,通过 padding 方式将特征图的尺寸还原为 8×8 ,再经过池化并叠加初始特征图,得到 4 个维度为 2048 的特征图,从而消除目标尺寸不同导致的有效特征信息不一致问题,提升绝缘子的分类准确率。文献[25]在网络结构中加入 SPP 模块,在 COCO 数据集测试中的平均精度比原始算法高 5%,验证了加入 SPP 模块对提升绝缘子目标检测精度的有效性。

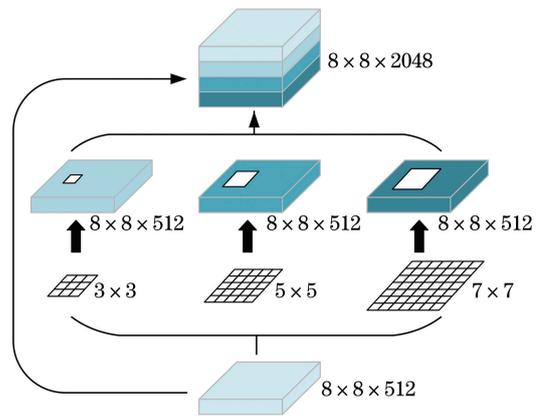


图 5 SPP 模块的结构

Fig. 5 Structure of the SPP module

3.4 改进损失函数

用均衡交叉熵函数和 Focal 损失函数改进原始损失函数,针对配网架空输电线路绝缘子数据集中存在的前景和背景复杂度不均衡现象以及绝缘子数据不同类别中样本数量的不均衡现象, Lin 等[26]提出了 Focal 损失函数,通过减少易分类样本的权重,使网络在训练过程中更专注稀疏的难分类样本,防止算法只学习到某一类样本信息,从而影响损失函数的梯度更新方向。原始损失函数可表示为

$$L = l_{xy} + l_{wh} + l_c + l_{cls}, \quad (5)$$

式中, l_{xy} 为边界框定位损失函数 (x, y 为位置坐标), l_{wh} 为边界框尺度损失函数 ($w \times h$ 为边界框的尺寸), l_c 为置信度损失函数, l_{cls} 为类别损失函数。实验用 Focal 损失函数 (L_{FL}) 替换 l_c 损失函数,可表示为

$$L_{FL} = \alpha(1 - p_t)^\gamma \lg(p_t), \quad (6)$$

式中, $p_t = 1/[1 + \exp(-x)]$ 为模型对检测目标的

预测概率, x 为全连接层的输出, α 和 γ 为超参数, 分别为 0.25 和 2。 L_{FL} 的反向传播过程可表示为

$$\frac{dL_{FL}}{dx} = \frac{dL_{FL}}{dp_i} \frac{dp_i}{dx} = \alpha(1 - p_i)^\gamma [\gamma(\lg p_i)p_i - (1 - p_i)] = \alpha \left[\frac{\exp(-x)}{1 + \exp(-x)} \right]^\gamma \left\{ \gamma \left[\lg \frac{1}{1 + \exp(-x)} \right] \left[\frac{1}{1 + \exp(-x)} \right] - \frac{\exp(-x)}{1 + \exp(-x)} \right\} \quad (7)$$

由于航拍配网架空输电线路图像中每张图像可能含有多种类型的绝缘子, 每个标签都是独立分布且互不影响。因此, 用均衡交叉熵函数对 l_{cls} 进行改进, 单独对每个类别进行计算, 每个类别只有两种可能值, 是一个二项分布, 可表示为

$$L_{cls} = - \sum_{i=1}^m \sum_{j=1}^n [s_{ij} \lg(p_{ij}) + (1 - s_{ij}) \lg(1 - p_{ij})], \quad (8)$$

式中, m 为样本总量, n 为类别数, s_{ij} 为图像第 j 类的真实框, 如果是该类为 1, 否则为 0; p_{ij} 为图像第 j 类预测框的置信度。改进后的损失函数由 l_{xy} 、 l_{wh} 、用 Focal 损失函数改进的 L_{FL} 、用均衡交叉熵改

进的 L_{cls} 组成。

3.5 本算法的网络结构

通过引入自定义的 DenseNet 和 SPP 模块, 优化多尺度融合预测机制等策略改进原始算法的网络结构, 将网络结构定义为多尺度密集网络 DSM (DenseNet-SPP-multi-scale)-Darknet, 其结构如图 6 所示。为进一步提取绝缘子数据集的细粒度特征, 首先, 将输入图像的尺寸由 416 pixel \times 416 pixel 提高至 512 pixel \times 512 pixel, 以保留更多的目标信息。其次, 针对巡检图像中绝缘子目标存在多尺度的问题, 优化了网络中的多尺度融合预测机制, 即将原网络只由 $\{13 \times 13, 26 \times 26, 52 \times 52\}$ 三

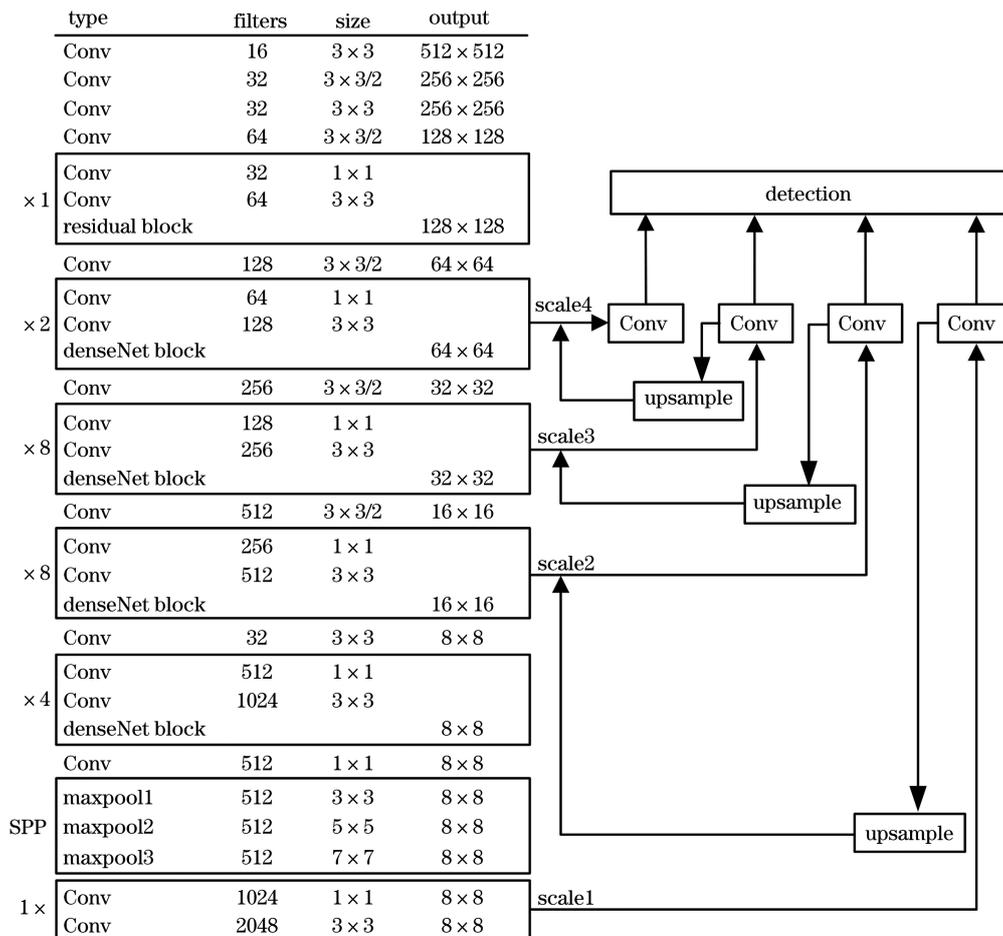


图 6 DSM-Darknet 的结构

Fig. 6 Structure of the DSM-Darknet

个尺度特征图进行预测拓展为 $\{8 \times 8, 16 \times 16, 32 \times 32, 64 \times 64\}$ 四个尺度。从图 6 可以发现, 经上采样操作与网络的特征图融合, 再经一次卷积后进行预测, 可增强特征的融合与复用, 使小目标绝缘子的特征信息直接传递到深层特征中, 避免了小目标特征在深层网络中的丢失问题, 从而提升小目标绝缘子的检测精度。

4 实验结果及分析

4.1 构建配网架空输电线路绝缘子图像数据集

为了验证本算法的鲁棒性, 需构建一定数量的绝缘子图像数据集, 使训练中获得更多准确的特征参数。实验使用的数据集图像为南方电网提供的无人机巡检图像, 包含绝缘子图像的有 5120 张。数据集样本图像中的绝缘子用途及形态结构包括玻璃悬式绝缘子(GS)、瓷质悬式绝缘子(PS)、瓷质针式绝缘子(PPin)、瓷质支柱绝缘子(PPost)、瓷横担绝缘子(PC)、复合绝缘子(R) 6 类, 图像背景复杂多样, 且存在互相遮挡、杆塔、房屋、丛林等干扰信息, 图 7 为不同类型的绝缘子数据样本。

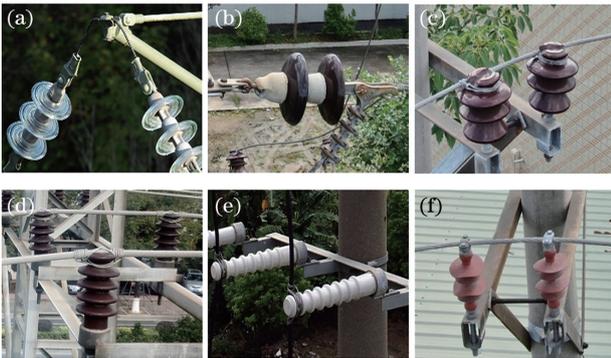


图 7 绝缘子数据集。(a) GS;(b) PS;(c) PPIn;
(d) PPost;(e) PC;(f) R

Fig. 7 Insulator data set. (a) GS; (b) PS; (c) PPIn;
(d) PPost; (e) PC; (f) R

构建的数据集根据 VOC 的建库方式, 借鉴文献[27]的数据增广方法, 对已有绝缘子图像进行水平镜像翻转、裁切、随机旋转等处理并剔除效果较差的图像后, 建立了包含 13500 张绝缘子图像的数据集。为了提高模型的泛化能力, 将 60% 的图像作为训练集(Train)、15% 的图像作为训练验证集(Train Val)、25% 的图像作为测试集(Test), 数据集中 6 类绝缘子的类别分布情况如表 1 所示。

表 1 数据集中不同类别的数目

Category	Total	Train	TrainVal	Test
GS	5085	3051	762	1272
PS	8872	5323	1330	2219
PPIn	2245	1347	336	562
PPost	5956	3573	893	1490
PC	6839	4103	1025	1711
R	4745	2847	711	1187

4.2 参数设置与评估指标

训练参数: 输入图像的尺寸为 $512 \text{ pixel} \times 512 \text{ pixel}$, 每次训练迭代的 batch 为 128, 共 8 个批次, 最大训练迭代次数为 60000 次; 用随机梯度下降(SGD)法更新权值, 权值衰减和动量分别为 0.0005 和 0.9, 初始学习率为 0.001, 学习率策略使用 step, 当网络迭代至 30000 次和 45000 次时, 学习率分别降为 0.0001 和 0.00001。

用目标检测常用的模型评价指标评价本模型, 包括准确率(Precision)和召回率(Recall), 并根据多次实验数据绘制出 PR(Precision-Recall)曲线, 具体计算公式可表示为

$$P = T_P / (T_P + F_P), \quad (9)$$

$$R = T_P / (T_P + F_N), \quad (10)$$

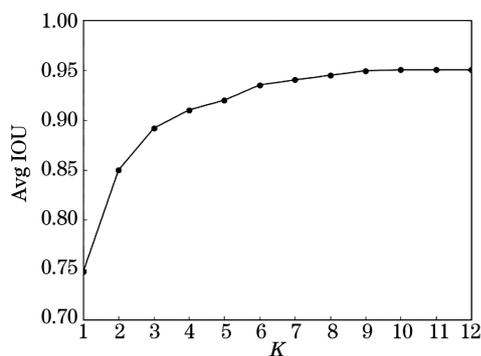
式中, P 为检测到绝缘子目标图像中包含真正目标的比例, R 为包含绝缘子目标图像中被成功检测出的比例, T_P 为预测为正的样本数, F_P 为预测为正的负样本数, F_N 为预测为负的正样本数。结合 PR 曲线和受试者工作特征曲线(ROC)展示本算法的分类性能, 每秒传输帧数(FPS)也是目标检测中的重要性能指标, 可表示为

$$X_{\text{FPS}} = \frac{1}{T/F}, \quad (11)$$

式中, T 为总时间, F 为帧数。

4.3 数据目标框的聚类分析

K 的值是对配网架空输电线路绝缘子图像数据集中的绝缘子目标框进行 K -means 聚类分析得到, 对于 K 个聚类中心, 取其最优值并绘制 K 与 Avg IOU 之间的关系, 结果如图 8 所示。可以发现, Avg IOU 随 K 的增大越来越平稳, 当 $K=9$ 时, 交并比为 94.3%, 继续增大 K 时, Avg IOU 的变化较小。得到的 9 个 anchor 分别为 $\{(15, 18), (20, 26), (29, 48), (45, 63), (53, 64), (62, 55),$

图 8 K -means 聚类的结果Fig. 8 Results of the K -means clustering

(72, 59), (86, 63), (91, 67)}, 实验时需将 anchor 数据设置到配置文件中。

4.4 不同改进对实验结果的影响

为了验证添加 DenseNet、引入 SPP 模块、优化

多尺度特征融合、改进损失函数、输入尺寸与改进 anchor 对算法的影响,进行了对比实验,结果如表 2 所示,其中 \checkmark 表示采用了对应的改进策略。可以看出,数据集在原始 YOLOv3 网络上的测试精度较低,原因是测试数据集上的绝缘子目标较小、类别数目不均衡、背景复杂。对于瓷质针式绝缘子,原始 YOLOv3 网络的准确率低于 75%,原因是其形状外观和瓷质支柱绝缘子类似,且目标较小、背景复杂。相比原始 YOLOv3 网络,本算法的平均精度(mAP)提高了约 12 个百分点,对瓷质针式绝缘子、瓷质支柱绝缘子、复合绝缘子的检测精度均有明显提高,平均精度提升了约 15 个百分点;对玻璃悬式绝缘子、瓷质悬式绝缘子、瓷横担绝缘子的精度提升较小,平均精度仅提升了约 8 个百分点。

表 2 不同策略对算法结果影响

Table 2 Different strategies influence the results of the algorithm

Algorithm	Anchor	Input size	Dense Net	SPP	Multi-scale	Loss	GS / %	PS / %	PPin / %	PPost / %	PC / %	R / %	mAP / %	FPS / frame
YOLOv3							88.6	89.1	73.5	74.2	89.1	74.2	81.5	40
Improve1	\checkmark						89.2	90.6	75.3	76.5	90.3	76.6	83.1	41
Improve2	\checkmark	\checkmark					89.6	91.1	76.9	78.1	91.1	78.1	84.2	40
Improve3	\checkmark	\checkmark	\checkmark				91.8	92.8	82.9	81.8	93.9	81.5	87.5	34
Improve4	\checkmark	\checkmark	\checkmark	\checkmark			93.1	94.2	84.8	85.7	95.0	85.7	89.8	33
Improve5	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark		94.3	95.7	86.4	87.3	97.3	88.2	91.5	31
Ours	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark	\checkmark	96.1	96.6	88.5	89.8	98.1	90.9	93.4	28

从表 2 可以发现,使用 K -means 聚类算法对目标框重新定义可明显提高算法的检测精度,此外,将原始网络中的残差模块替换为自定义的密集连接网络模块时,其检测精度也有大幅度提高,这验证了本算法的有效性。在网络中引入 SPP 模块和优化多尺度特征融合预测机制时,网络的 mAP 均有所提升,这表明池化模块可提升算法的检测精度。改进的损失函数也解决了瓷质针式绝缘子数目较少导致的检测精度低问题。图 9 为本算法和原始 YOLOv3 网络算法的平均训练损失函数曲线,可以发现,随着迭代次数的增加,两者均逐渐趋于平稳,但本算法的训练损失明显低于原始算法。

图 10 和图 11 为本算法在测试集上每个类别的 PR 和 ROC,可以发现,添加密集连接模块可进一步加强网络多层特征的复用和融合;增加 SPP 模块并优化多尺度特征融合预测机制可提高网络对图像深

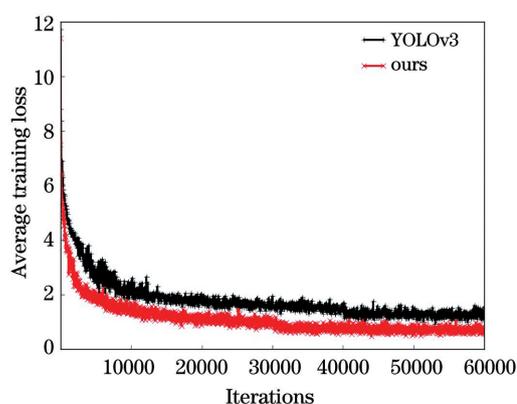


图 9 绝缘子数据集的训练损失曲线

Fig. 9 Training loss curve of the insulator data set

层特征的提取能力,从而克服原始网络容易漏检小绝缘子目标的缺点;改进原损失函数可提升网络整体的检测精度,使网络具有更好的鲁棒性和检测精度。

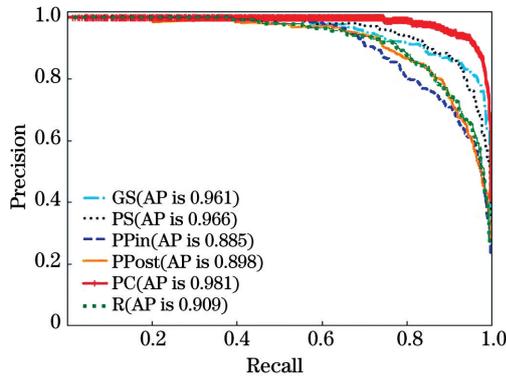


图 10 不同绝缘子的 PR 曲线

Fig. 10 PR curves of different insulators

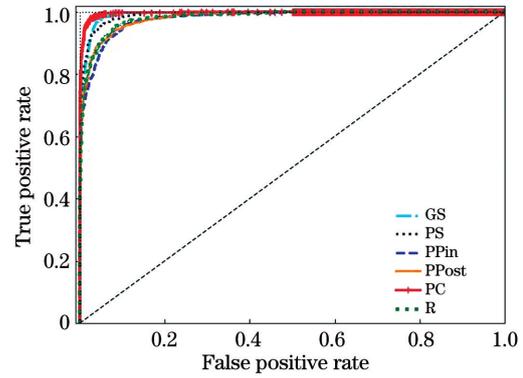


图 11 不同绝缘子的 ROC

Fig. 11 ROC of different insulators

4.5 不同算法的对比实验

为了验证本算法的优势,用目前主流的深度学习目标检测网络在配网架空输电线路绝缘子图像数据集上进行训练和测试实验,包括 Faster R-CNN、SSD、RetinaNet 和 YOLOv3 网络,将迭代次数达到稳定后

的检测结果进行对比,结果如表 3 和图 12 所示。可以发现,相比 SSD、YOLOv3 网络等算法,本算法的精度、召回率、mAP 均得到了明显提高,虽然 FPS 有所下降,但比部分算法的检测速度快。随着迭代次数的增加,本算法的精度逐渐趋于平稳,可达到 93.4%。

表 3 不同算法的检测结果

Table 3 Test results of different algorithms

Algorithm	Backbone	Iterations	Precision / %	Recall / %	mAP / %	FPS / frame
Faster R-CNN	VGG16-Net	60000	79.1	77.5	74.6	7
SSD	VGG16-Net	60000	82.0	83.2	78.9	26
YOLOv3	DarkNet53	60000	83.7	83.5	81.5	40
RetinaNet	ResNet101	60000	84.8	84.3	82.4	20
Ours	DSM-DarkNet	60000	94.5	96.0	93.4	28

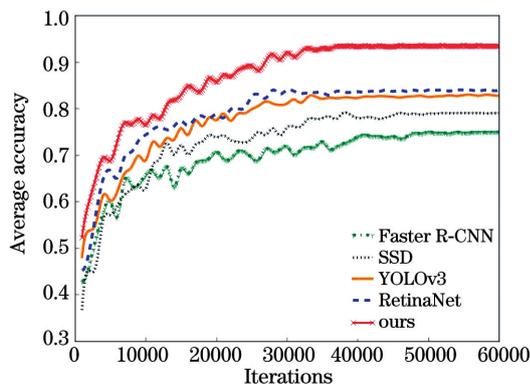


图 12 不同算法的 mAP

Fig. 12 mAP of different algorithms

为了直观展示本算法的检测效果和鲁棒性,给出了不同场景下本算法的检测效果,如图 13 所示。可以看出,在马路、村庄、森林和鱼塘等复杂背景和绝缘子出现遮挡的情况下,本算法依然可以准确识别出各类绝缘子,且在不同光照和有噪声图像下的检测效果较好,没有漏检和误判情况。这表明本算

法能精准识别出配网架空输电线路图像中的绝缘子目标,且鲁棒性较好。

5 结 论

绝缘子作为输电线路重要的设施之一,对其进行准确识别分类是实现配网架空输电线路绝缘子故障诊断和缺陷检测的重要前提。为了对绝缘子进行准确识别,提出了一种基于多尺度密集网络的配网架空输电线路绝缘子识别算法。通过 K-means 聚类分析数据集并改进其 anchor、增大输入图像的尺寸、添加密集连接网络、引入 SPP 模块、优化多尺度特征融合预测机制和改善损失函数等策略对原始网络进行改进。构建绝缘子图像数据集进行测试,实验结果表明,本算法能准确识别出配电网架空线路上的绝缘子,相比原始算法,准确率提高了约 12 个百分点,且鲁棒性更强,在电力检修方面有很大的应用前景。下一步将在此基础上实现绝缘子的缺陷、裂缝识别以及复合绝缘子伞裙破损等故障的诊断。

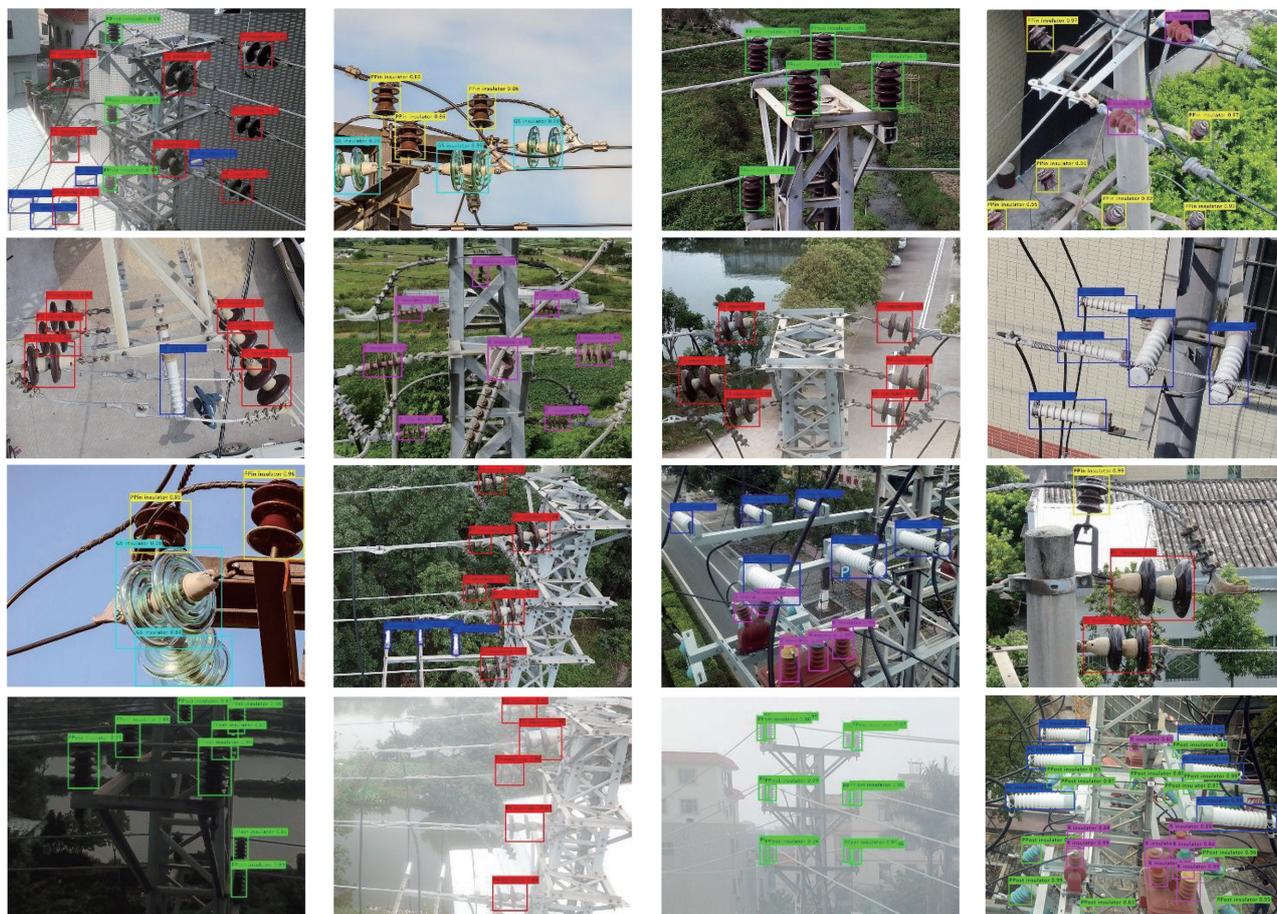


图 13 多尺度密集网络的检测效果

Fig. 13 Detection effect of the multi-scale dense network

参 考 文 献

- [1] Miao X R, Liu X Y, Chen J, et al. Insulator detection in aerial images for transmission line inspection using single shot multibox detector [J]. *IEEE Access*, 2019, 7: 9945-9956.
- [2] Tao X, Zhang D P, Wang Z H, 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*, 2020, 50(4): 1486-1498.
- [3] Yang D S, Pang Y H, Zhou B W, et al. Fault diagnosis for energy internet using correlation processing-based convolutional neural networks [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2019, 49(8): 1739-1748.
- [4] Cheng H Y, Chen R, Wang J N, et al. Study on insulator recognition method based on simulated samples expansion [C] // 2018 Chinese Control And Decision Conference (CCDC), June 9-11, 2018, Shenyang, China. New York: IEEE Press, 2018: 2569-2573.
- [5] Zhao Z B, Xu G Z, Qi Y C, et al. Multi-patch deep features for power line insulator status classification from aerial images [C] // 2016 International Joint Conference on Neural Networks (IJCNN), July 24-29, 2016, Vancouver, BC, Canada. New York: IEEE Press, 2016: 3187-3194.
- [6] Zhai Y J, Chen R, Yang Q, et al. Insulator fault detection based on spatial morphological features of aerial images [J]. *IEEE Access*, 2018, 6: 35316-35326.
- [7] Jiang H, Qiu X J, Chen J, et al. Insulator fault detection in aerial images based on ensemble learning with multi-level perception [J]. *IEEE Access*, 2019, 7: 61797-61810.
- [8] Prakash N, Singh Y. Fuzzy support vector machines for face recognition: a review [J]. *International Journal of Computer Applications*, 2015, 131(3): 24-26.
- [9] Felzenszwalb P F, Girshick R B, McAllester D, et al. Object detection with discriminatively trained part-based models [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(9): 1627-1645.

- [10] Dalal N, Triggs B. Histograms of oriented gradients for human detection [C] // 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR' 05), June 20-25, 2005, San Diego, CA, USA. New York: IEEE Press, 2005: 886-893.
- [11] Zhao J M, Zhang L P. Research on various feature extraction technology of insulator image [J]. Electrical Measurement & Instrumentation, 2013, 50 (12): 37-41.
赵俊梅, 张利平. 绝缘子图像的多种特征提取技术的研究[J]. 电测与仪表, 2013, 50(12): 37-41.
- [12] Qi Y C, Xu L, Zhao Z B, et al. A cosegmentation method for aerial insulator images[M]//Wang S, Ma H, Di K, et al. Advances in Image and Graphics Technologies. IGTA 2015. Communications in Computer and Information Science, Berlin, Heidelberg: Springer, 2015, 525: 113-122.
- [13] Duan Z J, Li S B, Hu J J, et al. Review of deep learning based object detection methods and their mainstream frameworks[J]. Laser & Optoelectronics Progress, 2020, 57(12): 120005.
段仲静, 李少波, 胡建军, 等. 深度学习目标检测方法及其主流框架综述[J]. 激光与光电子学进展, 2020, 57(12): 120005.
- [14] Li J F, Wang Q R, Li M. Electric equipment image recognition based on deep learning and random forest [J]. High Voltage Engineering, 2017, 43 (11): 3705-3711.
李军锋, 王钦若, 李敏. 结合深度学习和随机森林的电力设备图像识别[J]. 高电压技术, 2017, 43(11): 3705-3711.
- [15] Cheng H Y, Zhai Y J, Chen R. Faster R-CNN based recognition of insulators in aerial images[J]. Modern Electronics Technique, 2019, 42(2): 98-102.
程海燕, 翟永杰, 陈瑞. 基于 Faster R-CNN 的航拍图像中绝缘子识别[J]. 现代电子技术, 2019, 42 (2): 98-102.
- [16] Zhao Z B, Cui Y P, Qi Y C, et al. Detection method of insulator in aerial inspection image based on modified R-FCN [J]. Computer Science, 2019, 46 (3): 159-163.
赵振兵, 崔雅萍, 咸银城, 等. 基于改进的 R-FCN 航拍巡线图像中的绝缘子检测方法[J]. 计算机科学, 2019, 46(3): 159-163.
- [17] Wang W G, Wang Z L, Liu B, et al. Typical defect detection technology of transmission line based on deep learning[C]//2019 Chinese Automation Congress (CAC), November 22-24, 2019, Hangzhou, China. New York: IEEE Press, 2019: 1185-1189.
- [18] Chen J W, Xu X, Dang H S. Fault detection of insulators using second-order fully convolutional network model [J]. Mathematical Problems in Engineering, 2019, 2019: 1-10.
- [19] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [20] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [21] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. [2020-07-20]. <http://arxiv.org/abs/1804.02767>.
- [22] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [23] Ju M R, Luo H B, Wang Z B, et al. Improved YOLOv3 algorithm and its application in small target detection [J]. Acta Optica Sinica, 2019, 39 (7): 0715004.
鞠默然, 罗海波, 王仲博, 等. 改进的 YOLOv3 算法及其在小目标检测中的应用[J]. 光学学报, 2019, 39(7): 0715004.
- [24] Chen J M, Jin J, Wang W F. Improved algorithm based on feature pyramid networks [J]. Laser & Optoelectronics Progress, 2019, 56(21): 211505.
陈景明, 金杰, 王伟锋. 基于特征金字塔网络的改进算法[J]. 激光与光电子学进展, 2019, 56 (21): 211505.
- [25] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [26] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection [J]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2999-3007.
- [27] Zoph B, Cubuk E D, Ghiasi G, et al. Learning data augmentation strategies for object detection [EB/OL]. [2020-07-20]. <http://arxiv.org/abs/1906.11172>.