

# 基于 Gaussian YOLOv3 的航拍图像绝缘子缺陷识别

汪权<sup>1</sup>, 易本顺<sup>2\*</sup>

<sup>1</sup> 武汉邮电科学研究院, 湖北 武汉 430074;

<sup>2</sup> 武汉大学, 湖北 武汉 430072

**摘要** 输电线路上的绝缘子长期处于强电场和恶劣环境中,其安全性的监测尤为重要。为了快速精确识别航拍图像中的绝缘子,提出了一种基于 Gaussian YOLOv3(You only look once)的绝缘子检测算法。首先,通过增加网络的输出和改进网络的损失函数输出预测框。然后,结合高斯分布的策略输出对应预测框坐标的均值和方差。最后,采用多阶段迁移学习解决小数据集容易发生过拟合的问题。实验结果表明,本算法能准确定位物体的位置,在测试集中的绝缘子检测精度达到 93.8%,绝缘子缺陷检测精度达到 94.5%,优于同等条件下的 Faster 区域卷积神经网络和 YOLOv3 算法,为输电线路的绝缘子智能化检测提供了一定的参考价值。

**关键词** 图像处理; Gaussian YOLOv3; 绝缘子; 缺陷检测; 高斯分布; 迁移学习

中图分类号 TP277

文献标志码 A

doi: 10.3788/LOP202158.1210022

## Insulator Defect Recognition in Aerial Images Based on Gaussian YOLOv3

Wang Quan<sup>1</sup>, Yi Benshun<sup>2\*</sup>

<sup>1</sup> FiberHome Technologies Group, Wuhan, Hubei 430074, China;

<sup>2</sup> Wuhan University, Wuhan, Hubei 430072, China

**Abstract** The safety monitoring of insulators on transmission lines is particularly important because these insulators are exposed to strong electric fields and harsh environments. To quickly and accurately identify insulators in aerial images, an insulator detection algorithm based on Gaussian YOLOv3 (you only look once) is proposed in this work. First, in order to output the prediction box, the output of the network is increased and the loss function of the network is improved. Then, the mean and variance of the corresponding prediction box coordinate are output by combining the strategy of Gaussian distribution. Finally, the overfitting problem of small data sets is resolved via multi-stage transfer learning. Experimental results show that the algorithm can accurately determine the location of an object. Detection accuracy levels of 93.8% and 94.5%, which are better than the Faster regional convolutional neural network and YOLOv3 algorithm under the same conditions, are realized for insulators in the test set and insulator defects, respectively. The detection accuracy is important for power transmission. Moreover, the intelligent detection of line insulators yields a certain reference value.

**Key words** image processing; Gaussian YOLOv3; insulator; defect detection; Gaussian distribution; transfer learning

**OCIS codes** 100.2000; 100.3008; 100.4996

## 1 引言

输电线路上的绝缘子会出现自爆、污秽、覆冰、

裂纹等问题,从而影响输电系统的正常运行。随着科学技术的发展,无人机得到的航拍图像越来越清晰,图像包含的信息也越来越丰富。深度学习算法

收稿日期: 2020-08-24; 修回日期: 2020-09-24; 录用日期: 2020-11-04

\* E-mail: yibs@whu.edu.cn

自提出以来,在多个领域中得到了广泛的应用<sup>[1]</sup>。为了保障电网运行的安全性以及工人的人身安全,利用无人机巡检系统代替人工检测具有重要研究意义。

目前人们对绝缘子的航拍图像检测研究<sup>[2-3]</sup>主要集中在缺陷及自爆检测,目标检测算法可分为 two-stage 和 one-stage 两种。前者需要由算法先生成候选框,再根据候选框和卷积神经网络(CNN)进行分类回归;后者则不需要产生候选框,直接通过 CNN 处理分类和回归问题。two-stage 算法<sup>[4-7]</sup>的研究中,王万国等<sup>[8]</sup>在电力巡检中利用 Faster 区域卷积神经网络(R-CNN)<sup>[9]</sup>识别了多种类别的电力小部件,准确率可达 92.7%,但每秒检测帧数只有 12.5 frame,无法满足实时性要求。Ren 等<sup>[10]</sup>用全卷积网络(FCN)框架构建了深度学习算法,增加训练计算量的同时也降低了绝缘子的检测速率。one-stage 算法<sup>[11-12]</sup>的研究中,赖秋频等<sup>[13]</sup>基于 YOLOv2 (You only look once)<sup>[14]</sup>诊断绝缘子的破损情况及缺陷位置,并结合边缘检测、图像旋转等图像处理方法在一定程度上提高了绝缘子的检测精度,但在绝缘子比较密集的情况下容易出现漏检问题。林志成等<sup>[15]</sup>融合了多种检测性能差异明显的算法,达到了较好的检测结果,为绝缘子目标的检测提供了新思路。此外,杜小燕等<sup>[16]</sup>提出了基于图像分割的改进型单位连接脉冲耦合神经网络(UL-PCNN)绝缘子检测方法,但该方法在复杂场景中的检测精度较低。

针对上述问题,本文提出了一种基于 Gaussian YOLOv3<sup>[17]</sup>的绝缘子检测算法,首先,对原始数据集进行扩增处理;然后,对预测框的坐标进行高斯模型评估,设计了新的损失函数;最后,用多阶段迁移学习减小训练损失。实验结果表明,相比 Faster R-CNN 和 YOLOv3<sup>[18]</sup>算法,本算法在测试集中的检测速率和精度更高,可应用于电力巡检系统中绝缘子缺陷的实时监测。

## 2 数据集

实验使用的数据集为开源数据集,来自 Github 的 Insulator Data Set-Chinese Power Line Insulator Dataset (CPLID) (<http://github.com/InsulatorData/InsulatorDataSet>),包含 848 张绝缘子图像。其中,无人机捕获的常规绝缘子数量为 600 个,如图 1(a)所示。由于含有缺陷的绝缘子太少,因此,用影视分割(TVSeg)算法将有缺陷的绝缘子从图像中分割出来,再用 U-Net<sup>[19]</sup>训练分割的图像,将最

终得到的图像放置到适应场景中,得到 248 张合成的图像,如图 1(b)所示。




图 1 绝缘子图像。(a)正常图像;(b)含有缺陷的图像

Fig. 1 Image of the insulator. (a) Normal image;

(b) image with defects

考虑到数据集中的图像数量过少,训练时容易出现过拟合,对原始数据集进行扩增。为使得到的图像更贴近真实图像,仅对原始图像进行随机翻转和尺度缩放,扩增数据集中的图像数量为原始数据集的 4 倍,其中,正常的绝缘子图像数量为 2400 张,有缺陷的绝缘子图像数量为 992 张,共 3392 张图像。针对扩增的数据集,根据原始样本的标记规则,用 labelImg 工具进行标注,绝缘子位置标记为 insulator,如果绝缘子存在缺陷,则对缺陷位置标记为 defect。

## 3 Gaussian YOLOv3

### 3.1 YOLOv3

YOLOv3 的结构如图 2 所示,其中,输入图像是尺寸为 416 pixel $\times$ 416 pixel 的绝缘子 3 通道彩色图像,DBL 为代码中的 Darknetconv2d\_BN\_Leaky,由卷积层(Conv)、批归一化(BN)以及激活函数带泄露修正线性单元(Leaky ReLU)组成。DBL 与后面的 5 个残差网络结构体(Res- $n$ )组成没有全连接层的 Darknet-53,其中, $n$  为残差单元(Res\_Unit)的个数,Res- $n$  是由零填充(Zero padding)和 DBL 组件以及  $n$  个残差单元组成的残差网络结构体。没有全连接层的 Darknet-53 与常用的特征提取残差网络 ResNet-152 和 ResNet-101<sup>[20]</sup>的分类精度相差不大,但其计算速度更快。YOLOv3 的后半部分网络借鉴了多尺度特征金字塔<sup>[21]</sup>的思想,通过上采样(Up-sample)和拼接(Concat)操作输出三个尺寸为 13 $\times$ 13 $\times$ 255、26 $\times$ 26 $\times$ 255、52 $\times$ 52 $\times$ 255 的特征图,以检测不同尺寸的绝缘子,最后用非最大值抑制(NMS)方法得到检测结果。

### 3.2 Gaussian YOLOv3

在真实情况下,用无人机拍摄的绝缘子图像容

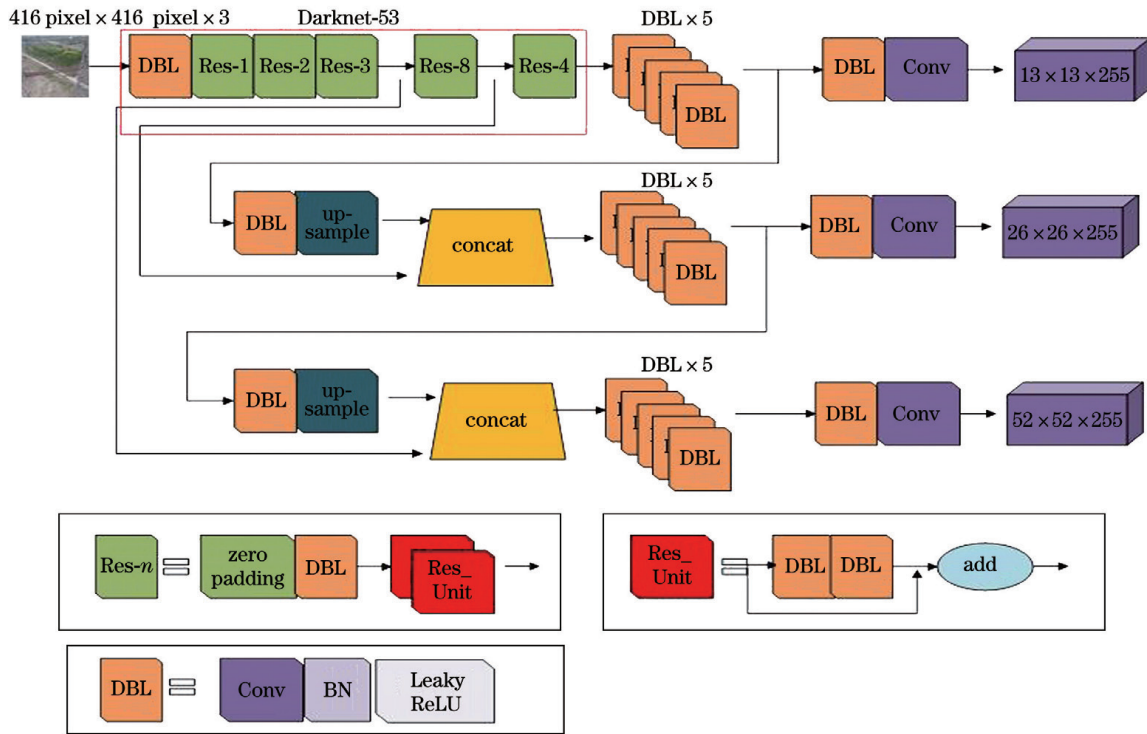


图 2 YOLOv3 的结构

Fig. 2 Structure of the YOLOv3

易有遮挡、重叠现象,且大量的噪声数据会使 YOLOv3 训练出的回归框没有全部包裹物体,同时产生重复标框、置信度低等问题,如图 3 所示。




图 3 YOLOv3 的检测结果。(a)未完全包裹目标;  
(b)重复标框

Fig. 3 Test results of the YOLOv3. (a) Target is not completely wrapped; (b) duplicate frame

基于传统深度学习的目标检测算法被检测对象类别的可靠性是已知的,预测框回归的可靠性是未知的。Gaussian YOLOv3 没有改变 YOLOv3 内部的网络结构,而是通过增加输出量,利用高斯参数对预测框坐标参数进行建模,重新定义损失函数,使最终得到的回归框更精确,预测定位的可靠性更高。YOLOv3 和 Gaussian YOLOv3 的输出分别如图 4 和图 5 所示。

从图 4 和图 5 可以发现,在 YOLOv3 中,每个绝缘子网格负责预测三个真实框,每个框由三部分组成,其中,回归框的坐标  $t_x$ 、 $t_y$  是预测框横纵坐标

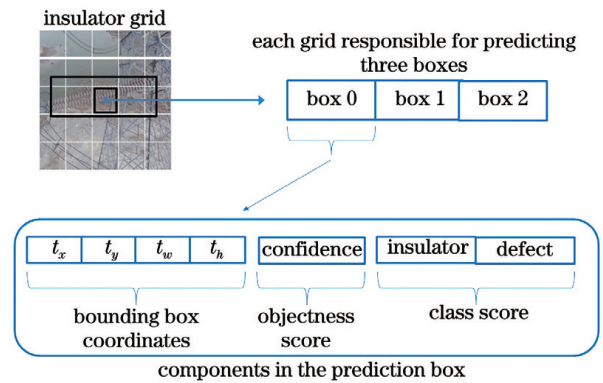


图 4 YOLOv3 的输出

Fig. 4 Output of the YOLOv3

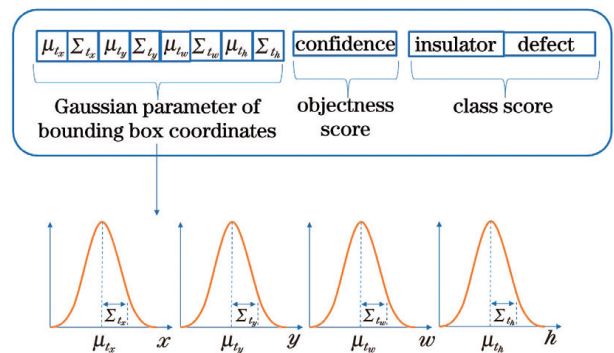


图 5 Gaussian YOLOv3 的输出

Fig. 5 Output of the Gaussian YOLOv3

的偏移值,  $t_w$ 、 $t_h$  为图像宽高的缩放尺度,

confidence 为物体检测得分, insulator 和 defect 对应两个类别的可靠性信息。Gaussian YOLOv3 考虑到边界框坐标的不确定性, 不再使用确定的真实框坐标, 而是通过  $t_x, t_y, t_w, t_h$  对应的高斯模型进行建模。给定一个测试输入  $x$ , 其对应的输出  $y$  由高斯参数组成, 可表示为

$$p(y|x) = N\left[y; \mu(x), \sum(x)\right], \quad (1)$$

式中,  $\mu(x)$ 、 $\sum(x)$  分别为对应输入  $x$  的均值和方差函数,  $N$  为正态分布下的概率密度函数,  $p(y|x)$  为  $x$  的概率密度。将预测框坐标加入高斯模型后, 得到 Gaussian YOLOv3 回归框坐标的输出,  $t_x, t_y, t_w, t_h$  对应的均值为  $\mu_{t_x}^{\wedge}, \mu_{t_y}^{\wedge}, \mu_{t_w}^{\wedge}$  和  $\mu_{t_h}^{\wedge}$ , 方差为  $\sum_{t_x}^{\wedge}, \sum_{t_y}^{\wedge}, \sum_{t_w}^{\wedge}$  和  $\sum_{t_h}^{\wedge}$ 。均值可表示预测回归框的坐标范围, 方差可表示坐标的不确定性。为使每个网格对应的物体中心落在当前网格内, 需将均值和方差缩放至 0 到 1 (0 表示非常可靠, 1 表示不可靠) 之间, 可表示为

$$\mu_{t_x} = \sigma(\mu_{t_x}^{\wedge}), \mu_{t_y} = \sigma(\mu_{t_y}^{\wedge}),$$

$$\mu_{t_w} = \sigma(\mu_{t_w}^{\wedge}), \mu_{t_h} = \sigma(\mu_{t_h}^{\wedge}), \quad (2)$$

$$\sigma(x) = \frac{1}{1 + \exp(-x)}, \quad (3)$$

$$\sum_{t_x} = \sigma(\sum_{t_x}^{\wedge}), \sum_{t_y} = \sigma(\sum_{t_y}^{\wedge}), \quad (4)$$

$$\sum_{t_w} = \sigma(\sum_{t_w}^{\wedge}), \sum_{t_h} = \sigma(\sum_{t_h}^{\wedge}). \quad (5)$$

此外, Gaussian YOLOv3 还重新设计了损失函数, YOLOv3 坐标使用的是平均误差损失之和, 类别为二元交叉熵损失和。Gaussian YOLOv3 的类别损失函数不变, 其坐标则为通过高斯模型输出的高斯参数, 高斯模型为负对数似然损失函数 (NLL), 可表示为

$$L_x = - \sum_{i=1}^W \sum_{j=1}^H \sum_{k=1}^K \gamma_{ijk} \lg \left\{ N \left[ x_{ijk}^G | \mu_{t_x}(x_{ijk}), \sum_{t_x}(x_{ijk}) \right] + \epsilon \right\}, \quad (6)$$

式中,  $L_x$  为坐标  $t_x$  的损失函数,  $W, H$  为特征图的宽和高, 即宽和高的网格数,  $K$  为对应的 anchor 数量,  $\mu_{t_x}(x_{ijk}), \sum_{t_x}(x_{ijk})$  分别为网格  $(i, j)$  中第  $k$  个 anchor 处的  $t_x$  均值和方差 (检测层的输出),  $x_{ijk}^G$  为  $t_x$  的真值 (GT),  $\epsilon = 10^{-9}$  为防止对数函数失效的常数, GT 编码计算方式可表示为

$$x_{ijk}^G = x^G \times W - i, y_{ijk}^G = y^G \times H - j, \quad (7)$$

$$w_{ijk}^G = \lg \left( \frac{w^G \times IW}{A_k^w} \right), h_{ijk}^G = \lg \left( \frac{h^G \times IH}{A_k^h} \right), \quad (8)$$

式中,  $x^G, y^G, w^G, h^G$  为 GT 框在原图中的比例,  $I$  为 GT 框的缩放比例,  $IW, IH$  为调整后图像的宽和高,  $A_k^w, A_k^h$  为通过聚类得到第  $k$  个 anchor 的宽和高。此外, 在设计损失函数时, 加入了惩罚系数  $\gamma_{ijk}$ , 可表示为

$$\gamma_{ijk} = \frac{w_{scale} \times \delta_{ijk}^{obj}}{2}, \quad (9)$$

式中,  $\delta_{ijk}^{obj}$  为 GT 和当前 anchor 的交并比 (IOU), 大于一定阈值取 1, 否则取 0。比例  $w_{scale}$  可由  $w^G, h^G$  表示为

$$w_{scale} = 2 - w^G \times h^G. \quad (10)$$

可以发现, 重新设计的损失函数对于预测回归框的鲁棒性更强, 能更好地应对噪声数据。

## 4 实验结果及分析

### 4.1 实验条件

原始数据集包括 848 张无人机航拍的绝缘子图像, 通过旋转得到的新数据集包括 3392 张图像, 每张图像可能包含一串或多串绝缘子。用 labelImg 工具标记得到的绝缘子图像将有绝缘子的部分标记为 insulator, 绝缘子有缺陷的部分标记为 defect。将整个数据集中的图像打乱, 按照 8 : 2 的比例划分为训练验证集和测试集, 将训练验证集按照 9 : 1 的比例划分为训练集和验证集, 最终得到的训练集包括 2440 张图像, 验证集包括 272 张图像, 测试集包括 680 张图像, 如表 1 所示。

表 1 数据集的划分

Table 1 Division of the data set

Data set	Insulator	Defect
Training set	1727	713
Validation set	193	79
Test set	480	200

通常用准确率和召回率评价算法的性能, 在此基础上, 实验还使用了平均精度均值 (mAP) 评价算法的性能。每一类的 mAP 使用 11 点插值法获得, 分别计算  $[0, 0.1, 0.2, \dots, 1]$  中不同召回率级别的最大准确率, 并求平均值。由于只涉及到绝缘子和缺陷两个类别, 对这两个类别求和取平均, 得到的最终 mAP 可表示为

$$X_{mAP} = \frac{1}{22} \sum_2 \sum_{r \in [0, 1]} \max [X_{pre} (X_{rec} \geq r)], \quad (11)$$

式中,  $X_{pre}$  为准确率,  $X_{rec}$  为召回率,  $r$  为 11 个不同的阈值。此外, 绝缘子的检测速度也是一个比较重要评价指标, 测试过程中的检测速度可表示为

$$X_{FPS} = F_{FrameCount} / T_{TotalTime}, \quad (12)$$

式中,  $F_{FrameCount}$  为处理的图像数量,  $T_{TotalTime}$  为处理时间。为了检测回归框能否完整包裹绝缘子以及缺陷部位, 用  $P_i$  表示所有绝缘子检测框中检测框和真实框的 IOU 大于 0.9 时图像数量占全部图像数量的百分比, 用  $P_d$  表示所有缺陷部位检测框中检测框和真实框的 IOU 大于 0.8 时图像数量占全部图像数量的百分比。测试时的硬件配置: CPU 为英特尔 E5-2678v3, GPU 为 NVIDIA GTX1080TI, 内存为 4 根 16 GB 内存条, 训练环境为 Python3.7、tensorflow-gpu1.14.0 版本。

### 4.2 多阶段迁移学习

直接从头训练网络耗时长且容易出现过拟合现象, 因此, 实验采用多阶段迁移学习<sup>[22-23]</sup>。原因是迁移学习得到的参数效果优于随机初始化参数, 且适合绝缘子图像较少的情况, 不仅能防止过拟合, 还能

提高训练效率。多阶段迁移学习的具体步骤如下。

1) 加载 Gaussian YOLOv3 在 Pascal VOC 数据集上训练得到的权重, 冻结 Gaussian YOLOv3 后半部分的网络结构, 以得到特征图。设定的学习速率  $l_r = e^{-3}$ , 迭代次数为 150。

2) 加载步骤 1) 得到的权重, 冻结 Gaussian YOLOv3 前半部分用于特征提取的 Darknet 网络层, 设定学习速率  $l_r = e^{-4}$  开始训练。

3) 加载步骤 2) 得到的权重, 不冻结 Gaussian YOLOv3, 设定学习速率  $l_r = e^{-5}$  开始训练。

图 6 为 3 个步骤在迭代次数为 150 时的训练集损失 (train\_loss) 和验证集损失 (val\_loss), 可以发现: 步骤 1) 中起始时间段训练集的损失较大, 大幅度下降后逐渐平缓, 验证集损失变化不明显; 步骤 2) 中训练集损失下降逐渐变缓, 验证集损失波动较大, 但有缓慢下降趋势; 步骤 3) 中训练集损失不断下降, 验证集损失的下降也比较明显, 这表明网络没有达到过拟合状态, 从而验证了多阶段迁移学习的合理性。




图 6 不同情况下的训练损失。(a)步骤 1);(b)步骤 2);(c)步骤 3)

Fig. 6 Training losses in different situations. (a) Step 1); (b) step 2); (c) step 3)

### 4.3 实验结果

得到步骤 3) 的训练权重后, 在测试集上进行测试, 并计算不同算法的 mAP 和  $X_{FPS}$ , 结果如表 2 所示。可以发现, 相比 Faster R-CNN 和 YOLOv3 算法, 同等条件下 Gaussian YOLOv3 算法对绝缘子的检测精度分别提高了 2.3 和 0.3 个百分点, 缺陷的检测精度分别提高了 11.5 和 9.5 个百分点, 这表

明使用多阶段迁移学习的 Gaussian YOLOv3 算法能明显提高对小目标的检测精度; Gaussian YOLOv3 算法的检测速率虽然略低于 YOLOv3 算法, 但仍能保持较好的实时性; 且 Gaussian YOLOv3 算法的  $P_i$  和  $P_d$  也远高于其他算法。

Gaussian YOLOv3 算法的检测结果如图 7 所示, 可以发现, 该算法对正常绝缘子及缺陷绝缘子的检测

表 2 不同算法的测试结果

Table 2 Test results of different algorithms

Algorithm	Insulator / %	Defect / %	mAP / %	$X_{FPS}$ / (frame·s <sup>-1</sup> )	$P_i$ / %	$P_d$ / %
Faseter R-CNN	91.5	83.0	87.1	5.4	32.5	22.0
YOLOv3	93.5	85.0	90.3	26.3	29.6	24.0
Gaussian YOLOv3	93.8	94.5	94.3	26.1	91.7	94.0

效果都很好,且定位准确,回归框能完整包裹绝缘子及缺陷部位,也不存在重复标框和置信度低的情况,有利

于巡检人员准确定位缺陷并排查故障,验证了 Gaussian YOLOv3 算法对绝缘子坐标建模的合理性。

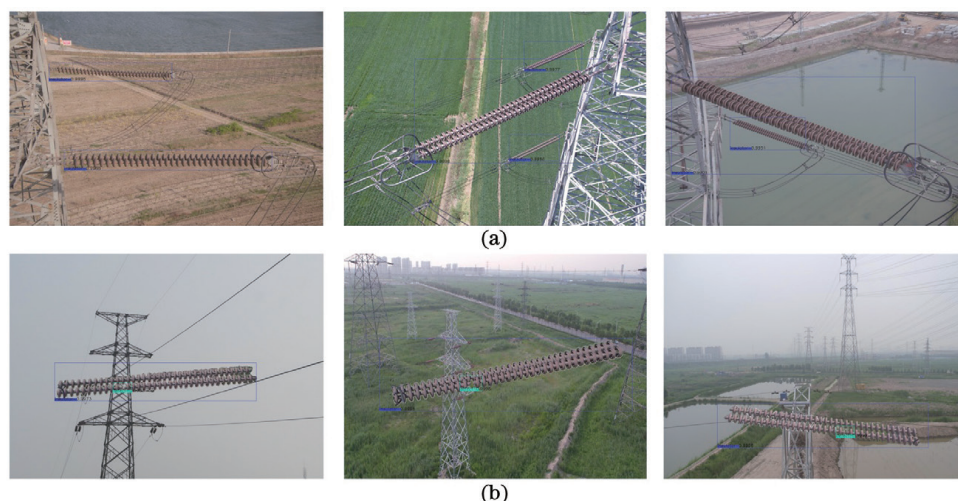


图 7 Gaussian YOLOv3 的检测结果。(a)正常绝缘子;(b)带缺陷的绝缘子

Fig. 7 Detection results of the Gaussian YOLOv3. (a) Normal insulator; (b) insulator with defects

## 5 结 论

提出了一种基于多阶段迁移学习的 Gaussian YOLOv3 绝缘子缺陷检测算法,实验结果表明,相比其他对比算法,本算法在同等条件下的检测精度更高,且实时性好、定位准确。下一步还需考虑在不丢失检测精度的情况下提高算法的检测速率,以满足巡检系统的需求。

### 参 考 文 献

- [1] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [2] Sampedro C, Rodriguez-Vazquez J, Rodriguez-Ramos A, et al. Deep learning-based system for automatic recognition and diagnosis of electrical insulator strings [J]. IEEE Access, 2019, 7: 101283-101308.
- [3] Xie X L, Li C X, Yang X G, et al. Dynamic receptive field-based object detection in aerial imaging [J]. Acta Optica Sinica, 2020, 40(4): 0415001.  
谢学立, 李传祥, 杨小冈, 等. 基于动态感受野的航拍图像目标检测算法 [J]. 光学学报, 2020, 40(4): 0415001.
- [4] Kang G Q, Gao S B, Yu L, et al. Deep architecture for high-speed railway insulator surface defect detection: denoising autoencoder with multitask learning [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(8): 2679-2690.
- [5] Guo T, Yang H, Shi L, et al. Self-explosion defect identification of insulator based on Faster RCNN [J]. Insulators and Surge Arresters, 2019(3): 183-189.  
沈晓海, 栗泽昊, 李敏, 等. 基于多任务深度学习的铝材表面缺陷检测 [J]. 激光与光电子学进展, 2020, 57(10): 101501.
- [6] 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.
- [7] Shen X H, Li Z H, Li M, et al. Aluminum surface-defect detection based on multi-task deep learning [J]. Laser & Optoelectronics Progress, 2020, 57(10): 101501.  
王万国, 田兵, 刘越, 等. 基于 RCNN 的无人机巡检图像电力小部件识别研究 [J]. 地球信息科学学报, 2017, 19(2): 256-263.
- [8] Wang W G, Tian B, Liu Y, et al. Study on the electrical devices detection in UAV images based on region based convolutional neural networks [J]. Journal of Geo-Information Science, 2017, 19(2): 256-263.
- [9] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [10] Gao J F, Lü Y H. Research on recognition and segmentation of insulator strings in aerial images [J]. Journal of Zhengzhou University (Natural Science Edition), 2019, 51(4): 16-22.

- 高金峰, 吕易航. 航拍图像中绝缘子串的识别与分割方法研究[J]. 郑州大学学报(理学版), 2019, 51(4): 16-22.
- [11] Wu T, Wang W B, Yu L, et al. Insulator defect detection method for lightweight YOLOv3 [J]. Computer Engineering, 2019, 45(8): 275-280.  
吴涛, 王伟斌, 于力, 等. 轻量级 YOLOv3 的绝缘子缺陷检测方法[J]. 计算机工程, 2019, 45(8): 275-280.
- [12] Yan H W, Chen J X. Insulator string positioning and state recognition method based on improved YOLOv3 algorithm[J]. High Voltage Engineering, 2020, 46(2): 423-432.  
颜宏文, 陈金鑫. 基于改进 YOLOv3 的绝缘子串定位与状态识别方法[J]. 高电压技术, 2020, 46(2): 423-432.
- [13] Lai Q P, Yang J, Tan B D, et al. An automatic recognition and defect diagnosis model of transmission line insulator based on YOLOv2 network[J]. Electric Power, 2019, 52(7): 31-39.  
赖秋频, 杨军, 谭本东, 等. 基于 YOLOv2 网络的绝缘子自动识别与缺陷诊断模型[J]. 中国电力, 2019, 52(7): 31-39.
- [14] 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.
- [15] Lin Z C, Miao X R, Jiang H, et al. Multi-model fusion of transmission line insulator self-explosion fault detection [J]. Journal of Fuzhou University (Natural Science Edition), 2020, 48(2): 217-223.  
林志成, 缪希仁, 江灏, 等. 多模型融合的输电线路绝缘子自爆故障检测[J]. 福州大学学报(自然科学版), 2020, 48(2): 217-223.
- [16] Du X Y, Zhong J. Insulator image segmentation based on improved unit-linking pulse-coupled neural network [J]. Laser & Optoelectronics Progress, 2019, 56(15): 151005.
- 杜小燕, 钟俊. 基于改进型 UL-PCNN 的绝缘子图像分割[J]. 激光与光电子学进展, 2019, 56(15): 151005.
- [17] Choi J, Chun D, Kim H, et al. Gaussian YOLOv3: an accurate and fast object detector using localization uncertainty for autonomous driving[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 502-511.
- [18] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08)[2020-08-20]. <https://arxiv.org/abs/1804.02767>.
- [19] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science, 2015, 9351: 234-241.
- [20] Wu Z F, Shen C H, van den Hengel A. Wider or deeper: revisiting the ResNet model for visual recognition[J]. Pattern Recognition, 2019, 90: 119-133.
- [21] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [22] Weiss K, Khoshgoftaar T M, Wang D D. A survey of transfer learning[J]. Journal of Big Data, 2016, 3(1): 1-40.
- [23] Li W T, Jiao D, Zhang Q, et al. Research on intelligent cognition method of self-exploding state of glass insulator based on deep migration learning[J]. Proceedings of the CSEE, 2020, 40(11): 3710-3721.  
李帷韬, 焦点, 张倩, 等. 基于深度迁移学习的玻璃绝缘子自爆状态智能认知方法研究[J]. 中国电机工程学报, 2020, 40(11): 3710-3721.