

基于单阶段目标检测算法的变电设备红外图像目标识别及定位

朱惠玲,牛哲文,黄克灿,唐文虎
(华南理工大学 电力学院,广东 广州 510006)

摘要:针对红外图像中变电设备的识别和定位问题,提出了一种基于改进YOLOv3算法的变电设备检测方法。在现场采集的变电设备红外图像集的基础上,首先使用基于Retinex的图像增强算法以及阈值分割等图像处理对图像集进行预处理;然后基于变电设备红外图像对YOLOv3算法进行参数优化,并通过迁移学习的策略对改进YOLOv3网络进行训练以解决图像集样本数量较少的问题。实验结果表明,在样本数量较少的情况下,所提方法可以达到满意的检测准确率,并能快速地实现变电设备的识别和定位。

关键词:变电设备;目标检测;Retinex图像增强;YOLOv3;迁移学习

中图分类号:TM 507

文献标志码:A

DOI:10.16081/j.epae.202104015

0 引言

非接触式红外测温技术测温范围广、准确度高,因此被广泛地应用于变电站的设备监测中。为确保设备运行的可靠性与稳定性,通过实时监测了解设备的运行状态,可以有效地引导工作人员对设备进行进一步的排查,降低设备故障发生率。为此,充分利用巡检及高清视频监控产生的大量红外图像,对维护电力设备运行、保障电力系统的安全稳定具有十分重要的意义。然而,传统的设备监测依赖经验丰富的工程人员,成本代价高、主观性强。随着智能电网时代的到来,变电站时刻都在产生大量文本、图像、视频及音频等非结构化数据,如果仅凭借人工识别、分类及监测,高强度、繁琐重复的工作显然会导致工作人员效率降低,判别的准确率下降,继而影响电网的自动化水平。因此,实现对变电站的海量红外图像的自动处理,不仅能够克服人工方式的各种缺陷,提高工作效率和检测准确率,还能提高变电站的自动化、智能化水平,从而实现资源的优化配置。

传统的图像处理方法通常通过特征描述子,如尺度不变特征变换和边缘检测符等提取图像特征,结合支持向量机、Adaboost等算法来达到目标分类的目的。文献[1]通过绝缘子图像子块及预设模板边缘方向矢量的计算与匹配,得到绝缘子的候选区

域。文献[2]通过Hough变换分析刀闸边缘图像进而判断刀闸状态。文献[3]研发了一种能够自动识别断路器及其他刀闸的位置状态的机器人,该机器人通过尺度不变特征变换算法匹配先找出目标区域,再利用Hough变换检测直线确定刀闸状态。文献[4]结合绝缘子的形状特征,利用阈值分割和数学形态学分割出可能区域,采用灰度共生矩阵提取纹理信息识别绝缘子。文献[5]利用ASIFT算法将待识别视频与标准图像库中的绝缘子进行匹配,从而识别出绝缘子。上述方法计算复杂,难以充分利用图像信息,且只针对特定的类别,识别准确度较低。

2012年,多伦多大学的Hinton教授在ImageNet竞赛中利用深度学习算法达到了84.7%的分类精度。深度学习的成功促使研究者们纷纷将目光转移到了卷积神经网络框架上,深度学习自此成为人工智能领域的研究热点。2014年,GIRSHICK R等提出了区域卷积网络R-CNN(Regions with CNN)算法^[6],这是一种目标检测算法,目的是在图像上定位出目标的准确位置,并对目标进行分类识别。之后,基于深度学习的目标检测技术迅速发展,二阶段目标检测算法快速R-CNN(Fast R-CNN)^[7]、更快R-CNN(Faster R-CNN)^[8]以及单阶段目标检测算法YOLO(You Only Look Once)^[9]和单次多盒检测器SSD(Single Shot multibox Detector)^[10]等检测框架相继面世。文献[11]通过融合上下文信息构建改进的掩模R-CNN(mask R-CNN)算法^[12],提高了复杂现场环境下电力设备部件的识别准确率,每张图像的处理时间约为800 ms。文献[13]通过收集约20000张图像在不同角度、光照下实现了基于Faster R-CNN的开关指示灯、数字仪器的检测。文献[14]为了避免Faster R-CNN中分类正则化参数可能导致的近似结果,采用支持向量机替换其分类方法从而提高

收稿日期:2020-06-22;修回日期:2021-02-20

基金项目:国家自然科学基金资助项目(51977082);中央高校基本科研业务费专项资金资助项目(x2dl-D2181850);广东电网有限责任公司科技项目(031800KK52180081)

Project supported by the National Natural Science Foundation of China(51977082), the Fundamental Research Funds for the Central Universities(x2dl-D2181850) and the Science and Technology Program of Guangdong Power Grid Co.,Ltd.(031800KK52180081)

了对电缆隧道中积水的识别准确率。文献[15]收集30 000多张巡检图像,通过正则化手段优化Faster R-CNN参数权重,在84.84%的平均检测精度均值下实现约每秒18张的检测速度。但是上述方法仍然有一定的局限性,在保证检测速度的前提下准确率不高,而在提高准确率的前提下无法保证检测的速度。

对于整体灰度值偏低、光照不均匀的红外图像,其目标特征细节不够清晰,增加了检测的难度,为了提高网络的检测效果,图像预处理是很有必要的。常见的图像预处理方法包括直方图均衡法、线性变换法和同态滤波法等。直方图均衡法通过平均图像灰度分布增强对比度,但是容易导致过增强。线性变换法同样会导致图像亮部过度曝光。同态滤波法通过分离图像高、低频信息达到图像增强的目的,缺点是对高光区的增强效果差^[16]。LAND E H于1963年提出的Retinex理论认为人眼观测到的图像是物体反射图像与光照图像的乘积,只要从观测图像中去除光照的影响,即可得到物体反射的理想图像,从而达到图像增强的目的。常见的Retinex增强算法包括单尺度Retinex SSR(Single-Scale Retinex)算法、多尺度Retinex MSR(Multi-Scale Retinex)算法和带色彩恢复的MSR MSRCR(MSR with Color Restoration)算法。SSR算法利用高斯函数和观测图像的卷积来预估光照图像,当高斯函数的方差取值较大时图像颜色失真小但细节恢复差,较小时图像的细节恢复较好但是颜色失真增大。为此,MSR算法对高斯函数的方差进行了3次不同取值后进行加权求和,但是增强后的图像红绿蓝(RGB)比值与原图不同,导致色彩失真。MSRCR算法引入色彩恢复因子,通过调整图像中3个通道的颜色比例减少失真的影响,但同时可能会使颜色发生不可预知的变化。针对以上算法的缺陷,带色度保持的MSR MSRCP(MSR with Chromaticity Preservation)算法取消了MSRCR算法的色彩恢复步骤,通过在强度通道上应用MSR达到保持色度的目的^[17]。

针对Faster R-CNN算法准确率较高但是检测速度慢的问题,同时考虑变电设备红外图像设备目标较大,本文提出了一种改进的YOLOv3^[18]算法对红外图像中的变电设备进行实时识别及定位:首先基于MSRCP算法对现场采集的变电设备红外图像进行预处理,然后对YOLOv3网络进行优化,并采用迁移学习训练网络从而实现变电设备的准确识别及定位。

1 基于YOLOv3算法的图像目标识别及定位

1.1 基于YOLOv3算法的识别及定位网络

YOLOv3算法属于单阶段目标检测算法,它通

过一个神经网络输出目标边界框的位置,实现目标的识别及定位。神经网络的基本结构如附录A图A1所示,主要包含特征提取和检测2个部分。

1)特征提取。采用Darknet-53基础网络对输入图像进行特征提取,该网络借鉴了残差网络ResNet的思想,设置了快捷链路,将2个卷积层和1个快捷链路组成一个残差组件(Residual),从而避免梯度消失和梯度爆炸的问题,保证深度神经网络的学习性能^[19]。

2)检测。随着网络的加深,图像的特征信息部分丢失,不利于小目标物体的检测。为此YOLOv3算法采用多尺度融合方法,通过连接(concatenate)不同层的特征图来减小信息的流失,并采用多尺度检测提高针对小目标的准确率。检测时,输出特征图(图A1中的 Y_1-Y_3)将被划分为 $S \times S$ 个网格,每个网格预测 B 个边界框和 C 个类别概率。每个边界框输出的信息包括反映边界框位置信息的 t_x, t_y, t_w, t_h (t_x, t_y 为预测框的坐标偏移值; t_w, t_h 为预测框的尺度缩放值),反映预测目标框(预测框)中出现目标物体的概率以及该预测框准确度的置信度 c 及所属类别。最后,利用非极大值抑制筛选出具有最高概率,即最能代表目标的边界框来定位目标。

为了减小训练难度,输出特征图中的每个网格都配置了相同尺寸的先验框,预测框会以先验框为基础进行调整。当该网格相对特征图原点的位置为 (C_x, C_y) ,先验框的宽度、高度分别为 p_w, p_h 时,预测框的位置将通过式(1)~(4)进行调整。

$$b_x = \sigma(t_x) + C_x \quad (1)$$

$$b_y = \sigma(t_y) + C_y \quad (2)$$

$$b_w = p_w e^{t_w} \quad (3)$$

$$b_h = p_h e^{t_h} \quad (4)$$

其中, b_x, b_y 为预测框的中心坐标值; b_w, b_h 分别为预测框的宽度和高度; $\sigma(x)$ 为将预测偏移值限制在0~1范围内的Sigmoid函数的输出。

利用K-means聚类算法得到先验框的尺寸。由于预测框的筛选指标是预测框与真实边界框的交并比IOU(Intersection-Over-Union)较大,与预测框的大小无关。因此,K-means聚类算法的距离度量采用IOU距离,计算公式如式(5)所示。

$$d = 1 - \lambda_{\text{IOU}} = 1 - \frac{A \cap A'}{A \cup A'} \quad (5)$$

其中, A 和 A' 为2个边界框; d 为 A, A' 间的IOU距离; λ_{IOU} 为 A, A' 间的IOU值, λ_{IOU} 越大,则 A, A' 越接近, A, A' 间的IOU距离越小。

1.2 损失函数的计算

YOLOv3的损失函数主要可以分为位置损失 L_{loc} 、置信度损失 L_{conf} 以及类别损失 L_{cls} 3个部分,如式

(6)所示^[18]。

$$f_{\text{loss}} = \frac{1}{n} (L_{\text{loc}} + L_{\text{conf}} + L_{\text{cls}}) \quad (6)$$

其中, n 为处理图像总数。

位置损失、置信度损失以及类别损失的具体计算公式分别如式(7)—(9)所示^[18]。

$$L_{\text{loc}} = \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{\text{obj}} (2-wh) (L_{xy} + 0.5 L_{wh}) \quad (7)$$

$$L_{\text{conf}} = \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{\text{obj}} [-\hat{c}_i^j \ln c_i^j + (1-\hat{c}_i^j) \ln(1-c_i^j)] + \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{\text{noobj}} [-\hat{c}_i^j \ln c_i^j + (1-\hat{c}_i^j) \ln(1-c_i^j)] \quad (8)$$

$$L_{\text{cls}} = \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{\text{obj}} [-\hat{p}_i^j \ln p_i^j + (1-\hat{p}_i^j) \ln(1-p_i^j)] \quad (9)$$

其中, L_{xy} 和 L_{wh} 分别为坐标损失和宽高损失; w 、 h 分别为归一化后的预测框宽度、高度; 当网格 i 中的先验框 j 负责预测该目标时 $I_{ij}^{\text{obj}} = 1$, 否则 $I_{ij}^{\text{obj}} = 0$; 当网格 i 中的先验框 j 不负责预测该目标时 $I_{ij}^{\text{noobj}} = 1$, 否则 $I_{ij}^{\text{noobj}} = 0$; c_i^j 、 \hat{c}_i^j 分别为网格 i 中的先验框 j 对应的预测框的置信度预测值、真实值, 当网格 i 中的先验框 j 负责预测该目标时, 其对应的 $\hat{c}_i^j = 1$, 否则 $\hat{c}_i^j = 0$; p_i^j 、 \hat{p}_i^j 分别为网格 i 中的先验框 j 对应的预测框的概率预测值、真实值。

在同一个网格的所有先验框与其真实目标框(真实框)的 IOU 中, 当某一先验框与真实框之间的 IOU 值最大时该先验框将负责预测该目标。由于先验框较小时, 偏移程度对准确率影响较大, 因此在计算坐标损失时利用 $2-wh$ 来平衡预测框尺寸带来的影响。当 wh 较小即预测框较小时, $2-wh$ 较大, 从而提高较小预测框的偏移损失; 当 wh 较大即预测框较大时, $2-wh$ 较小, 从而减小较大预测框的偏移损失。

2 基于 YOLOv3 算法的变电设备红外图像目标识别及定位方法改进

由于红外图像具有对比度低、边缘模糊的缺点, 直接采用 YOLOv3 算法对变电设备的原始红外图像进行检测, 训练速度慢且准确率不高。为了提高准确率, 对 YOLOv3 算法进行改进, 基于改进 YOLOv3 算法的变电设备红外图像目标识别及定位流程如图 1 所示: 首先对现场采集建立的变电设备红外图像进行预处理; 然后对 YOLOv3 网络进行优化, 并利用迁移学习策略训练得到检测模型; 最后通过检测模型即可得到输入图像中待检测设备的种类及其相应的位置。

2.1 变电设备红外图像集的预处理方法

为了过滤图像中的无关信息, 使神经网络更专注于提取有用信息, 加快网络的训练速度, 首先对变

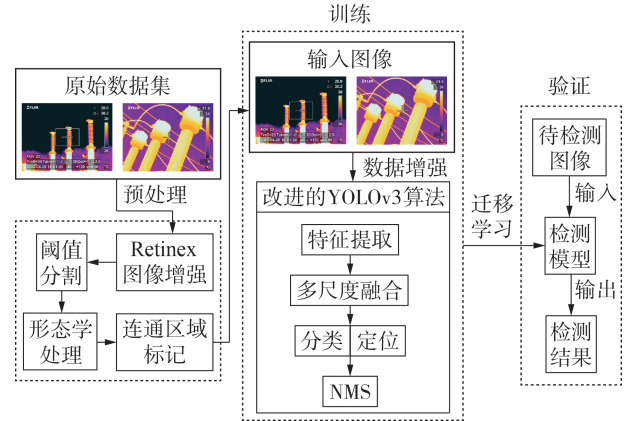


图 1 基于改进 YOLOv3 算法的变电设备红外图像目标识别及定位流程

Fig.1 Flowchart of identification and location of infrared image for substation equipment based on improved YOLOv3 algorithm

电设备红外图像集进行预处理。由于红外图像的前景和背景的颜色差别较大, 使用直方图均衡法或线性变换法反而会导致红外图像的增强效果较差。因此本文将采用 MSRCP 算法对变电设备红外图像进行预处理, 基本流程如下:

1) 分离原图 3 个通道的图像 I_B 、 I_G 、 I_R , 计算强度通道图像 $I = (I_B + I_G + I_R)/3$;

2) 应用 MSR 算法对强度通道图像 I 进行增强, 将增强后的图像记为 I_{MSR} ;

3) 设 S_{max} 为原图中第 i 个像素点 3 个通道的像素值的最大值, 通过 $A_s = \min(255/S[i], I_{\text{MSR}}[i]/I[i])$ (其中, $S[i]$ 为原图中的第 i 个像素点; $I_{\text{MSR}}[i]$ 、 $I[i]$ 分别为步骤 2) 中的 I_{MSR} 以及步骤 1) 中的强度通道图像 I 在第 i 个像素点的值) 计算该点各个通道的放大系数, 然后分别对 3 个通道的像素进行放大, 直至整幅图像都完成放大操作。

变电设备红外数据集的预处理示意图如附录 A 图 A2 所示。图像 1、2 均为变电设备红外原图, 对图像 1、2 分别利用 MSRCP 算法进行增强后可得到相应的 MSRCP 图像。由图 A2 可见, MSRCP 算法能够保持原始图像的色度, 增强对比度, 并在一定程度上减弱复杂背景的影响。为了进一步去除复杂的背景, 采用大津阈值分割法对 MSRCP 图像进行阈值分割, 将分割出的二值图像进行连通区域标记, 并只取面积较大的部分, 去除背景中占比小的多余物体, 最后将保留的像素点映射回原图像, 从而实现对图像中感兴趣的目标的分割。通过以上方法得到的图像背景简单, 前景和背景的对比更加明显, 能够更好地分辨变电设备的边缘特点。

2.2 YOLOv3 网络参数的优化

由于变电设备明显、高大, 因此基于 YOLOv3 算法的变电设备红外图像目标识别及定位网络只在具

有较大感受视野的2个输出尺度下对变电设备进行检测,降低网络的复杂度及参数量,在一定程度上也能加快检测速度。

由于变电设备的预测框是在预先设置的先验框基础上进行位置调整的,YOLOv3算法采用K-means聚类算法得出最适合的先验框尺寸。K-means聚类算法虽然简单实用,但是由于初始的K个聚类点通过随机选取获得,分类结果容易受初始点的影响。为了减小初始点选择的随机性带来的影响,本文采用K-means++聚类算法对变电设备红外图像中的待检测设备进行高度及宽度分析。K-means++聚类算法中,距离当前聚类中心越远的点被选取为聚类中心的概率越高,有效地改善了初始聚类点的选取导致的分类误差,其具体计算流程为:

- 1)将各待检测设备的尺寸作为分析样本,设置 Y_1, Y_2, \dots, Y_K 共K个聚类点;
- 2)随机选取一个样本作为第1个聚类点 Y_1 ;
- 3)计算每个样本 x_i 与最近的聚类点的IOU距离 $d(x_i, Y_k)$,以及该点被选为下一个聚类点的概率 $P = d^2(x_i, Y_k) / \sum d^2(x_i, Y_k)$,然后根据轮盘法选择下一个聚类中心;
- 4)重复步骤3)直至筛选出的聚类点个数为K;
- 5)计算各样本与K个聚类点的IOU距离,并将其分配到IOU距离最小的聚类点的点群中;
- 6)将聚类点修正为点群中IOU距离的中位数,重复步骤5)直至聚类点不再改变,则确定的K个聚类点即为K-means++聚类算法得到的待检测设备的尺寸代表值。

2.3 迁移学习

神经网络的效果依赖于数据样本的数量,基于大量训练数据样本才能拟合出一个表现良好的神经网络。如果训练数据样本少,则训练出的神经网络容易过拟合,且泛化能力较差。

本文建立的数据集比较小,若将其直接用于训练一个变电设备红外图像检测的网络,则训练速度慢且准确率不高。为了加快网络训练速度、增强网络泛化能力、提高准确率,使用PASCAL VOC数据集对YOLOv3网络进行预训练。PASCAL VOC数据集有27450张图像,涵盖了人、动物、家具和交通工具等共20种物体。通过PASCAL VOC数据集训练得到的预训练模型具有强大的泛化能力,其在浅层学习图像低层次的特征,包括图像的边缘、颜色信息等;在深层学习图像的高层语义特征,这些特征将随着图像的不同而有不同的表现。因此,针对变电设备红外图像的检测,本文将在预训练模型基础上进行变电设备红外图像的迁移学习,并分为以下2个阶段。

- 1)阶段1。移植预训练模型的各层网络参数到

基于变电设备红外图像的改进YOLOv3网络中,冻结选中层数之前的参数使其不被调整,通过较大的学习率训练后层的参数以加快改进YOLOv3网络的训练速度;

- 2)阶段2。解冻改进YOLOv3网络的所有参数,通过监测验证损失函数动态减小学习率对网络所有参数进行微调。

3 算例仿真及结果分析

3.1 实验设置

由于目前没有公开的变电设备红外图像集,为了提高检测准确率,本文建立了变电设备红外图像小样本集实现变电设备检测模型的训练。采集2012—2017年广东省广州市多个变电站的设备,包括避雷器(arrester)、开关(breaker)和电流互感器(CT)3类设备的红外图像共509幅(尺寸为640像素×480像素)作为样本数据,其中避雷器、开关、电流互感器的典型样本如附录A图A3所示。由图可见,变电设备的红外图像上不可避免地出现了一些干扰信息,如商标、温度、数值和色卡等。当拍照角度变化时,商标、温度等数值可能会遮挡部分图像,导致边界框标注模糊,影响边界框的学习。同时,图像中不仅包含带电设备,还有停电设备,因此存在背景复杂及对比度弱、图像不清晰的缺点,给变电设备的检测造成了一定的困难。为了加快网络的训练速度,减小网络的学习难度,按照2.1节利用MSRCP算法、大津阈值分割算法等对该数据集进行预处理,将经过预处理的图像建立为新的图像集作为本文的实验数据集。在该数据集中,随机选取了约80%、20%的图像分别作为训练集、网络测试集,详细划分情况见表1。

表1 变电设备红外数据集详细划分情况

Table 1 Detailed classification of infrared data set of substation equipments

设备	训练集数量	测试集数量	总计
避雷器	138	37	175
开关	117	23	140
电流互感器	152	42	194
总计	407	102	509

对每幅图像中的变电设备进行人工标注。通过垂直边界框标记图像中的变电设备,记录边界框的左上点坐标 (x_{\min}, y_{\min}) 、右下点坐标 (x_{\max}, y_{\max}) 及其类别信息(避雷器、断路器或电流互感器),这些信息以标准PASCAL VOC数据集的格式存储在相应的文件中。

本文实验基于Keras深度学习框架,使用的计算机系统为Ubuntu18.04,硬件配置为GeForce RTX

2080 显卡、11 GByte 内存。此外,本文实验网络设置 2 种特征图尺寸对变电设备进行检测,每个尺寸的每个网格都配置 3 个先验框,因此一共需要 6 个先验框,设置 $K=6$ 。通过 K -means++ 聚类算法得到的先验框尺寸如表 2 所示。

表 2 变电设备红外数据集的先验框尺寸设置

Table 2 Anchor size setting of infrared data set for substation equipments

特征图尺寸	感受视野	先验框尺寸
13 像素×13 像素	大	185 像素×263 像素
		225 像素×371 像素
		322 像素×313 像素
26 像素×26 像素	中	134 像素×342 像素
		124 像素×236 像素
		95 像素×259 像素

3.2 迁移学习实验

针对变电设备红外图像小样本集采用迁移学习的方法,在阶段 1 冻结参数时以 0.001 的学习率进行 50 次迭代,完成迭代后解冻网络所有参数,并以 0.0001 的初始学习率对参数进行微调,若验证损失不下降则将学习率降低为原学习率的 10%,以防损失函数在局部最小值附近振荡却无法收敛至最小值。

为了确定迁移学习的冻结层数,在不冻结网络(即冻结层数为 0)、冻结前 153 层网络、冻结前 185 层网络和冻结前 220 层网络这 4 种条件下进行了迁移学习实验,结果如图 2 所示。图中, V_{mAP} 为平均精确率均值。由图可见,当不采用迁移学习时检测准确率最低,这是因为本文所用的变电设备红外图像训练集较小,训练得到的网络泛化能力较差,导致在检测新图像时效果不佳;随着冻结层数的增多,准确率不断升高,在 185 层冻结层数下,网络的检测精度最好。因此,选择冻结前 185 层网络进行迁移学习实现变电设备红外图像的精确检测。




图 2 不同冻结层数下的迁移学习实验结果

Fig.3 Results of transfer learning experiment under different frozen layers

3.3 基于改进 YOLOv3 算法的变电设备红外图像目标识别及定位网络的模型训练及结果

由于本次实验的数据集较小,为了增强网络的

泛化能力,避免网络在学习的过程中产生过拟合的问题,本文采用在线数据增强方法,包括:①随机缩放,即随机缩小或者放大图片,空余部分由灰色填补,对多余部分进行随机裁剪;②随机平移、翻转,即在左/右方向随机移动图像、左/右随机翻转图像;④色调、饱和度、亮度(HSV)调整,即将图像转换到 HSV 空间,随机调整曝光度、饱和度以及亮度。

网络设置训练迭代 1500 次,每次训练随机选取 8 个样本图像,梯度下降算法为 Adam 算法,选择迁移学习的冻结层数为 185 层。通过监控网络损失,综合经济效益,本文选取第 876 轮迭代后的网络权重作为基于改进 YOLOv3 算法的变电设备红外图像的检测模型权重,此时验证损失较低且时间损耗较少。

变电设备红外图像检测模型对输入图像进行检测时,会在输出特征图中输出多个预测框。在对多个预测框进行非极大值抑制(NMS)筛选时,首先过滤掉置信度小于置信度阈值的预测框,然后计算置信度最高的预测框与标注的真实框之间的 IOU 值,若该 IOU 值大于 IOU 阈值则将该预测框判断为预测正确,而同一个检测对象的其余预测框都会被视作预测错误。由此可见,检测模型中有 2 个可调整的阈值,即置信度阈值和 IOU 阈值。在不同的置信度阈值和 IOU 阈值下进行测试,比较不同阈值下模型的检测性能。测试指标为漏检率 O 及错检率 F ,分别如式(10)、(11)所示。

$$O = F_N / (T_p + F_N) \quad (10)$$

$$F = F_p / (T_p + F_p) \quad (11)$$

其中, F_N 为该类变电设备被预测错误的数量; T_p 为该类变电设备被预测正确的数量; F_p 为其他种类的变电设备被错误预测为该设备的数量。

检测模型在不同置信度阈值和 IOU 阈值下的平均错检率和平均漏检率如表 3 所示。当置信度阈值为 0.4、IOU 阈值为 0.45 时,平均漏检率最低且平均错检率也较低。因此,本文最终选定置信度阈值为 0.4、IOU 阈值为 0.45,此时的检测效果较好,不会出现大量漏检、错检的现象。

表 3 阈值选取

Table 3 Threshold selection

置信度阈值	IOU 阈值	平均漏检率 / %	平均错检率 / %
0.3	0.30	6.02	8.11
0.3	0.45	2.64	8.31
0.3	0.60	4.60	9.49
0.4	0.45	2.64	8.05
0.5	0.45	3.47	7.67
0.6	0.45	5.84	5.90

本文基于改进 YOLOv3 算法的变电设备红外图像目标检测模型对测试集的检测结果如附录 A 图

A4所示。由实验结果可以看出,本文方法能够准确定位变电设备的位置并准确识别出设备的类别,检测模型的平均精确率均值达95.97%,其中开关的平均精确率均值达99.07%,避雷器、电流互感器的平均精确率均值也分别达到了93.63%、95.20%,平均检测速率为21.2帧/s,满足实时检测的需求。3种设备的检测结果有所差别,这是因为在该变电设备红外图像集中,避雷器的样式有5种,电流互感器的样式有6种,开关的样式只有3种,相对而言开关的样本反而更多,因此其检测精度高于避雷器和电流互感器。除此之外,避雷器的均压环较细,经过图像预处理后均压环的一部分被消除导致检测精度下降。适当增大训练集中各样式的变电设备图像数量,并在保证一定图片质量的情况下,本文方法能够达到更高的水平。

3.4 不同训练方法对变电设备红外图像目标识别及定位的影响

为了更好地分析各改进方法对变电设备红外图像目标识别及定位的影响,在相同的数据集下分别针对是否采用K-means++聚类方法修改先验框尺寸,是否进行基于MSRCP算法的图像预处理以及是否采用迁移学习方法进行模型训练,各种不同方法训练得出的检测模型的性能如表4所示。

表4 YOLOv3算法在不同训练方法下的检测性能对比

Table 4 Comparison of detection performance of YOLOv3 algorithm under different training methods

训练方法	平均漏检率/%	平均错检率/%
YOLOv3算法	14.17	21.64
YOLOv3算法+迁移学习	6.27	11.87
YOLOv3算法+迁移学习+K-means++聚类算法	5.33	6.97
YOLOv3算法+迁移学习+预处理	5.03	8.17
改进的YOLOv3算法	2.64	8.05

由表4可知,直接采用原始数据集进行YOLOv3网络训练,在测试集上的表现较差,平均漏检率及平均错检率都较高,这是因为模型的泛化能力差;在原始数据集的基础上采用迁移学习的策略,大幅增强了模型的泛化能力,因此在测试集上表现良好,平均漏检率及平均错检率都大幅下降。在此基础上通过K-means++聚类算法对待检测设备的尺寸进行聚类,为网络提供更接近待检测设备尺寸的先验框,进一步减小模型的平均错检率和平均漏检率。基于YOLOv3算法+迁移学习,采用基于MSRCP算法的图像预处理方法将通过增强图像的对比度、特征细节,加强模型的检测能力。其中K-means++聚类算法对模型平均错检率的降低效果更显著,而基于MSRCP算法的图像预处理对平均漏检率的降低效果更显著。这是因为K-means++聚类算法分析了数据集中

的目标设备框大小,从而通过准确的先验知识引导预测框的形成,提高了模型的检测准确率,降低了模型的平均错检率;基于MSRCP的图像预处理则通过抑制图像冗余的信息提升模型的检测能力,使平均漏检率下降。相比于直接利用原始数据集,采用改进的YOLOv3算法,并综合K-means++聚类算法、MSRCP算法以及迁移学习策略将显著提升模型的检测能力及泛化能力,改进的YOLOv3模型的平均漏检率减小了11.53%,平均错检率减小了13.59%。

3.5 变电设备红外图像的不同检测方法对比

为了评估本文方法检测变电设备红外图像的有效性,将本文基于改进YOLOv3算法的变电设备红外图像目标识别及定位方法与Faster R-CNN算法、YOLOv1算法、YOLOv3算法以及基于ResNet50的RetinaNet算法进行比较,其中Faster R-CNN算法、YOLOv1算法、YOLOv3算法以及基于ResNet50的RetinaNet算法均不修改先验框,而是采用原始数据集在预训练权重下得到,对比结果如表5所示。表中, F_s 为每秒传输帧数。

表5 不同目标检测算法对比

Table 5 Comparison of different object detection algorithms

算法	$V_{\text{map}} / \%$	$F_s / (\text{帧} \cdot \text{s}^{-1})$
Faster R-CNN	87.71	11.70
YOLOv1	78.00	43.40
YOLOv3	78.36	19.10
RetinaNet(ResNet50)	89.92	13.54
改进的YOLOv3	95.97	21.20

由表5可以看出,Faster R-CNN算法的平均精确率均值比YOLOv1算法的平均精确率均值要高,这是因为在Faster R-CNN算法中,筛选后剩下的预测框要多于YOLOv1算法,因此Faster R-CNN算法的精确率会更高。但是由于Faster R-CNN包含特征提取和RPN这2个网络,检测速率降低。YOLOv3算法通过对YOLOv1进行正则化、先验框尺寸选取、多尺度检测等优化,平均精确率均值有所提高,但是由于网络变得更加复杂有深度,检测的速度减慢。基于ResNet50的RetinaNet算法的平均精确率均值及检测速率在各算法中表现较为突出,这是因为RetinaNet算法使用了更多的先验框进行目标预测,并采用2个分支分别对类别及预测框的位置进行预测,大幅增强了检测平均精确率均值。通过分析变电站红外图像的特点,对图像进行针对性的预处理,同时对网络参数进行相应的优化,然后采用迁移学习的方法使得本文基于改进YOLOv3算法的变电设备红外图像检测能够在保证较快的检测速率的同时大幅提高准确率,提高工作效率,满足日常的实时检测需求,为进一步的设备故障检测提供保障。

4 结论

变电设备的检测是变电站实现自动化诊断、智能化运行的重要步骤。在变电设备红外图像中,复杂的背景、成像中的商标、瞄准框和温度值等干扰,对红外图像中设备的智能检测造成了一定的影响和挑战。

为此本文首先用基于 Retinex 图像增强的算法增强原始图像的对比度,并用传统数字图像处理方法如大津阈值分割法、连通区域标记等方法减小复杂背景的影响,改善图像的质量。然后对 YOLOv3 尺度参数进行简化并通过 K-means++ 算法分析确定先验框尺寸参数,最后利用迁移学习训练网络,实现了变电设备红外图像的准确检测。实验结果表明,本文方法检测避雷器、开关以及电流互感器这 3 种变电设备的平均精度均值达 95.97%,检测速度达 21.2 帧/s,证明该算法具有非常好的检测效果,为后续故障诊断等处理提供了良好的基础。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] CHENG W, SONG Z. Power pole detection based on graph cut[C]//2008 Congress on Image and Signal Processing. Sanya, China: IEEE, 2008, 3: 720-724.
- [2] 仲莉恩,冯辉,隋立林. 一种利用边缘方向直方图检测绝缘子的方法[J]. 电气技术, 2010(1): 22-25.
ZHONG Lien, FENG Hui, SUI Lilin. An insulator detection method using edge orientation histogram[J]. Electrical Engineering Magazine, 2010(1): 22-25.
- [3] 乐全明,张宗益,孙勇. 基于机器人的变电站开关状态图像识别方法[J]. 电力系统自动化, 2012, 36(6): 101-105.
YUE Quanming, ZHANG Zongyi, SUN Yong. An image recognition method of substation breakers state based on robot[J]. Automation of Electric Power Systems, 2012, 36(6): 101-105.
- [4] 于兰英,姚波,吴文海,等. 一种基于多特征的绝缘子识别方法[J]. 电瓷避雷器, 2016(3): 79-83.
YU Lanying, YAO Bo, WU Wenhai, et al. Insulator identification method based on multi-feature[J]. Insulators and Surge Arresters, 2016(3): 79-83.
- [5] 苑津莎,崔克彬,李宝树. 基于 ASIFT 算法的绝缘子视频图像的识别与定位[J]. 电测与仪表, 2015, 52(7): 106-112.
YUAN Jinsha, CUI Kebin, LI Baoshu. Identification and location of insulator video images based on ASIFT algorithm[J]. Electrical Measurement Instrumentation, 2015, 52(7): 106-112.
- [6] GIRSHICK R, DONEHUE J, DARRELL T, et al. Region-based convolutional networks for accurate object detection and segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 38(1): 142-158.
- [7] GIRSHICK R. Fast R-CNN[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 6517-6525.
- [8] REN S, HE K, 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.
- [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. Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [10] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//European Conference on Computer Vision. Amsterdam, The Netherlands: Springer International Publishing, 2016: 21-37.
- [11] 欧家祥,史文彬,张俊玮,等. 基于深度学习的高效电力部件识别[J]. 电力大数据, 2018, 21(9): 1-8.
OU Jiaxiang, SHI Wenbin, ZHANG Junwei, et al. Recognition of efficient electrical components based on deep learning[J]. Power Systems and Big Data, 2018, 21(9): 1-8.
- [12] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//International Conference on Computer Vision. Venice, Veneto, Italy: IEEE, 2017: 2980-2988.
- [13] 高露,马元婧. 基于 Faster R-CNN 的设备故障检测与识别[J]. 计算机系统应用, 2019, 28(4): 170-175.
GAO Lu, MA Yuanjing. Equipment fault detection and recognition based on Faster R-CNN[J]. Computer Systems & Applications, 2019, 28(4): 170-175.
- [14] 崔江静,黄顺涛,仇炜,等. 改进的 Faster R-CNN 方法及其在电缆隧道积水定位识别中的应用[J]. 电力自动化设备, 2019, 39(7): 219-223.
CUI Jiangjing, HUANG Shuntao, QIU Wei, et al. Improved Faster R-CNN method and its application in recognition of cable tunnel water accumulation[J]. Electric Power Automation Equipment, 2019, 39(7): 219-223.
- [15] 林刚,王波,彭辉,等. 基于改进 Faster-RCNN 的输电线巡检图像多目标检测及定位[J]. 电力自动化设备, 2019, 39(5): 213-218.
LIN Gang, WANG Bo, PENG Hui, et al. Multi-target detection and location of transmission line inspection image based on improved Faster-RCNN[J]. Electric Power Automation Equipment, 2019, 39(5): 213-218.
- [16] 梁琳,何卫平,雷蕾,等. 光照不均图像增强方法综述[J]. 计算机应用研究, 2010, 27(5): 1625-1628.
LIANG Lin, HE Weiping, LEI Lei, et al. Survey on enhancement methods for non-uniform illumination image[J]. Application Research of Computers, 2010, 27(5): 1625-1628.
- [17] RAHMAN Z U, JOHNSON D J, WOODSELL G A. Retinex processing for automatic image enhancement[J]. Proceedings of SPIE-the International Society for Optical Engineering, 2004, 13: 100-110.
- [18] REDMON J, FARHADI A. Yolov3: an incremental improvement [EB/OL]. (2018-04-08) [2020-10-20]. <http://arxiv.org/abs/1804.02767>.
- [19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 770-778.

作者简介:



朱惠玲

朱惠玲(1996—),女,广东开平人,硕士研究生,主要研究方向为人工智能技术在电力系统中的应用(**E-mail**: 18826076797@163.com);

唐文虎(1974—),男,江苏盐城人,教授,博士研究生导师,博士,通信作者,主要研究方向为电力设备智能化、电力系统状态风险评估和计算机智能及应用等(**E-mail**: wenhutang@scut.edu.cn)。

(编辑 任思思)

Identification and location of infrared image for substation equipment based on single-stage object detection algorithm

ZHU Huiling, NIU Zhewen, HUANG Kecan, TANG Wenhui

(School of Electric Power Engineering, South China University of Technology, Guangzhou 510006, China)

Abstract: In order to identify and locate the substation equipment in infrared image, a detection method based on improved YOLOv3 algorithm is proposed. Using the infrared image set of substation equipment collected in the field, the image enhancement algorithm based on Retinex and image processing methods such as threshold segmentation are used to preprocess the image set. Then the parameters of YOLOv3 algorithm are optimized based on infrared images of substation equipment, and the improved YOLOv3 network is trained through the transfer learning strategy to solve the problem of insufficient number of image set samples. The experimental results show that the proposed method can achieve a satisfactory detection accuracy in the case of a small number of samples, and can quickly identify and locate substation equipment in infrared images.

Key words: substation equipment; object detection; Retinex image enhancement; YOLOv3; transfer learning

(上接第207页 continued from page 207)

Evaluation of provincial power grid voltage sag and optimal selection of potential power supply points for industrial users

WANG Jianxun¹, ZHANG Yi¹, CHEN Jingteng², WU Minhui³

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China;

2. State Grid Putian Electric Power Company, Putian 351100, China;

3. State Grid Fujian Electric Power Co., Ltd., Fuzhou 350001, China)

Abstract: Aiming at the problem that most nodes of provincial power grid are lack of measured data and evaluation results of voltage sag, which leads to the lack of basis for industrial users to enter the network, a method of simulating and calculating the voltage sag index of provincial power grid nodes and optimally selecting the potential power supply points of industrial users is proposed. In order to evaluate the voltage sag level of nodes more accurately, the simulation calculation range of provincial power grid is proposed, and the difference of fault rate and fault type ratio of lines with different voltage levels due to the expansion of simulation range is considered. Considering the faults of 10 kV voltage level lines, the BPA model data of 10 kV voltage level lines in the power grid dispatching department is extended, and the automatic call of BPA parallel simulation calculation is realized to obtain the voltage sag index of grid side nodes. The concept of voltage sag associated cost is introduced, and the potential power supply points are selected optimally by comprehensively considering factors such as the grid side voltage sag index, the user side load sag tolerance degree, the voltage sag economic loss, the installation cost of special line, and so on. Through example analysis of a provincial power grid, it is verified that the proposed method can effectively avoid the problem of over-evaluation or under-evaluation of voltage sag, which can provide a reference for industrial users to select potential power supply points.

Key words: provincial power grid; voltage sag; Monte Carlo method; evaluation index; optimal selection of potential power supply points; industrial users

附录 A

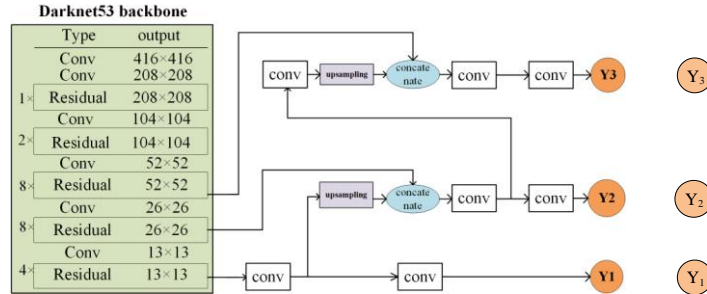


图 A1 基于 YOLOv3 的图像目标识别及定位网络框架

Fig.A1 Identification and location network based on YOLOv3

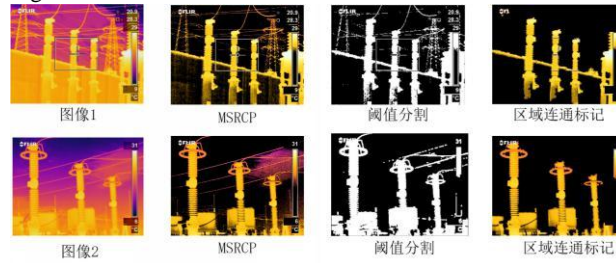


图 A2 变电设备红外数据集的预处理

Fig.A2 Preprocessing of infrared data set for substation equipments




图 A3 变电设备红外数据集的样本示例

Fig.A3 Partial samples of the infrared data set for substation equipments




图 A4 基于改进 YOLOv3 的变电设备红外图像目标识别及定位模型检测结果

Fig.A4 Detection results of identification and location of infrared image for substation equipments based on improved YOLOv3 algorithm