

基于 YOLO v3 的高压开关设备异常发热点目标检测方法

王永平, 张红民, 彭 闯, 郭泓邑
(重庆理工大学 电气与电子工程学院, 重庆 400054)

摘要: 针对高压开关设备红外图像异常发热点检测中存在目标位置场景复杂和大小不均衡带来的检测准确率下降问题, 基于 YOLO v3 算法, 通过添加卷积模块及调整部分超参数对其基础网络架构进行优化, 以实现高压开关设备异常发热点的快速检测、识别和定位。同时, 建立了用于高压开关设备红外图像异常发热点的数据集, 通过训练得出合适的权重。实验结果表明, 该检测方法识别速度快, 准确率高且具有较强的泛化能力, 测试准确率达到 91.83%, 可将其初步应用于高压开关设备异常发热点目标检测中。

关键词: 高压开关设备; 红外图像; YOLO v3; 目标检测

中图分类号: TP391 **文献标志码:** A **文章编号:** 1001-8891(2020)10-0983-05

The Target Detection Method for Abnormal Heating Point of High-Voltage Switchgear Based on YOLO v3

WANG Yongping, ZHANG Hongmin, PENG Chuang, GUO Hongyi

(College of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China)

Abstract: This study aims to solve the problem of reduced detection accuracy caused by a complex target-position scene and an uneven size in the detection of the abnormal heating point in an infrared image of a high-voltage switchgear. According to the YOLO v3 algorithm, the basic network architecture was optimized by including a convolution module and adjusting some hyper-parameters to realize rapid detection and identification of abnormal heating points in high-voltage switchgears. Simultaneously, a dataset for abnormal heating points of infrared images in high-voltage switchgears was established, and appropriate weights were obtained through training. The experimental results indicated that the detection method had a fast recognition speed, high accuracy, and strong generalization ability. The test accuracy reached 91.83%, indicating that the method can be initially applied to the detection of abnormal heating-point targets in high-voltage switchgears.

Key words: high voltage switchgear, infrared image, YOLO v3, target detection

0 引言

高压开关设备作为保护发电厂、变电所等各类配电装置中不可缺少的电气设备, 在日常运行中常因氧化、锈蚀、接触不良、脏污等因素导致的异常发热造成严重损失。运用红外测温成像技术来显示、监测高压开关设备的热异常运行状况是一个非常好的解决方案。

近年来, 深度学习技术已广泛应用于电气设备红外图像处理及识别领域并取得了较好的效果。2017年郭鹏程等人采用二值函数和高斯核函数对 Chan-Vese

模型进行了改进, 使其能有效地分割出电力设备^[1]。2018年贾鑫等基于 GoogleNet 卷积神经网络对红外图像进行特征提取, 然后采用 softmax 损失和 centerloss 损失函数较准确地识别出 5 种电气设备及其故障^[2]。2019年 S. Rokrakthong 等人首先用图像处理技术确定设备零界温度, 再利用 R-CNN 对电气设备类型进行识别, 准确率达 91%^[3]。2018年 Ying Lin 等人则通过 RPCA (robust principal component analysis) 优化和位置统计, 提取出标记的温度范围区域, 然后分别对每个单个数字和符号进行分割^[4]。2019年 L. Lianqiao 等人基于 YOLO 算法, 对组合滤波器、绝缘瓷套、隔离

收稿日期: 2020-03-08; 修订日期: 2020-06-20.

作者简介: 王永平 (1990-), 男, 硕士, 研究领域为电气设备红外图像故障诊断, E-mail: ypwang0001@126.com.

通信作者: 张红民 (1970-), 男, 博士, 教授, 研究领域为图像处理与模式识别, E-mail: hmzhang@cqut.edu.cn.

基金项目: 重庆市基础与前沿研究计划项目 (cstc2015jcyjA40051, cstc2016jcyjA0497, cstc2016jcyjA0447)。

开关、均衡环4种电气设备红外图像进行目标检测和器件温度测量,识别准确率达到80%以上^[5]。2019年R. Gitzel等人使用对抗生成性网络对开关设备的红外图像进行改善和加强,提高了对开关设备故障或非故障状态检测的效率^[6]。

目标检测算法R-CNN(region with convolutional neural network)^[7-8]是近年来深度学习领域中广受关注的检测方法,其对图像生成可能包含目标的候选区域(region),然后用卷积神经网络(CNN)对候选区域进行分类,精度很高,但在速度方面表现欠佳^[9]。YOLO在目标检测时,以整张图作为输入,在特征层输出边框位置和所属的类别,从而转变为一个回归问题。文献[10]指出One-stage检测算法准确率低的原因之一是数据集中简单易分的样本与复杂难分的样本之间存在严重的不均衡现象,使得算法出现误检测,而且也会影响损失函数的梯度更新方向。2019年,吴双忱等人将弱小目标的检测问题转化为对小目标的位置分布的分类问题,通过使用全卷积网络对红外图像进行背景抑制,再引入SENet对图像特征进行提取以达到检测目的,虽然其对小目标检测效果较好,但实现步骤较为复杂^[11]。针对以上问题,通过对高压开关设备红外图像的分析,本文通过采用YOLO v3(You Only Look Once vision3)算法^[12]并对其模型进行合理优化,实现了高压开关设备异常发热点目标快速准确检测。

1 高压开关设备红外热图数据集构建

本文的红外图像数据采集来源于重庆电网公司红外典型故障图库。数据集中异常发热的高压开关设备类型有:隔离开关、断路器、熔断器等,建立共计960张的数据集。图1为数据集部分典型样本。

由图1可以发现高压开关设备红外图像具有以下特点:采集到的红外图像中不可避免地存在其他非目标电力设备;采集到的高压开关设备红外图像会因为热像仪拍摄角度、远近的不固定,导致设备在图像中的形状和大小不规范。以上因素导致传统的红外图像目标识别对热异常的检测比较困难。针对这些难点,收集了大量的高压开关设备红外图像(960张)建立数据集,使用现有深度学习的网络的训练模型,以实现较为满意的热异常目标检测。

本文使用图片标注工具(label Img)对数据集进行标注:若高压开关设备红外图像存在异常发热的情况,则将红外热像图中发热点用矩形框标记,标记后的红外图片以XML文件存储,作为对应训练图片的标签(如图2所示)。

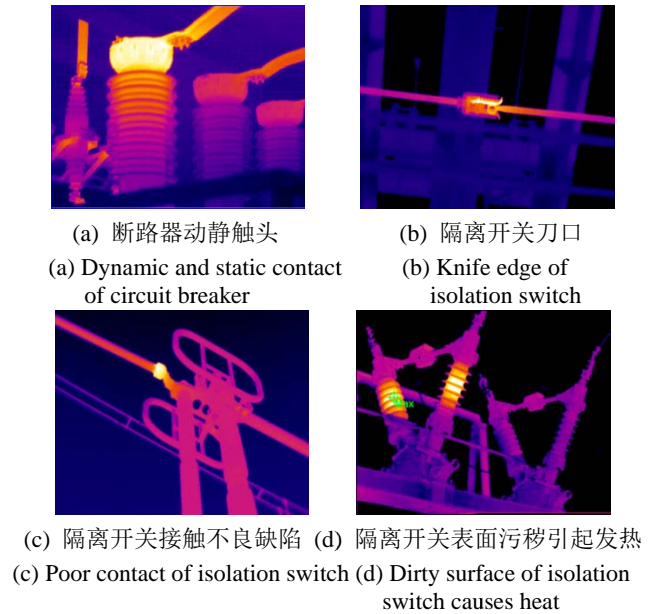


图1 典型高压开关设备热故障

Fig.1 Typical high-voltage switch thermal faults




图2 异常发热点标注示意图

Fig.2 Schematic diagram of abnormal heating point labeling

数据由训练集、测试集、验证集3部分组成(如表1所示),共使用960张图片进行训练,对已标记好的异常发热的高压开关设备红外图像进行整理,以XML文件作为对应红外图片训练的标签,存储了3个属性:Label、Pixels、Usage。

表1 数据的训练集组成

Table1 Data consists of training sets	
Data set type	Number of pictures
Training set	760
Validation set	110
Testing set	90

2 基于YOLO v3的深度学习算法

2.1 YOLO v3 模型

YOLO v3^[12]是一种在对目标进行识别和定位算法过程中,将问题转化为了回归问题,把输入图片中提取出的特征图划分为不同大小的各类网格,在每个网格上通过候选框检测,最后输出每个候选框检测的置信度、类别概率和坐标。其特点是运行速度快,可以用于实时系统。不仅具有检测速度快速的性质,而且还在检测精度方面得到提升,同时还具备检测大、中、小目标的能力,这与高压开关设备热故障诊断的应用极为契合。

YOLO v3 提取红外图像特征时,采用的是Darknet-53网络结构,如表2所示,它含有53个卷积层,同时借鉴残差网络(residual network)^[13],在卷积层之间设置了快捷链路(shortcut connections)。

表2 YOLO v3 模型参数

Table 2 Parameters of YOLO v3 model

	Type	Filters	Size	Output
Inputs	Convolutional	32	3×3	416×416
	Convolutional	64	3×3/2	208×208
1×	Convolutional	32	1×1	208×208
	Convolutional	64	3×3	
	Residual	64	1×1	
	Convolutional	128	3×3/2	104×104
2×	Convolutional	64	1×1	104×104
	Convolutional	128	3×3	
	Residual			
	Convolutional	256	3×3	52×52
8×	Convolutional	128	3×3	52×52 (feature 3)
	Convolutional	256	3×3	
	Residual			
	Convolutional	512	3×3/2	26×26
8×	Convolutional	256	3×3	26×26 (feature 2)
	Convolutional	512	3×3	
	Residual			
	Convolutional	1024	3×3/2	13×13
4×	Convolutional	512	3×3	13×13 (feature 1)
	Convolutional	1024	3×3	
	Residual			

Darknet-53为特征提取网络,首先以416×416×3的红外图像作为输入,然后采用残差结构使得网络更深,同时采用了short cut机制解决梯度消失问题,恒等变换(identity mapping)使得网络更加容易优化,收敛能力加快,最后用feature 1、feature 2、feature 3进行多尺度的回归检测,如图3所示。

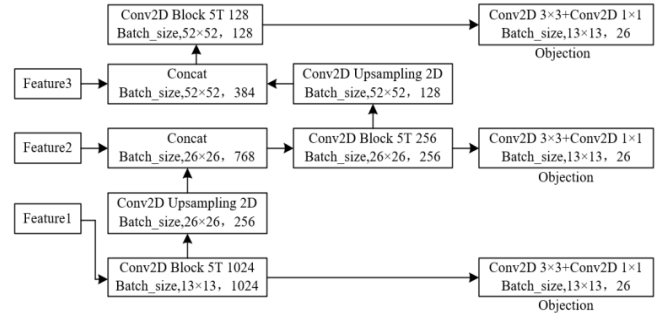


图3 YOLO v3 目标检测

Fig.3 YOLO v3 target detection

2.2 YOLO v3 算法的优化

高压开关设备红外图像异常发热目标检测存在的问题如下,有些高压开关设备红外图像采集时距离近,背景单一,干扰因素较少,容易找到异常发热点;而有一些在采集图像时距离远,干扰因素较多,属于待检测难定位目标。因此,在目标检测时存在着待检测目标复杂度不均衡问题。针对以上问题,对YOLO v3 算法进行了如下方面的优化:

1) 参数优化

在参数优化中使用了Adam Optimizer 算法和Momentum Optimizer 算法进行尝试。

Momentum Optimizer 在更新参数时,利用了超参数,参数更新公式为:

$$p_i = \alpha_1 p_{i-1} + g(\mu_{i-1}) \quad (1)$$

$$\mu_{i-1} = \mu_{i-1} - \beta p_i \quad (2)$$

式中: α_1 为超参数; β 为学习率(初始值为0.001); μ 为参数; $g(\mu_{i-1})$ 为损失函数的梯度。

Momentum 算法计算了梯度的指数加权平均,减少了纵轴的震荡,加快了横轴的迭代速度,但其收敛较慢。

Adam Optimizer 通过利用梯度的一阶矩阵估计和二阶矩阵估计,为不同的参数设计了独立的自适应学习率,而且能够存储之前衰减的平均梯度,是一种寻找全局最优的优化算法,集成了动量梯度算法和RMS (root mean square) 梯度下降算法的优点。因此,参数优化使用Adam 优化器在训练过程中进行优化(初始学习率为0.001)。

2) 损失函数优化

YOLO v3的优化后的损失函数由公式(3)中的两部

分组成，分别是置信度损失函数和位置回归损失函数：

$$L_{(c,x,y,w,h)} = \frac{1}{M} (L_{\text{Conf}(x,c)} + \varphi L_{\text{loc}(x,y,w,h)}) \quad (3)$$

式中： $L_{(c,x,y,w,h)}$ 为优化后的 YOLO v3 损失函数； M 为匹配到目标区域的 Default Box 的数量； φ 为用于调整 Confidence loss 和 Location loss 的比例（ $\varphi_{\text{初}}=1$ ）。

3) 检测框的优化

在高压开关设备红外图像中 Ground truth (GT) 是非常少的，Default_box 是非常多的，因此采用以下步骤对其抑制：

Step 1: 取 IOU 最高的 pre_box 与 GT 匹配，保证 Feature map 上的 Default_box 至少有一个与 GT 匹配；

Step 2: 若剩余 Default_box 的 IOU 大于阈值，则 GT 对应多个 Default_box。采用模块对正负样本进行选择，使其正负样本比例控制在 1:3；

Step 3: 采用非极大值抑制模块 (non-maximum suppression, NMS) 检测，得分最高的框保留，其他与被选中框有明显重叠的检测框被抑制。

经改进后的 YOLO v3 使得数据集中占少数的样本对损失函数的贡献度将得到提升，同时目标标定框的准确率有所提升。

3 实验结果与分析

实验环境: 本文在 Linux 系统下使用 Ubuntu 16.04 的系统平台, 在 Python2.7.15 下使用 Tensorflow 1.3.0, 计算机配置如表 3 所示。

表 3 实验硬件设备

Device name	Configuration
Processor	Intel Core i5-7300HQ
GPU	NVIDIA GeForce GTX 1050 Ti
RAM	8 G
Hard disk	128 G

3.1 模型效果展示

在新建的高压开关设备红外图像数据集中，随机抽取 8 张异常发热故障测试图像，对迁移学习加载权重训练出来的模型，进行测试，测试效果如图 4 所示。

图 4 中可以看出，具有异常发热的高压开关设备的亮白区域，不论存在单个异常发热区域，还是存在多个异常发热区域均能被正确的标定，同时矩形框的大小符合目标区域的大小。

实验测试结果表明，优化后的 YOLO v3 能够从复杂的红外图像中比较准确地识别和定位出高压开关设备的异常发热故障点，同时具有较高的检测精度。




图 4 模型测试效果图 Fig.4 Model test effect diagram

3.2 实验结果分析

Loss 曲线是用来表示预测的目标值与实际的目标值的差距。在卷积神经网络训练时，网络中的所有参数不断地被优化，使得损失函数的值连续减小，从而得到表现更加优异的卷积神经网络模型。图 5 显示出，该模型在学习率方面因被修改后的损失函数而表现良好。

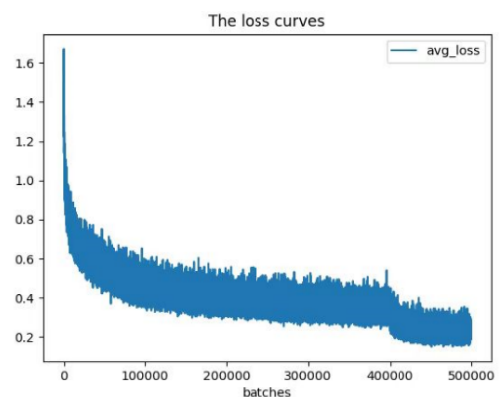


图 5 Loss 曲线图 Fig.5 The loss curve

IOU (intersection-over-union) 是一个衡量我们的模型检测故障目标好坏的重要指标，预测的框与标注的框的差异性越接近越好，这样才会使得标注框与预测框的重合程度提高。从图 6 可以看出，随着 batches 的增加，矩形框能够与目标完美地重合。

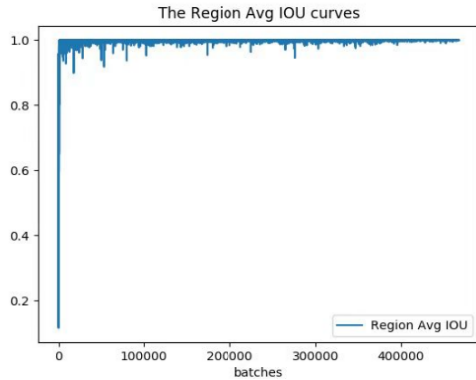


图6 IOU 曲线图 Fig.6 The region Avg IOU curves

使用平均精度 (mean average precision, mAP) 作为评价指标, 对算法进行评估, 由表 4 可以看出, 优化后的 YOLO v3 的 mAP 值达到 91.83%, 与 Faster R-CNN 效果接近, 较一次性回归检测算法 SSD300、RetinaNet 和 YOLO v3 分别提升了 0.1011、0.1215、0.0818。SSD300 采用多层特征图作为预测输出, 在网络加深时, 目标的特征进一步弱化, 网络无法对其进行有效表征。RetinaNet 采用了 Focalloss, 有效地提升了正负样本不平衡问题, 然而由于其处理基础网络较为简单, 相比较 YOLO v3 所采用的 DarkNet-53 网络依旧缺乏对红外目标的特征提取, 而优化后 YOLO v3 在高压开关设备异常发热点检测时平均精度相对较高。

表 4 实验结果及算法对比

Table 4 Experiment results and algorithm comparison

Experimental method	Baseline	mAP/%
Faster R-CNN	Vgg16	92.25
SSD300	ResNet-50	81.72
RetinaNet	ResNet-50	79.68
YOLO v3	DarkNet-53	83.65
Optimized-YOLO v3	DarkNet-53	91.83

4 总结

高压开关设备是保护电气设备的重要一环。在系统的日常运行、维护或更换过程中可能会出现发热故障, 从而可能引发系统故障问题。此时使用红外图像故障诊断识别技术是一个很好的解决方案。本文提出了基于 YOLO v3 的高压开关设备红外图像异常发热点目标检测方法, 通过对该算法参数、Loss 函数和检测框的优化, 使得检测的速度和误差在高压开关设备异常发热点检测中得到了大大的改善。实验测试结果表明, 优化后的 YOLO v3, 能够弱化干扰信息, 使得红外图像中的异常发热故障点被准确地定位和识别出来, 应用效果较为理想, 具有较高的实际应用价值。

需要特别说明的是, 实验时如果测试集得出的准确率很高, 实际目标检测的准确率上不去, 要考虑图片噪声是否过大, 若是则应先进行图片预处理, 使预

处理后的输入图片尽量接近测试集中的图片。因为测试集和训练集是相对独立的, 测试集得出的准确率对模型是有意义的。

参考文献:

- [1] 顾鹏程, 黄福珍. 基于改进 Chan-Vese 模型的电力设备红外图像分割[J]. 计算机工程与应用, 2017, 53(10): 193-196, 212.
GU Pengcheng, HUANG Fuzhen. Power equipment infrared image segmentation based on improved Chan-Vesemodel[J]. *Computer Engineering and Applications*, 2017, 53(10): 193-196, 212.
- [2] 贾鑫, 张惊雷, 温显斌. 双监督信号深度学习的电气设备红外故障识别[J]. 红外与激光工程, 2018, 47(7): 32-38.
JIA Xin, ZHANG Jinglei, WEN Xianbin. Infrared faults recognition for electrical equipments based on dual supervision signals deep learning[J]. *Infrared and Laser Engineering*, 2018, 47(7): 32-38.
- [3] Rokrakthong S, Suesut T, Tumrukwatthana N. Applying CNN to infrared thermography for preventive maintenance of electrical equipment [C//OL][2019-03-15]//*Proceedings of the International Multiconference of Engineers and Computer Scientists*, 2019: http://www.iaeng.org/publication/IMECS2019/IMECS2019_pp367-370.pdf.
- [4] LIN Y, QIN J, ZHANG W. Rpga based temperature digit extraction for electrical equipment infrared images[C]//*Top Conf. Series: Journal of Physics: Conf. Series*, 2018: 7.
- [5] LI Lianqiao, CHEN Xiai, ZHEN Huili, et al. Recognition and application of infrared thermal image among power facilities based on Yolo[C] //2019 *Chinese Control and Decision Conference*, 2019: DOI: 10.1109/CCDC.2019.8833160.
- [6] Gitzel R, Amihai I, Perez M S G. Towards robust MI-algorithms for the condition monitoring of switchgear[C]//2019 *First International Conference on Societal Automation, IEEE*, 2019: 1-4.
- [7] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 *IEEE Conference on Computer Vision and Pattern Recognition*, 2014: 580-587.
- [8] Uijlings J R R, K E A van de Sande, Gevers T, et al. Selective search for object recognition[J]. *International Journal of Computer Vision*, 2013, 104(2): 154-171.
- [9] 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.
- [10] LIN T, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(2): 318-327.
- [11] 吴双忱, 左峥嵘. 基于深度卷积神经网络的红外小目标检测[J]. 红外与毫米波学报, 2019, 38(3): 371-380.
WU Shuangchen, ZUO Zhengrong. Small target detection in infrared images using deep convolutional neural networks[J]. *Infrared Millim. Waves*, 2019, 38(3): 371-380.
- [12] Redmon J, Farhadi A. Yolo v3: an Incremental Improvement[R//OL]. *Computer Vision and Pattern Recognition*, 2018: <https://arxiv.org/abs/1804.02767>.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 *IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770-778.