

[文章编号] 1003-4684(2022)05-0006-06

基于改进 YOLOv4 的电力高空作业安全带检测

顿伟超, 王淑青, 张鹏飞, 王 娟

(湖北工业大学电气与电子工程学院, 湖北 武汉 430068)

[摘 要] 为了让电力工作人员在电力作业中采取规范的防护措施,提出了一种基于改进 YOLOv4 的电力高空作业识别及安全带佩戴检测算法。首先,该算法采用 MobileNetv2 作为主干提取网络,在保证较好的特征提取效果同时降低了网络的参数量,提高模型的识别速度;然后使用 K-means 聚类算法对数据集中的目标边框重新聚类,并调整空间金字塔池化结构,提高模型的检测精度;最后使用 Soft-NMS 算法替换原 NMS 算法降低目标的漏检率。实验结果表明,改进 YOLOv4 网络模型比原 YOLOv4 模型 mAP 提高 3.2%,检测速度提高 30fps,模型的训练权重大小压缩 4.16 倍,算法在高空作业安全带检测上具有很强的实用性和高效性。

[关键词] 安全带;深度学习;YOLOv4;MobileNet;卷积神经网络

[中图分类号] TP391.4 **[文献标识码]** A

随着深度学习的快速兴起,目标检测算法也获得显著发展,基于深度学习的目标检测算法大致可以分为 One-stage 和 Two-stage 两大类别。One-stage 算法即单阶段目标检测算法,主要包括 YOLO 系列^[1-4]算法和 SSD^[5]算法,该类算法是基于回归的检测算法,直接利用预训练主干网络产生目标的类别概率和位置坐标,其检测目标精确度相略低于双目标检测算法,但检测速度较快。Two-stage 算法即双阶段目标检测算法,主要包括 R-CNN^[6]、Fast R-CNN^[7]、Faster R-CNN^[8]、Mask R-CNN^[9],该类算法是基于区域建议的检测算法,首先通过 RPN 网络生成待检测目标的候选区域,然后对这些候选区域进行分类和位置回归,由于该类算法将目标检测分成了两步,所以其检测速度低于单阶段目标检测算法。目前基于深度学习的目标检测算法被广泛应用于各行各业^[10-12]。

在电力检修高空作业时,检修人员对佩戴安全带的规定,仅依赖于自身自觉性以及现场监督人员的提醒,但有时由于人手不够,现场并未指派监护人员。同时针对公司指派的临时活,部分工作人员因为怕麻烦就不佩戴安全带,直接进行高空作业,容易导致高空坠落事故的发生。目前现有目标检测方法并未应用于高空电力安全带检测,为确保电力工作人员采用规范的防护措施和操作流程,本文采用目标识别相关算法对施工现场进行合规检测,能够提

高工作人员安全防护意识,提升现场安全作业水平,实现对违章人员智能化的安全管理,保障工作人员的生命安全。

针对上述安全管理制度存在的盲点问题,本文将传统 YOLOv4 深度学习网络的 CSPDarknet53 替换为 MobileNet,同时修改 PAnet 结构和 Head 结构中的网络,使用深度可分离卷积网络,降低网络训练的参数,提高网络的检测速度,构建一种改进 MobileNet_YOLOv4 网络的电力高空作业安全带佩戴检测模型,实现了复杂环境中对检修人员是否佩戴安全带的标记,以及对施工现场监护人员和其它无关人员的标记。针对 YOLOv4 网络使用的 NMS 算法使重叠程度较高的物体漏检现象,本文采用 Soft-NMS 算法对传统的 YOLOv4 中的 NMS 算法进行改进,降低被检测对象目标的漏检率,提升检测精度。

1 网络结构分析算法原理

1.1 YOLOv4 目标检测算法

YOLOv4 是一种目标检测算法,是 YOLOv3 模型的进化,相比 YOLOv3 算法,AP (Average Precision)和 FPS (Frames Per Second)分别提升了 10%和 12%。同时它的检测速度是 EfficientDet 的两倍。使用 Tesla V100 显卡在 MS COCO 数据集测试其检测精度可达 43.5% mAP (65.7% AP50),

[收稿日期] 2021-11-30

[基金项目] 国家自然科学基金青年基金(62006073)

[第一作者] 顿伟超(1994-),男,河南许昌人,湖北工业大学硕士研究生,研究方向为人工智能与深度学习

[通信作者] 王淑青(1969-),女,河北衡水人,湖北工业大学教授,研究方向为人工智能

实时检测速度可达 65 FPS^[13]。YOLOv4 目标检测网络主要包括 CSPDarknet53 主干特征提取网络、Spatial Pyramid Pooling (SPP)^[14]+Path Aggregation Network (PANet)^[15] 加强特征提取网络和 YOLO Head 特征图预测网络。

1.2 MobileNet 网络结构

MobileNet^[16]模型是 Google 针对手机等嵌入式设备提出的一种轻量级的深层神经网络,其使用的核心思想便是深度可分离卷积块。深度可分离卷积其实是一种可分解卷积操作,其可以分解为两个更小的操作: $D_K \times D_K$ 的深度卷积和 1×1 的逐点卷积^[17],如图 1 所示。深度可分离卷积和标准卷积不同,对于标准卷积,其卷积核是用在所有的输入通道上,而深度可分离卷积针对每个输入通道采用不同的卷积核,就是说一个卷积核对应一个输入通道,所以说深度可分离卷积是 Depth 级别的操作。而逐点卷积其实就是普通的卷积,只不过其采用 1×1 的卷积核。




图 1 标准卷积和深度可分离卷积结构

假定输入特征图大小是 $D_F \times D_F \times M$,而输出特征图大小是 $D_F \times D_F \times N$,使用 $D_K \times D_K$ 卷积核,其中 D_F 是特征图的宽和高, M 是输入通道数, N 是输出通道数, D_K 是卷积核的空间维数,那么标准卷积的计算量为: $D_K \times D_K \times M \times N \times D_F \times D_F$;深度可分离计算量为: $D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F \times D_F \times D_F$,深度可分离卷积与标准卷积计量比较如下:

$$\frac{D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F \times D_F \times D_F}{D_K \times D_K \times M \times N \times D_F \times D_F} = \frac{1}{N} + \frac{1}{D_K^2} \quad (1)$$

一般情况下 N 很大,MobileNet 采用 3×3 的卷积核则深度可分离卷积相对于标准卷积可以降低 8—9 倍的计算量。

2 改进的 YOLOv4 网络模型

2.1 主干特征提取网络的替换

将 YOLOv4 深度学习网络的 CSPDarknet53 替换为 MobileNet 作为特征提取网络,替换后的

MobileNet_YOLOv4 网络结构见图 2。同时修改 PANet 和 YOLO Head 结构中的网络,将 3×3 普通卷积块,改为深度可分离卷积块即一个 3×3 的深度可分离卷积+ 1×1 的普通卷积,替换前后卷积核结构。

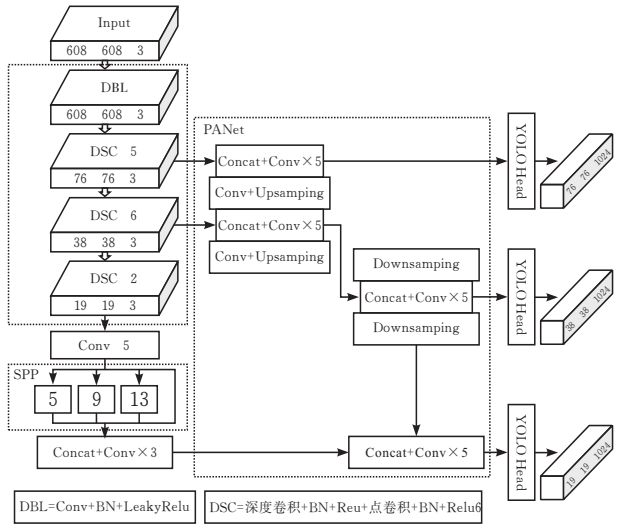


图 2 MobileNet_YOLOv4 网络结构

改进的 MobileNet_YOLOv4 网络模型仍采用 YOLOv4 模型中的损失函数 CIoU,该损失函数是在 YOLOv3 模型的基础上得到的,该损失函数由目标位置损失函数、置信度损失函数与分类损失函数三部分组成^[18],如下:

$$\text{Loss} = \text{loss}_{\text{loc}} + \text{loss}_{\text{obj}} + \text{loss}_{\text{cls}} \quad (2)$$

2.2 先验框尺寸与数量的设置

YOLOv4 输出的 3 个尺度特征图分别为: 52×52 、 26×26 和 13×13 ,每个尺度的特征图对应 3 个固定尺寸的先验框。其中尺度为 52×52 特征图感受野较小,选用尺寸较小的先验框(12,16)、(19,36)和(40,28)检测较小目标,尺度为 26×26 的特征图选用尺寸中等的先验框(36,75)、(76,55)和(72,146)检测中等大小的目标,尺度为 13×13 的特征图具有较大的感受野,选用尺寸较大的先验框(142,110)、(192,243)和(459,401)来检测大目标。

YOLOv4 模型的先验框是在 COCO 数据集上聚类得到的,而 COCO 数据集中有 80 类待检测目标,这些目标的形状尺寸大小不一,不同类别之间差异较大,导致聚类出来的先验框尺寸不一,且本文的检测目标的形状大多是高大于宽,因此无法使用 YOLOv4 模型预设的先验框。本文使用 K-means 聚类算法获取电力现场作业数据集中的标签情况,生成更加符合高空作业及安全带检测对象的先验框。传统的 K-means 聚类算法采用欧式距离函数进行聚类,本文采用聚类中心与数据集标签中 box 的 IoU 值作为聚类相似度的评判标准,可以极大程

度保证获取的先验框与检测目标的尺寸大小更加匹配。聚类距离计算方法如下：

$$d[\text{box}, \text{center}] = 1 - \text{IoU}(\text{box}, \text{center}) \tag{3}$$

式(3)中 $d[\text{box}, \text{center}]$ 为实际目标框与聚类中心的距离, center 为聚类中心。

本文图像的输入尺寸为 608×608 , 采用 K-means 算法输出 9 个尺寸的先验框分别应用到不同尺度的检测层中, 分配结果见表 1。

表 1 不同尺寸的特征图对应的先验框尺寸

特征图	先验框尺寸		
76×76	(12, 19)	(30, 35)	(40, 82)
38×38	(62, 197)	(94, 102)	(106, 264)
19×19	(167, 170)	(180, 312)	(298, 452)

2.3 空间金字塔池化结构的改进

原 YOLOv4 模型在空间金字塔池化结构 (SPP) 分别采用了 1×1 、 5×5 、 9×9 和 13×13 四个尺度的卷积核对 19×19 的特征图进行最大池化操作, 然后对池化结果进行堆叠, 再进行三次卷积操作, 来加强图像的特征提取。本文尝试对 SPP 结构进行适配性的调整, 并通过实验来验证不同 SPP 结构对模型检测效果的影响。实验过程中调整 SPP 结构为 1×1 、 3×3 、 5×5 池化内核命名为 SPP_A, 1×1 、 3×3 、 5×5 、 7×7 池化内核命名为 SPP_B, 1×1 、 5×5 、 7×7 、 9×9 池化内核命名为 SPP_C。

2.4 改进后的 NMS 算法

在实际的电力高空作业过程中, 摄像头可能会捕捉到维修人员相互遮挡的画面, 直接使用传统非极大抑制算法 (NMS) 容易将重叠程度较大的检测框直接删除, 造成漏检现象。针对此情况, 本文采用 Soft-NMS^[19] 替换原 YOLOv4 模型中的 NMS, 改进后非极大抑制中的置信度重置函数为：

$$S_i = \begin{cases} S_i, \text{IoU}(M, b_i) < N \\ S_i(1 - \text{IoU}(M, b_i)), \text{IoU}(M, b_i) \geq N \end{cases} \tag{4}$$

式(4)中 S_i 为第 i 个预测框的置信度, M 为当前得分最高框, b_i 为待处理的预测框 IoU 为 M 和 b_i 交并比, N 为设置的阈值。

由式(4)可知, M 和 b_i 交并比越大, b_i 的得分 S_i 就下降得越快, 且呈线性衰减。但由于这种衰减方式所产生的函数并不是连续函数, 因此采用高斯加权的方式使其成为一个连续的分数的重置函数, 最终改进如下：

$$S_i = S_i e^{-\frac{\text{IoU}(M, b_i)}{\sigma}}, \forall b_i \neq D \tag{5}$$

式(5)中 D 为检测框集合, σ 为超参数。

由公式(5)可知该连续函数对重叠度越高的检测框置信度得分衰减越厉害, 对没有重叠的检测框置信度得分保持不变, 能够有效避免因强制删除检

测框造成的漏检情况, 提升检测精度。

3 实验及结果分析

3.1 电力高空作业人员数据集的收集与处理

本次实验采用的数据集来自广东某电厂, 共获取 1700 张高空作业图片作为训练样本, 600 张高空作业图作为测试样本, 获取的图片均为电厂高空作业人员的模拟训练图, 保证了此次实验数据的真实性与客观性。然后通过 labeling 软件对数据进行标签制作, 标签标注格式为 txt 格式, 在对目标进行手工标注时, 尽可能准确框出目标的全部样貌, 同时避免边界框包含不必要的背景。实验数据共计 2300 张图像, 共制作标签数据 11 060 个(表 2)。

表 2 数据集分布情况

检测目标类别	训练集	测试集
person	5821	1954
gaders	1389	428
offgroundperson	1821	639
safebeltperson	1540	482

标签一共分为 4 类, 分别为: 作业现场中包含的人(其中包含监护人员和无关人员)、作业现场中自带的监护袖章(此类人员为监护人员)、作业现场中的离地状态人员(此类人员为高空电力维修人员)、作业现场佩戴的安全带, 将这四种类别依次标注为 “person”、“gaders”、“offgroundperson”、“safebelt-person”。数据标注如图 3 所示。数据标注后保存的文本文件部分内容见表 3。使用代码对标注后的数据集随机划分, 将 90% 的标注图像作为训练集, 10% 作为测试集。



图 3 图像标注

表 3 数据标注

类别	x	y	w	h
0	0.457 661	0.147 681	0.124 328	0.211 694
2	0.461 022	0.122 228	0.098 790	0.048 387
3	0.568 852	0.365 347	0.154 980	0.093 147

表 3 中的每一行均代表了一个待检测目标的位置信息, x 、 y 、 w 、 h 是相对于图片尺度的归一化值, 介于 0~1 之间。 x 、 y 分别代表标注框中心点在 x 轴和 y 轴方向的坐标; w 、 h 分别为标注框的宽和高。

3.2 实验环境的配置

实验硬件采用 Intel(R) Xeon(R) CPU E5-1650 v3 @ 3.50GHz, 内存为 16GB, GPU 为 NVIDIA GeForce RTX2080Ti, 显存 11GB。操作平台为 Windows 10, 加速环境为 CUDA10.0 和 CUDNN7.6.0, 深度学习框架为 Pytorch1.7.1 版本。

实验整个训练过程为 200 个 epoch, 其中前 100 个 epoch 采用冻结部分网络可以加快训练速度, 学习率设置为 0.001, batchsize 设置为 16, 后 100 个 epoch 的学习率设置为 0.0001, batchsize 设置为 8, 优化器均采用 Adam。

3.3 评价指标

使用训练好的网络模型对测试集进行检测, 按照下式分别计算查准率 (Precision)、召回率 (Recall)。

$$\left\{\begin{aligned} \text{Precision} &= \frac{\text{TP}}{\text{TP} + \text{FP}} \\ \text{Recall} &= \frac{\text{TP}}{\text{TP} + \text{FN}} \end{aligned}\right. \quad (6)$$

式中: TP 为被判为正类的正类; FP 为被判为正类的负类; FN 为被判为负类的正类。

平均精度 (AP) 表示 Precision-Recall 曲线下面的面积, 对数据集中每类目标的平均精度求均值即 mAP, 其计算公式如下:

$$\text{mAP} = \sum \text{AP} / N \quad (7)$$

式中: N 为不同类别目标的总和。

3.4 实验结果分析

本文通过设置不同的网络模型的对比实验来确定理想的改进方案, 然后用改进的网络模型与常见目标检测算法进行比较, 对改进后模型的检测性能进行分析。

3.4.1 不同主干特征提取对检测性能的影响 为了研究不同的 MobileNet 检测网络对模型检测性能的影响, 分别采用不同特征提取网络 MobileNetv1、MobileNetv2、MobileNetv3 与 YOLOv4 相结合, 同时修改 YOLOv4 中的 PANet 和 YOLO Head 中的 3×3 普通卷积为深度可分离卷积, 依次记对应为 MobileNetv1_YOLOv4、MobileNetv2_YOLOv4 与 MobileNetv3_YOLOv4 模型, 训练过程损失函数曲线见图 4。

使用训练好的模型对测试集进行预测, 实验结果见表 4, 通过实验可知 MobileNetv2_YOLOv4 模型 mAP 达到 87.3% 表现最佳, 其损失函数值下降速度最快, 收敛效果更好, 并且该模型的计算量最少, 相比 YOLOv4 降低了 83.2%。经过实验分析, 针对本文目标检测对象, 在使用 MobileNetv2 作为




图 4 损失函数对比曲线

主干特征提取网络, 能够更加有效的学习到目标的特征信息, 且网络训练的参数量更少。因此选用 MobileNetv2_YOLOv4 网络模型完成电力高空作业识别及安全带检测。

表 4 不同主干网络检测结果比较

网络模型	主干网络	mAP/%	网络参数
YOLOv4	CSPDarknet53	85.4	64,429,405
MobileNetv1_YOLOv4	MobileNetv1	85.6	12,692,029
MobileNetv2_YOLOv4	MobileNetv2	87.3	10,801,149
MobileNetv3_YOLOv4	MobileNetv3	86.9	11,729,069

3.4.2 空间金字塔池化对模型的影响 为了研究 SPP 结构对模型性能的影响, 在模型 MobileNetv2_YOLOv4 的基础上分别修改 SPP 结构实验结果见表 5。通过实验发现修改后的三种 SPP 结构均在不同程度上提升了模型的检测能力, 其中使用较小的 1×1 、 3×3 、 5×5 、 7×7 的池化核提升效果最显著, mAP 提升了 1.3%, 表明通过使用不同大小的池化结构能够在不同程度上除去经过深层和浅层特征融合后的冗余特征信息, 更加有效的增强图像特征学习范围, 帮助模型学习更多的信息, 相比于 SPP_C 结构中 9×9 的池化核, 较小的池化核在识别电力高空作业及安全带检测模型上效果更好。因此采用 MobileNetv2_YOLOv4(SPP_B) 作为该模型的检测网络, 并将该模型命名为 Improved_YOLOv4。

表 5 不同 SPP 结构检测结果比较

网络模型	mAP/%	FPS	模型大小/M
MobileNetv2_YOLOv4(SPP_A)	86.9	68	52.3
MobileNetv2_YOLOv4(SPP_B)	88.6	66	53.3
MobileNetv2_YOLOv4(SPP_C)	88.1	59	54.2

3.4.3 与其它目标检测算法的精度对比 在训练平台信息配置不变的条件下, 分别使用 Faster RCNN(VGG16)、SSD(ResNet50) 和 YOLOv4 深度学习模型在同一数据集上进行训练分析。各网络模型的检测精度 (AP)、mAP 值、FPS 值以及模型权重文件大小详细数据见表 6。

由表 6 可知, 改进后 YOLOv4 模型的平均检测精度为 88.6%, 每秒帧数为 66, 优于其它 3 种网络。

同时该模型的预训练权重大小仅为 53.8M,相比于传统的 YOLOv4 降低了 76%,模型更加轻量化,检测速度更快,更容易将网络模型部署到嵌入式设备

表 6 不同模型检测精度比较

算法	AP/%				mAP/%	FPS	模型大小/M
	person	gaders	offgroundperson	safebelperson			
Faster RCNN	85.3	80.2	80.8	79.6	81.5	25	110.9
SSD	82.5	77.4	78.6	76.8	78.8	33	86.7
YOLOv4	87.6	87.3	86.1	80.6	85.4	36	224
Improved_YOLOv4	89.8	89.6	88.6	86.4	88.6	66	53.8

3.4.4 模型检测结果 使用训练好的网络模型对测试集中的图片进行检测,挑选出检测结果中 3 张具有代表性的图片(图 5),其中图 a、c、e 为 YOLOv4 检测结果,图 b、d、f 为本文算法检测结果。由检测对比图可知,图 5a 中并未检测出监护袖章,并且检测精度不高,图 5b 使用改进后的算法明显的检测到了监护袖章,并且置信度较高;图 5c 中对较远拍摄到的目标出现漏检现象,检测效果较差,而图 5d 中则完全识别出了待检测目标。图 5e 中未检测到被遮挡的离地维修人员,同时对于佩戴的安全带全部未检测到,而图 5f 中则完全识别离地维修人员以及佩戴的安全带。从对比图片结果中可以看出,改进后的模型检测结果的置信度更高,对密集目标识别效果较好,并且能够克服 YOLOv4 模型中的漏检情况,检测效果更好。




图 5 YOLOv4 与 Improved_YOLOv4 检测结果

4 结论

本课题使用深度学习的方法,更加精准的识别

中,能够满足电力生产作业过程中对作业人员的实时监控。

高空作业人员安全带的佩戴情况,减少传统人工监督的一些客观因素导致的高空坠落事件的发生,同时也提高了现场安全作业的检测效率,为工业检修人员的智能化安全管理提供了新的解决办法,通过使用 MobileNetv2 网络替换 YOLOv4 中的 CSP-Darknet53 主干提取网络,可以大幅度降低网络模型的参数量,使网络模型轻量化,提高检测速度;通过 K-means 聚类算法重新获取先验框,并适配性的调整空间金字塔结构,可以提高模型的检测精度;通过使用 Soft-NMS 算法能够有效降低待检测目标的漏检率。实验结果表明 Improved_YOLOv4 比原 YOLOv4 网络 mAP 提高 3.2%,检测速度提高 30fps,模型的训练权重压缩 4.16 倍,检测效果优于其它常见的目标检测网络。接下来的工作要继续拓展数据集集中的检测种类和数量,进一步提高模型的泛化能力。

[参 考 文 献]

[1] REDMON J, DIVVALA S, GIRSHICK R, et al. You Only look once: unified, real time object detection[C] // Computer Vision and Pattern Recognition, 2017, 6517-6525.

[2] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017, 6517-6525.

[3] REDMON J, FARHADI A. Yolov3: An incremental improvement[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2018, 1804.0276.

[4] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[C] // IEEE Conference on Computer Vision and Pattern Recognition. 2020. arXiv: 2004.10934v1 [cs. CV].

[5] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C] // Proceedings of the European Conference on Computer Vision (ECCV), 2016, 21-37.

[6] GIRSHICK R, DONAHUE J, DARRELL T, et al.

Rich feature hierarchies for accurate object detection and semantic segmentation[C]// IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2014: 580-587.

[7] GIRSHICK R. Fast R-CNN[C]// Proceedings of the IEEE International Conference on Computer Vision, 2015, 1440-1448.

[8] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]// Proceedings of the 2015 advances in Neural Information Processing Systems, 2015, 91-99.

[9] He K M, Gkioxari G, Dollar P, et al. Mask R-CNN [C]// Proceedings of the IEEE international conference on computer vision, Venice: IEEE Press, 2017, 2961-2969.

[10] 许凯, 邓超. 基于改进 YOLOv3 的安全帽佩戴识别算法[J]. 激光与光电子学进展, 2021, 58(6): 300-307.

[11] 冯文文, 曹银杰, 李晓琳, 等. 基于改进的深度卷积神经网络的人脸疲劳检测[J]. 科学技术与工程, 2020, 20(14): 5680-5687.

[12] 霍星, 费志伟, 赵峰, 等. 深度学习在驾驶员安全带检测中的应用[J]. 计算机科学, 2019, 46(S1): 182-187.

[13] 谢晓方, 刘厚君, 张龙杰, 等. 融合轻量级 YOLOv4 与 KCF 算法的红外舰船目标识别[J]. 兵器装备工程学报, 2021, 42(6): 175-182.

[14] HE K M, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(9): 1904-1916.

[15] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2018, 8759-8768.

[16] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [J/OL]. [2021-11-30]. arXiv preprint arXiv:1704.04861, 2017.

[17] 张陶宁, 陈恩庆, 肖文福. 一种改进 MobileNet_YOLOv3 网络的快速目标检测方法[J]. 小型微型计算机系统, 2021, 42(5): 1008-1014.

[18] 李彬, 汪诚, 吴静, 等. 改进 YOLOv4 算法的航空发动机部件表面缺陷检测[J]. 激光与光电子学进展, 2021, 58(14): 414-423.

[19] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS-improving object detection with one line of code [C]//2017 IEEE International Conference on Computer Vision (ICCV), August 8, 2017, 5562-5570.

Safety Belt Detection Algorithm for Electric Aerial Work Based on Improved YOLOv4

DUN Weichao, WANG Shuqing, ZHANG Pengfei, WANG Juan

(School of Electrical and Electronic Engin., Hubei Univ. of Tech., Wuhan 430068, China)

Abstract: Power aerial work accidents occur frequently. In order to allow electric power workers to take standardized protective measures during electric power operations, this paper proposes a recognition algorithm for power high-altitude operation and safety belt wearing based on improved YOLOv4. Firstly, this algorithm uses MobileNetv2 as the backbone extraction network, which reduces the amount of network parameters and improves the recognition speed of the model while ensuring a good feature extraction effect. Then we use the K-means clustering algorithm to re-cluster the target borders in the data set, and adjust the spatial pyramid pooling structure to improve the detection accuracy of the model. Finally, the Soft NMS algorithm is used to replace the original NMS algorithm to reduce the missed detection rate of the target. The experimental results show that the mean Average Precision of the improved YOLOv4 network model is 3.2% higher than the original YOLOv4 model, the detection speed is increased by 30 frames per second (fps), and the training weight of the model is reduced by 4.16 times. In conclusion, the proposed algorithm has strong practicability and high efficiency in safety belt detection of electric aerial work.

Keywords: safety belt; deep learning; YOLOv4; MobileNet; convolutional neural network

[责任编辑: 张岩芳]