

曹捷,郭志彬,潘立志,等. 高空作业场景下的安全带穿戴检测[J]. 湖南科技大学学报(自然科学版), 2022, 37(1):92-99. doi:10.13582/j.cnki.1672-9102.2022.01.013

CAO J, GUO Z B, PAN L Z, et al. Detection of Safety Belt Wearing in Aerial Work [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2022, 37(1):92-99. doi:10.13582/j.cnki.1672-9102.2022.01.013

# 高空作业场景下的安全带穿戴检测

曹捷<sup>1</sup>, 郭志彬<sup>1</sup>, 潘立志<sup>1</sup>, 丁兴号<sup>2\*</sup>

(1. 国网福建省电力有限公司建设分公司, 福建 福州 350012; 2. 厦门大学 信息学院, 福建 厦门 361005)

**摘要:**为降低意外事故发生的风险,高空电力作业的安全防护十分重要.针对现有安全带穿戴检测方法时效性差且缺乏场景针对性的问题,提出了一种高空作业场景下的安全带穿戴检测方法.首先,引入最新的YOLOX目标检测模型,使得模型能够实时检测目标的同时具有较高的检测精度;其次,利用Mosaic和MixUp这2种特殊的数据增扩方式以丰富数据集中的场景和目标的变化性,并结合实例归一化策略以进一步提高模型应对复杂作业环境的鲁棒性.公开数据集上的实验结果表明:所提方法在测试集上的平均识别准确率均值达到95.78%,每张图像的平均推断时间为3.31 ms,具有识别速度快、精度高的特点,能够满足高空电力作业场景的实际应用需求.

**关键词:**高空作业;安全带;YOLOX算法;目标检测

中图分类号:TP181 文献标志码:A 文章编号:1672-9102(2022)01-0092-08

## Detection of Safety Belt Wearing in Aerial Work

CAO Jie<sup>1</sup>, GUO Zhibin<sup>1</sup>, PAN Lizhi<sup>1</sup>, DING Xinghao<sup>2</sup>

(1. State Grid Fujian Construction Company, Fuzhou 350012, China;

2. School of Informatics, Xiamen University, Xiamen 361005, China)

**Abstract:** In order to reduce the risk of accidents, the safety protection of aerial work is very important. Aiming at the existing safety belt wearing detection method with poor timeliness and lack of scene specificity, a safety belt wearing detection method for aerial work is proposed. Firstly, the state-of-the-art object detection method YOLOX is introduced to enable the model to work in real-time and have high accuracy. Secondly, two special augmentation methods, namely Mosaic and MixUp, are used to enrich the variability of scenes and targets in the dataset, and an instance normalization strategy is combined to further improve the robustness of the model in dealing with the complex operating environments. The experimental results on the public dataset show that the Mean Average Precision of the proposed method on the test set is 95.78% with an average inference time for each image is 3.31 ms, which has the characteristics of fast recognition and high accuracy, and can meet the practical application requirements of aerial work.

**Keywords:** aerial work; safety belt; YOLOX algorithm; object detection

电力作业通常都位于高空,作业条件和环境相较于地面作业更为复杂,资料显示,高空坠落是电力行业中各类安全事故中最为高发的事故<sup>[1]</sup>.高处作业环境复杂多样,作业人员在操作过程中需要频繁地移

收稿日期:2021-11-29

基金项目:国网福建省电力有限公司科技专项资金(52130T0000A)

\*通信作者, E-mail: dxh@xmu.edu.cn

动,在这种情况下,正确佩戴安全带对作业人员的生命安全保障起到至关重要的作用.电力作业人员所穿戴的安全带通常都配备有双重保险挂环<sup>[2]</sup>,高空作业时,应将 2 个挂环都挂到作业人员腰部以上的位置,这有助于减少意外坠落时的冲击距离,这是正确的安全带系挂方法.尽管目前已经具备设计良好的高空作业防护设备,但事故依旧频发,究其原因,一方面是仅靠作业人员的自觉意识很难保证安全带发挥其真正的保护作用.例如,部分作业人员因佩戴不规范或挂钩位置调整不及时而导致出现二保未挂、低挂高用等诸多错误佩戴操作,在意外发生时没能有效发挥安全带的缓冲作用,造成无法挽回的人身伤害.另一方面,实际作业过程因人力、设备条件有限,缺乏有效的监督方式,无法对作业人员施工过程中的操作不当进行及时提醒.

近年来,利用计算机视觉智能分析的高清视频监控技术已成为主流发展趋势<sup>[3-4]</sup>,并广泛应用于各种施工场景下的任务,如安全帽检测<sup>[5]</sup>、人脸检测<sup>[6]</sup>、行为识别<sup>[7]</sup>等.这类检测任务的基础环节都是目标检测.现有的目标检测算法可分为 2 类:一类是双阶段目标检测算法,代表性的工作为 R-CNN<sup>[8]</sup>、Fast R-CNN<sup>[9]</sup>以及 Faster R-CNN<sup>[10]</sup>.这类目标检测算法的主要特点是首先利用区域选择算法产生一系列候选框,作为目标检测的备选边界,利用卷积提取特征后,对感兴趣区域的目标进行分类以及边框的精细化调整;另一类是抛弃复杂的候选框建议算法,选用较为简单的候选框策略或者只针对几种尺度下的候选框直接进行回归的单阶段目标检测算法,代表工作为 YOLOv2<sup>[11]</sup>、YOLOv3<sup>[12]</sup>、SSD<sup>[13]</sup>、RetinaNet<sup>[14]</sup>等.这类方法的主要思想是首先将特征图均匀分成单元格,每个单元格负责检测目标中心点落在单元格内的位置、目标的边界框以及目标类别.

目前针对驾驶员安全带的检测方法已有许多,吴烈凡等<sup>[15]</sup>提出一种基于卷积神经网络的高空作业安全带识别和检测方法,但其是面向普通施工作业场景,在电力作业场景下使用具有一定的局限性;冯志珍等<sup>[16]</sup>提出一种基于 Mask R-CNN 的高空作业安全带检测方法,将安全带检测和人体关键点信息结合,判断作业人员的违规情况,但该方法的检测框架是基于双阶段的方法,其时效性难以满足实际应用需求.电力作业场景的特殊性一方面在于电力作业场景的复杂性,室外场景光照变化大,需要方法对不同环境具有良好的适应能力.另一方面,电力高空作业的场景与工地场景不同,安装常规的监控设备成本高且难维护,通常需要借助无人机设备搭载高清摄像头进行监控管理.

综上所述,虽然安全带检测已得到一定程度的研究,但是面向电力高空作业的安全带检测还有待进一步研究,主要表现在:(1)泛化推广能力不够,特别是面向复杂电力作业场景时的鲁棒性不足;(2)时效性差,难以满足边缘端设备使用和电力作业需要实时告警的需求.针对上述问题,提出一种高空作业场景下的安全带穿戴检测算法,该方法首先将最新的 YOLOX 模型引入到作业人员及安全带检测识别领域,在保证实时检测的前提下获得满足实际应用的检测精度.为了提高 YOLOX 模型应对复杂高空电力作业场景的能力,通过 Mosaic 和 MixUp 这 2 种特殊的增扩方式,以丰富高空电力作业场景的变化性,并结合实例归一化策略以进一步提高 YOLOX 模型在电力作业场景应用中的鲁棒性,为应用于不同电力作业环境下的安全带穿戴检测提供可行方法.

## 1 算法理论基础

YOLO 系列作为经典的单阶段目标检测方法,始终追求实时应用场景下的最佳速度和精度平衡.双阶段的目标检测方法精度更高,但实时性差,单阶段的方法速度更快、算法流程更简单,所以在工业场景下通常采用后者.自 2016 年 Redmon 等第一次提出 YOLO(You Only Look Once)算法开始<sup>[17]</sup>,近年来通过结合不同类型目标检测方法的各种优势策略方法得到了不断发展和演变.YOLOX 算法在 YOLOv3 的基础上,主要从解耦检测头 Decouple Head、无锚框结构 Anchor Free、标签分配等多个方面深入优化,使得算法模型在检测速度和精度上都能达到当前效果最优.另一方面,YOLOX 的轻量化设计有利于方法在无人机边缘端的部署,在应用场景受限的高空电力作业环境具有十分广阔的应用前景.

### 1.1 YOLOX 算法

YOLOX<sup>[18]</sup>算法的结构,主要包括特征提取网络 CSPDarknet53<sup>[12]</sup>、特征金字塔与路径聚合网络 (Feature Pyramid Networks + Path Aggregation Networks, FPN+PAN)和特征解耦头 Decouple Head 这 3 个部

分,如图 1 所示.CSPDarknet 是 YOLOX 算法的主干特征提取网络,主要包含 Fcous、CSPNet 和空间金字塔池化网络(Spatial Pyramid Pooling, SPP)3 个模块.对于一张输入图像,模型首先将输入图像进行切片操作.通过对完整图像进行等间隔采样,可以得到多张合适尺寸的下采样图像,再把这些图像在通道维度上组合起来,就将图像中的信息转移到了通道空间上,得到没有信息丢失的下采样图像.CSPNet 模块中包含主干特征提取和残差结构,能够更好地提取图像特征,降低计算量的同时保证精度.SPP 网络将最后一个 CSPNet 的输出进行一次卷积后利用 3 种不同尺度的最大池化核来融合特征图像在不同感受野下的特征,便于后续的特征聚合网络 FPN+PAN 所进行的上、下采样特征提取.FPN+PAN 是由卷积、上/下采样和特征融合操作构成的循环金字塔结构,对输入的图像特征进行反复提取,在不同尺度上分别进行特征融合,最后输出 3 个不同尺度的特征图送入 Decouple Head 进行预测.

在目标检测任务中,分类和回归任务间的冲突关系是众所周知的.Decouple Head 的方法广泛应用于各种目标检测中,以往的 YOLO 模型将分类结果、回归结果和回归置信度三者融合在一个检测头中完成,虽然这种做法更加便捷,但不利于模型的收敛,因此在 YOLOX 中采用了解耦头结构.结合 FPN 不同尺度的输出,Decouple Head 将每个尺度上的特征进行进一步的特征提取得到当前尺度下的预测结果,再经过非极大值(Non-Maximum Suppression, NMS)抑制筛选后将结果合并,得到最终预测结果.

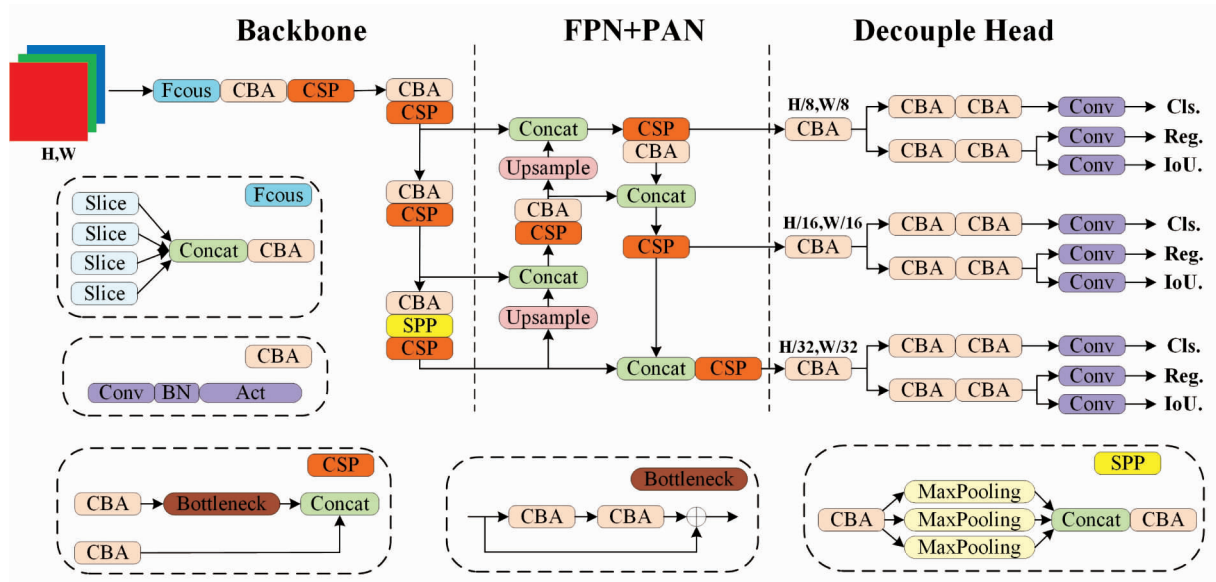


图 1 YOLOX 算法网络结构

### 1.2 无锚框与样本匹配

近年来,无锚框(Anchor Free)的目标检测方法发展得十分迅速<sup>[19-21]</sup>,这些工作都表明无锚框的检测效果都能与基于锚框的方法相媲美.无锚框的检测结构显著减少了许多需要依赖启发式调整和诸多技巧的超参数的数量,如 anchor 的数量、长宽比等.无锚框的方法在每个位置只预测一个 4 维的特征向量,即该处目标的左上角坐标以及目标的宽和高.电力作业检测场景的应用所具备的计算和存储资源往往有限,无锚框的设计可以更好地适应场景的需求.

样本匹配策略是目标检测的一个重要的处理方法<sup>[22]</sup>,好的样本匹配算法可以天然缓解拥挤场景的检测问题,如 LLA<sup>[23]</sup>,OTA<sup>[24]</sup>里使用动态样本匹配可以在 Crowd Human 数据集上提升 FCOS<sup>[19]</sup>将近 10%,这些策略能够缓解极端长宽比的物体检测效果差的问题以及目标正负样本不均衡的问题.基于 YOLOX 提出了标签分配策略 SimOTA,本文所使用的样本分配策略的具体流程如下:

1) 使用中心先验确定正样本的候选区域.

2) 计算候选区域内每个样本与每个真实值(Ground Truth, GT)的交并比(Intersection over Union, IoU)<sup>[25]</sup>,即所预测出的样本框与真实框的交集和并集的比值,具体计算公式为

$$IoU = \frac{A \cap B}{A \cup B} \tag{1}$$

式中:  $A$  为预测框;  $B$  为真实框.在判断是否检测到目标时,模型首先设定一个 IoU 阈值,如果所预测的样本框与检测目标的 IoU 大于该阈值则认为该样本框检测到目标,小于阈值则认为未检测到目标.考虑到电力作业场景的复杂以及作业人员在操作时容易出现被遮挡问题,在 IoU 的基础上还加入距离的约束,即在选择过程中加入对目标框和真实框之间的距离考虑.最终的距离公式为

$$S = \text{IoU} + \lambda L_1(A, B). \quad (2)$$

式中:  $L_1(A, B)$  为框中心位置的  $L_1$  距离;  $\lambda$  为一个范围调整系数.

3) 利用所选的候选框,计算代价函数,公式如式(3)所示.

$$\text{Cost}_i = L_i^{\text{cls}} + \alpha L_i^{\text{reg}}. \quad (3)$$

式中:  $\alpha$  为一个平衡系数;  $L_i^{\text{cls}}$  和  $L_i^{\text{reg}}$  为样本  $i$  的预测结果和真实值之间的分类损失和回归损失.

采用交叉熵(Cross-Entropy Loss)作为分类损失,公式如式(4)所示.

$$L_i^{\text{cls}} = \sum_{j=1}^M G_{ij} \log(P_{ij}). \quad (4)$$

式中:  $M$  为类别的数量;  $G_{ij}$  为符号函数,只有当样本  $i$  的真实标签为类别  $j$  时  $G_{ij} = 1$ , 其余情况  $G_{ij} = 0$ ;  $P_{ij}$  为当前样本  $i$  预测为类别  $j$  的概率.

每个候选框的预测结果为一个 4 维的向量  $t_c = [x, y, w, h]$ , 表示当前预测框的中心位置坐标和框的尺寸.回归损失采用 SmoothL1 Loss<sup>[14]</sup>, 公式如式(5)所示.

$$L_i^{\text{reg}} = \sum_{c \in \{x, y, w, h\}} \text{Smooth}_{L_1}(t_c - v_c); \quad (5)$$

$$\text{Smooth}_{L_1}(x) = \begin{cases} 0.5x^2, & \text{if } |x| < 1; \\ |x| - 0.5, & \text{otherwise.} \end{cases} \quad (6)$$

式中:  $v_c$  为真实框的位置.

4) 最后,对于每个 GT,依据候选框的数量在候选区域内选择代价最小的  $k$  个样本作为正样本,其余作为负样本,  $k$  值会随着不同的 GT 变化.预先设定了最小正样本数量阈值为 10,然后依据每个候选框的代价进行排序,根据阈值选择代价最小的一部分候选框作为正样本.

### 1.3 数据增强

电力高空作业场景下的检测任务,首先要面临的的就是复杂环境条件,除去雨、雾等自然条件的干扰,检测任务还受到物体遮挡、线路复杂、视角限制等多种因素的干扰.数据增扩是深度学习中十分重要的一环,好的增扩方式不仅可以提升模型的检测精度,还可以提升模型的泛化性能和鲁棒性<sup>[26]</sup>.因此,选择合适的增扩方法对原始数据集进行扩充,有助于提高模型对于复杂的高空电力作业环境的适应能力,同时也有利于避免模型的过拟合.

为此,除了采用传统的翻转、噪声和尺度变换几种基本数据增扩方式,对于原数据还加入了 Mosaic 和 MixUp 这 2 种增扩策略,如图 2 所示.这 2 种方法的基本思路都是对多张数据进行不同方式的融合,从而增加一张图片中的目标数量和数据的复杂程度.Mosaic 是对多张不同的图片进行翻转、缩放、色彩改变等一系列操作后再裁剪拼接重新组合出一张新的图片,新的图片中往往会包含更多的目标,这种增扩方式混合极大地丰富了作业人员的背景,同时在一定程度上缓解检测过程中的正负样本不均衡的问题.MixUp 是将 2 张图片按照一定比例进行融合,同时样本的标签也对应加权求和,预测结果与加权之后的标签求损失,再反向传播更新参数.

### 1.4 实例归一化

实例归一化最早应用在图像的风格迁移中,相比于批归一化的方法,实例归一化更加关注每个样本的分布<sup>[27]</sup>.由于电力作业环境通常在室外,场景中的光照强度变化很大,不同角度拍摄的数据存在差异,强行使用批归一化之后,不同数据的分布被打乱,最终训练样本偏差较大,导致识别性能降低.

因此,本文对 YOLOX 模型进行了改进,通过引入实例归一化的方式,降低模型对电力高空作业场景光照、色彩等环境变化的敏感度,进一步提升检测模型的泛化能力.



图2 数据增扩

## 2 实验过程及分析

### 2.1 实验数据集

实验数据集采用阿里云天池官网公布的广东电网智慧现场作业挑战赛赛道三的数据集<sup>[28]</sup>,包含训练集 2 548 张,按照 9 : 1 的比例划分训练集和验证集,包含不同光照强度、不同视角、不同场景的低挂高用违规数据和高挂低用正确数据图片.数据集中标签信息如表 1 所示.

表 1 数据集介绍

类别名称	代表含义	目标数量
Badge	监督员袖章	673
Offground	高空作业人员	2 478
Ground	地面人员	2 223
Safebelt	作业安全带	1 725

### 2.2 实验平台及模型参数

实验使用的实验设备为 64 位的 Linux 系统计算机,CPU 选用 Intel(R) Xeon(R) Gold 6240,GPU 选用 GeForce RTX 3090 (24 GB),CUDA 版本为 11.1,所有模型均使用深度学习框架 PyTorch 搭建运行.

实验使用在 COCO 数据集上的预训练模型对本文模型进行初始化.模型训练参数:Batchsize 设置为 8,Epoch 设置为 60,使用随机梯度下降 SGD 优化算法,初始学习率为  $1e-3$ ,衰减率 decay 设置为  $5e-4$ ,动量设置为 0.9,采用 FP16 混合精度训练.

### 2.3 评价指标

选用平均精度(Average Precision, AP)和平均精度均值(mean Average Precision, mAP)作为模型性能的评价指标<sup>[29]</sup>.精度和召回率是 2 个相互影响的指标,公式为

$$\text{Precision} = \frac{TP}{TP+FP}; \quad (7)$$

$$\text{Recall} = \frac{TP}{TP+FN}. \quad (8)$$

式中:TP (True Positive) 为预测正确的正样本;FP (False Positive) 为预测错误的负样本;FN (False Negative) 为预测错误的正样本.

提高置信度阈值可以提高模型的精确度,但是会导致模型的召回率降低,因此使用 AP 指标可以更为合理地评估模型性能,即计算 Precision-Recall 曲线与坐标轴围成的面积,公式如式(9)所示.

$$AP = \int P dR. \tag{9}$$

式中: $P$  为不同召回率  $R$  条件下的精度.mAP 即取所有类别的 AP 值的平均值.

### 2.4 实验结果及对比分析

以深度学习中的目标检测技术为基础,通过构建基于 YOLOX 的电力高空作业安全带检测模型,对高空作业人员及安全带进行有效检测识别.评估模型时,IoU 的阈值设定为 0.5,即大于 0.5 的样本被认定是正确的预测.

本文方法与其他方法的性能比较如表 2 所示.相比于其他类别,袖章和安全带的检测平均准确率稍低,主要原因在于数据集中袖章和安全带的尺寸相对于人的目标较小.与其他方法相比,本文方法在每个类别上都有不错的性能提升,这充分证明了本文方法的有效性.

表 2 不同方法性能的比较

方法	AP/%			
	Badge	Offground	Ground	Safebelt
FasterRCNN <sup>[9]</sup>	82.2	94.2	89.6	88.4
SSD <sup>[13]</sup>	89.2	94.4	90.5	82.9
RetinaNet <sup>[14]</sup>	63.8	92.3	86.3	73.1
本文方法	93.3	99.1	97.4	93.3

为验证 Mosaic 和 MixUp 这 2 种数据增扩对模型性能的效果提升,进行了关于数据增扩方式的消融实验.为研究在不同增扩方式下对模型训练过程中不同类别的 AP 变化的影响,总共设计了 4 组实验:(1)仅包含翻转、噪声、图像调整的基本增扩方式;(2)基本数据增扩的基础上加入 MixUp;(3)基本数据增扩的基础上加入 Mosaic;(4)基本数据增扩的基础上加入 MixUp 和 Mosaic.每组实验的参数设置相同,每个类别的 AP 随着训练过程的变化如图 3 所示.

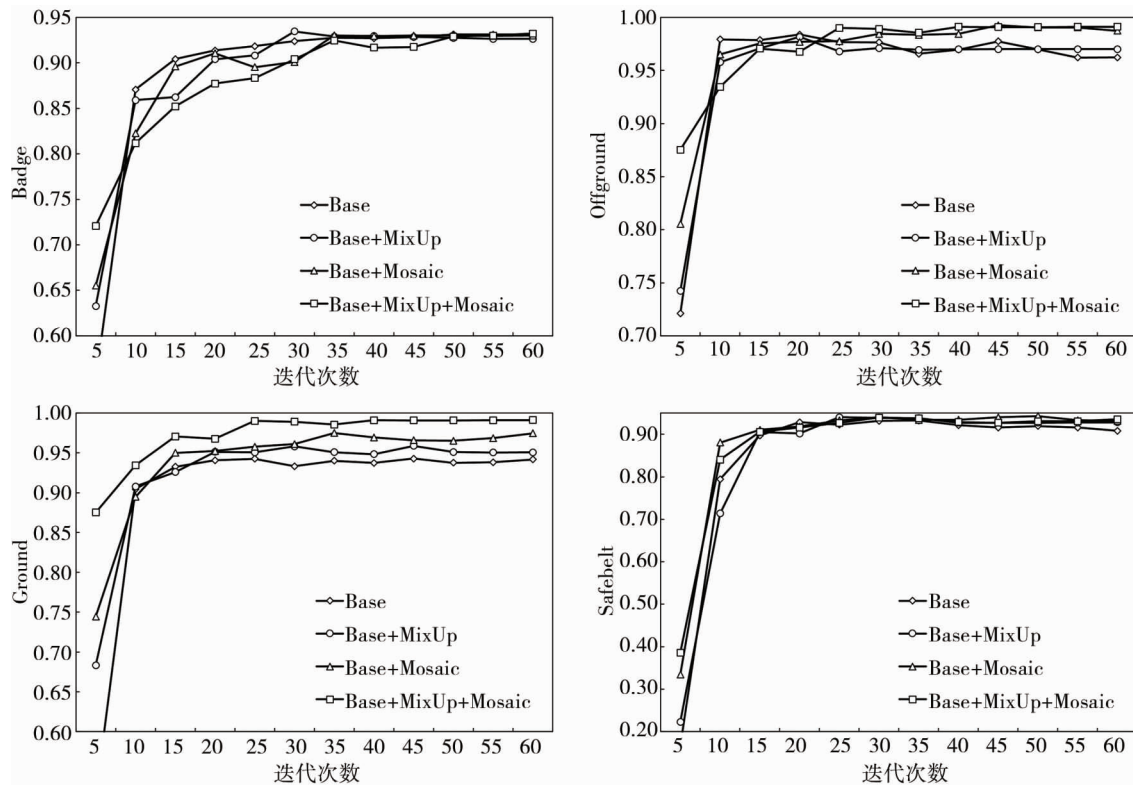


图 3 数据增扩对不同类别 AP 变化的影响

从实验结果可以看出:加入 2 种增扩方式后的模型在第一次迭代后的效果都会比基本增扩方式高,说明 2 种增扩方式都有利于模型对目标的学习.MixUp 的引入对训练过程 AP 的变化影响相比于 Mosaic 的引入要小,说明 Mosaic 这种形式的数据增扩容易使模型训练稳定性降低,这是因为 Mosaic 将不同图片拼

接后对特征提取过程产生了一定的影响,加上每一层感受野的限制,就导致最终判断结果出现了偏差.单独使用 MixUp 和 Mosaic 时,后者通常都会表现出更强的不稳定性,这与拼接后的图像特征分布变化过大有关.同时使用 2 种增扩时,训练过程会比单独使用增扩稳定,这说明 MixUp 的加入有助于缓解 Mosaic 带来的不稳定性.

本文还给出了不同增扩策略下最终各类别的准确率, Base 表示只含有基本增扩方式(翻转、噪声、图像调整),如表 3 所示.从结果来看,所加入的 2 种数据增扩方式都能较为明显的提高检测性能,除了监督员袖章,其他类别都能得到较为明显提升.包含所有增扩后,模型能更好地兼顾到所有类别的训练并且融合不同增扩方式的优点,使模型表现出更好的性能.

表 3 不同增扩策略对比

方法	AP / %				mAP
	Badge	Offground	Ground	Safebelt	
Base	93.1	96.5	94.2	90.9	93.68
Base+MixUp	92.8	97.0	95.1	92.8	94.43
Base+Mosaic	93.0	98.7	97.3	93.2	95.55
Base+MixUp+Mosaic	93.3	99.1	97.4	93.3	95.78

对检测后的图像进行可视化分析,能够更加直观地看到 YOLOX 模型针对本文检测场景的效果,部分本方法在测试集上的效果如图 4 所示.从图 4 可以看到:即使存在遮挡的情况,模型依旧可以有效检测到安全带和作业人员,表明本方法在复杂情况下也有很好地性能表现,可以良好地适应高空电力作业环境.值得一提的是,本方法在可视化测试时,每张测试图像经过平均前向传播时间为 2.7 ms,非极大值抑制处理时间为 0.61 ms,总的推断时间为 3.31 ms,证明本方法可以满足电力高空作业场景下实时应用的需求.



图 4 可视化结果

### 3 结论

1) 提出了一种高空作业场景下的安全带检测方法,可以准确地检测出高空电力作业场景下的作业人员和安全带的位置,为高空电力作业场景的检测任务提供了一种有效可行的方案,比前人方法更具适用性.但由于现实工作场景中复杂的自然条件和人为因素的干扰,本方法是否具备足够的鲁棒性,是否满足实际工程的要求,还有待实践检验.

2) 未来的工作一方面将在识别问题上开展,通过引入图像分割的方法对违规行为做出判断;另一方面将对数据集做进一步的扩充,为计算机视觉研究在电力作业方面奠定基础.

## 参考文献:

- [1] 杨美军. 基于电力高处作业防坠安全装置的应用研究 [J]. 江西电力, 2020, 44(2): 40-42.
- [2] 高明, 左红群, 柏帆, 等. 融合视觉关系检测的电力场景自动危险预警 [J]. 中国图象图形学报, 2021, 26(7): 1583-1593.
- [3] 周伟浩. 基于计算机视觉变电站绝缘子闪络监测系统的设计与实现 [D]. 成都: 西南交通大学, 2020.
- [4] 李先锋, 徐森, 花义明. 基于 OpenCV 计算机视觉的海事视频船舶火灾烟雾检测技术 [J]. 舰船科学技术, 2021, 43(22): 202-204.
- [5] 韩锬, 李斯宇, 肖友刚. 施工场景下基于 YOLOv3 的安全帽佩戴状态检测 [J]. 铁道科学与工程学报, 2021, 18(1): 268-276.
- [6] 赵洋, 许军. 基于 MobileNetV2 与树莓派的人脸识别系统 [J]. 计算机系统应用, 2021, 30(8): 67-72.
- [7] 姚宗强, 陈宏利, 闫文虎, 等. 基于视频图像的电力基建施工违章行为自动识别系统设计 [J]. 自动化与仪器仪表, 2021(3): 143-145.
- [8] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//Proceedings of the IEEE conference on computer vision and pattern recognition, 2014: 580-587.
- [9] Girshick R. Fast r-cnn [C]//Proceedings of the IEEE international conference on computer vision, 2015: 1440-1448.
- [10] Ren S, He K, Girshick R, et al. Faster r-cnn: Towards real-time object detection with region proposal networks [J]. Advances in neural information processing systems, 2015, 28: 91-99.
- [11] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C]//Proceedings of the IEEE conference on computer vision and pattern recognition, 2017: 7263-7271.
- [12] Redmon J, Farhadi A. Yolov3: An incremental improvement [J]. arXiv e-prints, 2018: 1804.02767.
- [13] Liu W, Anguelov D, Erhan D, et al. Ssd: Single shot multibox detector [C]//European conference on computer vision. Springer, Cham, 2016: 21-37.
- [14] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection [C]//Proceedings of the IEEE international conference on computer vision, 2017: 2980-2988.
- [15] 吴烈凡. 基于卷积神经网络的高空作业安全带识别与检测 [J]. 现代计算机, 2021, 27(24): 124-130.
- [16] 冯志珍, 张卫山, 郑宗超. 基于 Mask R-CNN 的高空作业安全带检测 [J]. 计算机系统应用, 2021, 30(3): 202-207.
- [17] 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, 2016: 779-788.
- [18] Ge Z, Liu S, Wang F, et al. Yolox: Exceeding yolo series in 2021 [J]. arXiv preprint, 2021: 2107.08430.
- [19] Tian Z, Shen C, Chen H, et al. Fcos: Fully convolutional one-stage object detection [C]//Proceedings of the IEEE/CVF international conference on computer vision, 2019: 9627-9636.
- [20] Law H, Deng J. Cornernet: Detecting objects as paired keypoints [C]//Proceedings of the European conference on computer vision (ECCV), 2018: 734-750.
- [21] Duan K, Bai S, Xie L, et al. Centernet: Keypoint triplets for object detection [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6569-6578.
- [22] Zhang S, Chi C, Yao Y, et al. Bridging the gap between anchor-based and anchor-free detection via adaptive training sample selection [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2020: 9759-9768.
- [23] Ge Z, Wang J, Huang X, et al. Lla: Loss-aware label assignment for dense pedestrian detection [J]. Neurocomputing, 2021, 462: 272-281.
- [24] Ge Z, Liu S, Li Z, et al. OTA: Optimal Transport Assignment for Object Detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 303-312.
- [25] Yu J, Jiang Y, Wang Z, et al. Unitbox: An advanced object detection network [C]//Proceedings of the 24th ACM international conference on Multimedia, 2016: 516-520.
- [26] Shorten C, Khoshgoftaar T M. A survey on image data augmentation for deep learning [J]. Journal of Big Data, 2019, 6(1): 1-48.
- [27] 蔡兴泉, 魏岳超, 孙海燕. 基于风格解耦和自适应层实例归一化的图像翻译方法 [J]. 科学技术与工程, 2021, 21(17): 7249-7257.
- [28] 天池平台, 广东电力信息科技有限公司. 广东电网智慧现场作业挑战赛 赛道三: 识别高空作业及安全带佩戴数据集 [DB/OL]. <https://tianchi.aliyun.com/specials/promotion/gzgrid>, 2021.
- [29] Everingham M, Eslami S M A, Van Gool L, et al. The pascal visual object classes challenge: A retrospective [J]. International Journal of Computer Vision, 2015, 111(1): 98-136.