

DOI:10.19651/j.cnki.emt.2209007

结合 YOLOv5 和质心匹配的轨迹追踪方法^{*}

许 明 宋远伟 赵 华

(南京师范大学计算机与电子信息学院/人工智能学院 南京 210023)

摘要: 针对施工场所中目标遮挡引起的安全帽佩戴者的轨迹追踪困难的问题,本文提出了一种结合 YOLOv5 和质心匹配算法的安全帽佩戴检测及轨迹追踪方法。该方法首先采用 YOLOv5 网络准确检测未佩戴安全帽的人员,计算其质心坐标;进一步的采用扩展卡尔曼滤波器预测目标位置信息;最后采用基于马氏距离及直方图相关性的质心匹配关联算法,结合预测信息实现了目标遮挡环境中的目标轨迹异常修正,可获得准确的目标轨迹。实验结果表明,本方法有效解决了目标跟踪中由目标遮挡引起的目标互换和丢失等问题,在自建数据集中获得了高于传统算法 10% 以上的目标跟踪准确度,为智慧工地的发展提供了有力的技术支持。

关键词: YOLOv5; 安全帽佩戴检测; 目标检测; 轨迹追踪; 遮挡; 匹配关联

中图分类号: TP183; TP391.4 文献标识码: A 国家标准学科分类代码: 520.6040

Trajectory tracking method combining YOLOv5 and centroid matching

Xu Yue Song Yuanwei Zhao Hua

(School of Computer and Electronic Information/School of Artificial Intelligence, Nanjing Normal University, Nanjing 210023, China)

Abstract: Aiming at the difficulty of trajectory tracking of helmet wearers caused by target occlusion in construction sites, a helmet wearing detection and trajectory tracking method combining YOLOv5 and centroid matching algorithm is proposed in this paper. Firstly, YOLOv5 network is used to precisely detect the personnel who do not wear safety helmets and calculate their centroid coordinates. Further, the extended Kalman filter is used to predict the target position information. Finally, the centroid matching association algorithm based on Mahalanobis distance and histogram correlation is adopted. Combined with the prediction information, the target trajectory anomaly correction in the target occlusion environment is realized, and the accurate target trajectory can be obtained. The experimental results show that the proposed method effectively solves the problems of target exchange and loss caused by target occlusion in target tracking, and obtains more than 10% target tracking accuracy higher than the traditional algorithm in the self-built data set, it provides strong technical support for the development of smart construction sites.

Keywords: YOLOv5; safety helmet wearing detection; object detection; trajectory tracking; target occlusion; match association

0 引言

安全帽是行业安全生产和交通安全中的必不可少的一种安全用具。无论是生产工人,还是摩托车、电动车的骑行者,安全帽都能在撞击瞬间有效地保护身体头部。安全帽作为有效的头部防护工具目前已被广泛使用于各类施工现场,但由于施工现场安全管理疏忽、施工人员安全防护意识薄弱等原因,一些因未佩戴安全帽而引发的伤亡事故也频繁发生^[1-2]。随着工业化的不断发展和人们安全意识的不断提高,安全帽佩戴检测成为安全生产中的重要问题。实

现施工现场安全帽佩戴识别,能对未佩戴安全帽人员的行动轨迹及时追踪,并根据检测追踪情况实时发出预警,同时对于追踪到的轨迹频繁发生的路段及区域进行统计分析等举措,将大大降低甚至避免作业人员的违规行为,保障作业人员的人身安全,降低安全事故发生概率,对于施工现场的安全防护管理以及智能信息化管理具有重要意义。

对于未佩戴安全帽人员的轨迹追踪和预警,首先需要解决未佩戴安全帽人员的目标检测^[3]。相较于效率低下的依靠人工目测监察来检测工人安全帽佩戴的方法,国内外一些研究人员将计算机视觉领域的目标检测技术应用到安

收稿日期:2022-02-14

*基金项目:江苏省自然科学基金(BK20201370)项目资助

全帽佩戴检测系统中。传统目标检测算法主要包括预处理、窗口滑动、特征提取选择分类和后处理等步骤^[4],整个检测过程效率与精度都较低。

基于卷积神经网络的深度学习算法在目标检测、识别等方面展示出远优于传统方法的性能^[5]。目前基于深度学习的目标检测算法,主要分为单阶段(one-stage)和两阶段(two-stage)两类算法。两阶段算法需要进行候选区域生成的操作,准确率较高,但存在速度瓶颈。而单阶段算法省去了生成候选区域的操作,直接在特征图上进行区域划分然后进行检测,可以在保持一定检测精度的同时具有极快的检测速度,非常适合对未佩戴安全帽人员的快速目标检测。2016 年提出的 YOLO 算法^[6]是单阶段目标检测算法的主要代表。

要实现对未佩戴安全帽人员的轨迹追踪则需要运用卡尔曼滤波算法、均值漂移(Meanshift)算法等目标跟踪算法^[7]。其中卡尔曼滤波(Kalman)算法^[7]一般仅适用于线性高斯系统假设,但实际情况中目标的运动大多无法满足高斯假设,导致精度不高,对杂乱的背景也很敏感。均值漂移(meanshift)算法^[8]在跟踪过程中没有利用目标在空间中的运动方向和速度等信息,容易出现遮挡及光线干扰条件下的目标丢失。Meanshift 算法结合目标色彩信息改进得到的连续自适应均值漂移(Camshift)算法可以适应运动目标的大小形状的改变,具有较好的跟踪效果,但当目标颜色接近背景色或发生遮挡时,易导致目标跟踪丢失^[9]。文献[10]提出了一种基于 YOLO v3 与 Kalman 滤波的多目标跟踪算法,使用 Kalman 滤波算法,在复杂背景等非线性影响下,获得了 34.4% 的目标跟踪准确度。以上算法在一定程度上达到了对目标检测跟踪的效果,但检测不够准确,且在背景复杂和发生遮挡时,易出现目标丢失和目标身份互换等问题^[11-12]。

综上所述,在背景复杂、发生遮挡的情况下,实现目标轨迹的有效跟踪,仍然难以得到很好的解决。针对检测精度低、目标易丢失等问题,本文提出了一种安全帽佩戴检测及轨迹追踪的方法。该方法采用 tracking-by-detect 策略,分为检测、预测、匹配和异常修正等 4 个步骤,首先在检测环节采用了 YOLOv5 网络实现目标的准确检测;其次在轨迹追踪中增加预测环节,使用扩展的卡尔曼滤波算法对目标运动轨迹进行预测;之后在匹配环节使用马氏距离与直方图相结合的方法对候选目标进行质心匹配关联,对于遮挡发生的轨迹异常结合预测状态信息进行异常轨迹的修正。基于自建数据集的实验结果证明,本文提出的方法有效解决了目标跟踪中由目标遮挡引起的目标互换和丢失等问题,获得了高于传统算法 10% 以上的目标跟踪准确度。

1 基于 YOLOv5 和质心匹配算法的轨迹追踪方法

1.1 轨迹追踪方法的总体流程

本文提出的未佩戴安全帽人员的轨迹追踪方法可分为

如图 1 所示的 4 个流程模块:目标检测→状态预测→质心匹配→异常轨迹修正。其中的目标检测部分采用 YOLOv5 检测器对目标进行检测;状态预测部分采用扩展的卡尔曼滤波算法对目标运动轨迹先进行预测;质心匹配关联部分使用马氏距离与直方图相结合的方法对候选目标进行匹配关联;异常轨迹修正部分结合预测状态信息对于遮挡发生的异常轨迹进行了轨迹的修正。

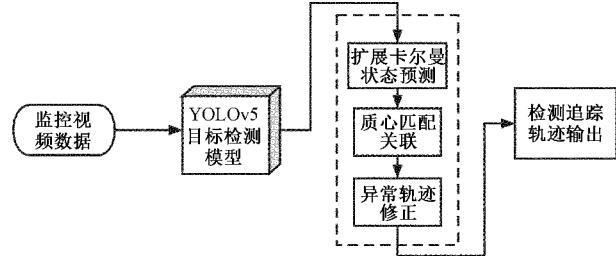


图 1 本文算法总体流程

1.2 基于 YOLOv5 的目标检测部分

目标检测部分采用 YOLOv5 模型,包括输入端、骨干网(backbone)、颈部(neck)和输出端(prediction)等 4 个部分^[13]。YOLOv5 结合了聚类和金字塔等技术,采用空间金字塔池化 SPP 以增大感受野,并运用特征金字塔增强模型实现了对不同缩放尺度对象的检测。YOLOv5 中的 CSPDarknet 结构将信息梯度的变化集成到特征图中,减少了模型的参数量;Focus 结构通过切片操作进一步减少了计算量。YOLOv5 结合了特征提取、候选框预测及目标识别等过程,可实现更快、更准的检测。

为提高对不同大小目标的检测精度,在对卷积神经网络训练时,分别针对检测的小、中、大目标自适应计算不同训练集的最佳先验框值,并通过 K-means 聚类对不同候选框按照尺寸进行自动归类,最终得出 3 种先验框如下所示。

anchors:
 - [10,16, 17,27, 23,39] # P3/8
 - [32,53, 42,74, 57,94] # P4/16
 - [80,129, 117,185, 217,303] # P5/32 (1)

在目标检测过程中,本文采用的 YOLOv5 模型可以准确识别当前帧中未佩戴安全帽的目标,并获得目标的质心坐标和宽度、高度的均值(x, y, w, h)。

1.3 基于扩展卡尔曼滤波算法的状态预测部分

状态预测部分采用了扩展卡尔曼滤波算法。传统的卡尔曼滤波采用参数化的贝叶斯模型,通过对下一时刻状态的先验估计,及测量得出的反馈相结合,最终得到准确的状态后验估计。传统的卡尔曼滤波算法仅适用于线性高斯系统假设^[12],不适应现实中存在各种非线性因素,如光照强度、物体形变、环境背景变化以及各种遮挡等因素。为实现准确的状态预测,状态预测部分采用扩展卡尔曼滤波^[11]方法,将非线性系统线性化后再进行卡尔曼滤波。

扩展卡尔曼滤波算法的状态预测方程是基于上一个状态执行控制量的二元函数基础上,叠加一个高斯噪声,表示为:

$$\mathbf{X}_k = f(\mathbf{X}_{k-1}) + \mathbf{S}_k \quad (2)$$

其中, \mathbf{X}_k 是第 k 帧目标的系统状态向量(第 k 帧目标的真实值); $f(\mathbf{X}_{k-1})$ 为状态转移矩阵; \mathbf{S}_k 是协方差为 Q 的零均值高斯噪声。

扩展卡尔曼滤波算法的观测方程需要在当前状态的函数再叠加一个高斯噪声,表示为:

$$\mathbf{Z}_k = h(\mathbf{X}_k) + \mathbf{V}_k \quad (3)$$

其中, \mathbf{Z}_k 为第 k 帧目标的系统观测向量(第 k 帧目标的检测值); $h(\mathbf{X}_k)$ 为观测矩阵; \mathbf{V}_k 是协方差为 R 的零均值高斯噪声。

扩展卡尔曼滤波方法在状态估计时仍采用卡尔曼滤波算法,对 $f(\mathbf{X}_{k-1})$ 和 $h(\mathbf{X}_k)$ 等非线性函数进行 Taylor 级数展开,将其扩展为一阶卡尔曼滤波,表示为:

$$\mathbf{X}_k = f(\mathbf{X}_{k-1}) + \mathbf{S}_k = f(\hat{\mathbf{X}}_{k-1}) + \mathbf{F}_{k-1}(\mathbf{X}_{k-1} - \hat{\mathbf{X}}_{k-1}) + \mathbf{S}_k \quad (4)$$

$$\mathbf{Z}_k = h(\mathbf{X}_k) + \mathbf{V}_k = h(\mathbf{X}'_k) + \mathbf{H}_k(\mathbf{X}_k - \mathbf{X}'_k) + \mathbf{V}_k \quad (5)$$

其中, \mathbf{X}'_k 为第 k 帧目标的预测值; $\hat{\mathbf{X}}_{k-1}$ 为第 $k-1$ 帧目标的估计值; \mathbf{F}_{k-1} 表示函数 $f(X)$ 在 $\hat{\mathbf{X}}_{k-1}$ 和 \mathbf{X}'_k 处展开的雅可比矩阵; \mathbf{H}_k 表示 $h(X)$ 函数在 $\hat{\mathbf{X}}_{k-1}$ 和 \mathbf{X}'_k 处展开的雅可比矩阵。

通过扩展卡尔曼滤波算法可以较好地去除检测结果中的噪声部分,并得到准确的跟踪预测框位置信息。

1.4 基于质心算法的目标匹配部分

在目标匹配部分,结合马氏距离度量和直方图相关性比较等算法,将当前检测目标与之前的预测位置,结合运动模型和外观信息进行目标的关联和匹配^[1]。匹配关联后未佩戴安全帽的检测目标的质心轨迹,形成被测物体的运动轨迹。

1) 马氏距离

目标匹配中采用马氏距离用于度量当前 t 时刻检测目标池内的质点与之前的质点预测位置向量 \mathbf{X}_j 之间的距离关系,表示为协方差距离。设检测目标池内的质点向量记为 \mathbf{X}_m ,协方差矩阵记为 \mathbf{S} ,则目标池内的质点向量 \mathbf{X}_i 与 \mathbf{X}_j 之间的马氏距离可用如下公式计算:

$$d(\mathbf{X}_i, \mathbf{X}_j) = \sqrt{(\mathbf{X}_i - \mathbf{X}_j)^T \mathbf{S}^{-1} (\mathbf{X}_i - \mathbf{X}_j)} \quad (6)$$

文中选择上述马氏距离作为依据,选出小于阈值的目标作为目标待选池,若待选池为空,则匹配失败。

2) 相关性比较

目标匹配中采用的相关性比较来源于统计学中的相关系数,表示为:

$$r(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}} \quad (7)$$

其中, $\text{Cov}(X, Y)$ 为 X 与 Y 的协方差, $\text{Var}(X)$ 为 X 的方差, $\text{Var}(Y)$ 为 Y 的方差, $r(X, Y)$ 即为 X 与 Y 的相关系数,绝对值越大,表明相关度越高^[7]。

本步骤的相关性比较的对象是待选池中目标的直方图和预测位置对应的上一帧中的原目标的直方图。相比于 RGB 空间,HSV 空间采用色调 H 和饱和度 S 分量计算直方图^[14],具有更好的相关性特性。为了提高相关性检测准确率,本文在目标的直方图归一化的基础上,将目标图从 RGB 色彩空间转换到 HSV 色彩空间^[15]。对于 HSV 空间的两个色调直方图 H_1 和 H_2 ,其相关性比较结果表示为:

$$d(H_1, H_2) = \frac{\sum_i (H_1(i) - \bar{H}_1)(H_2(i) - \bar{H}_2)}{\sqrt{\sum_i (H_1(i) - \bar{H}_1)^2 \sum_i (H_2(i) - \bar{H}_2)^2}} \quad (8)$$

其中,

$$\bar{H}_j = \frac{1}{n} \sum_{i=1}^n H_j(i) \quad (9)$$

由上式可见,相关性越强,该值越接近 1。

目标匹配过程首先从目标待选池中选取最大相关性比较值,并将该值和设定的阈值比较。如果该值大于设定阈值,则表示该目标和与上一帧($t-1$ 时刻)的原目标为同一目标,此时记录该目标在 t 时刻的对应质心坐标,即实现了目标质心匹配,确定了目标的质心运动轨迹;若该值小于设定阈值,则表明匹配失败,说明 t 时刻没有检测出 ID 为 j 的目标,可能发生了遮挡或者目标消失。

1.5 遮挡异常的修正部分

目标遮挡会影响轨迹追踪的效果。目标遮挡一般会带来两类问题:对遮挡的判别和目标再出现的再定位。当发生目标遮挡时,标志检测目标的标志 ID 在遮挡前后因为跟踪轨迹的中断,会被误认为新的目标而发生目标 ID 的变化。在此加入对轨迹异常情况的修正,是为了减少遮挡而引起的目标的标志 ID 的变化。针对前后两个时刻的质心数不同的变化,本文采取了如下处理方法。

1) t 时刻的目标质心数少于 $t-1$ 时刻的质心数

此时可认定为发生了遮挡,对于匹配失败的目标 k ,可以确定为被遮挡的目标。对于缺失的目标所要做的轨迹修正,需要补齐 t 时刻对应目标虚拟质心(非检测获得,故称为虚拟质心)。质心坐标取其预测位置 \mathbf{X}_k ,即为因遮挡而预设的虚拟质心,预测目标框表示为:

$$\text{Box}(T/T-1)_k = \{b_k^x, b_k^y, b_k^w, b_k^h\}^\top \quad (10)$$

直方图相关属性值同 $t-1$ 时刻的属性。

以上预测获得的虚拟质心将形成对应的虚拟轨迹,在后续连续 20 帧中若依然没有出现直方图相关性高的目标与目标 k 匹配,则确定该目标为消失目标,没有后续轨迹,则删除虚拟质心形成的轨迹。

2) t 时刻的目标质心数不少于 $t-1$ 时刻的质心数

此时对目标直方图相关性比较匹配后,若实际质心能

与虚拟质心进行匹配,则认定为遮挡目标重现。通过此步骤可解决了目标重现的再定位。若目标 ID 没有增加,目标 ID 匹配,虚拟轨迹成为质心实际轨迹。若不能匹配,则视为新的目标 ID。

遮挡异常的修正部分采用的轨迹修正算法,通过前导预测过程中的扩展卡尔曼滤波算法预测出发生遮挡的目标位置,并结合上一步目标的匹配检查及检测信息计时判断,最终实现对目标的连续跟踪。

本文采用的轨迹追踪算法相较于传统 Camshift 和 Meanshift 算法,在发生遮挡和目标大小变化的情况下,可以更好的实现对目标遮挡环境中的目标轨迹异常修正,获得更为准确的目标轨迹。该算法有效解决了目标跟踪中由目标遮挡引起的目标互换和丢失等问题,提高了追踪效率的同时也保证了轨迹的完整性和真实性,同时计算量没有明显增加。

1.6 算法流程

如图 2 所示,本文所述算法流程具体如下。

1) 采用 YOLOv5 检测器对目标进行检测,得到当前帧中未佩戴安全帽的目标的检测框和置信度,计算得出质心

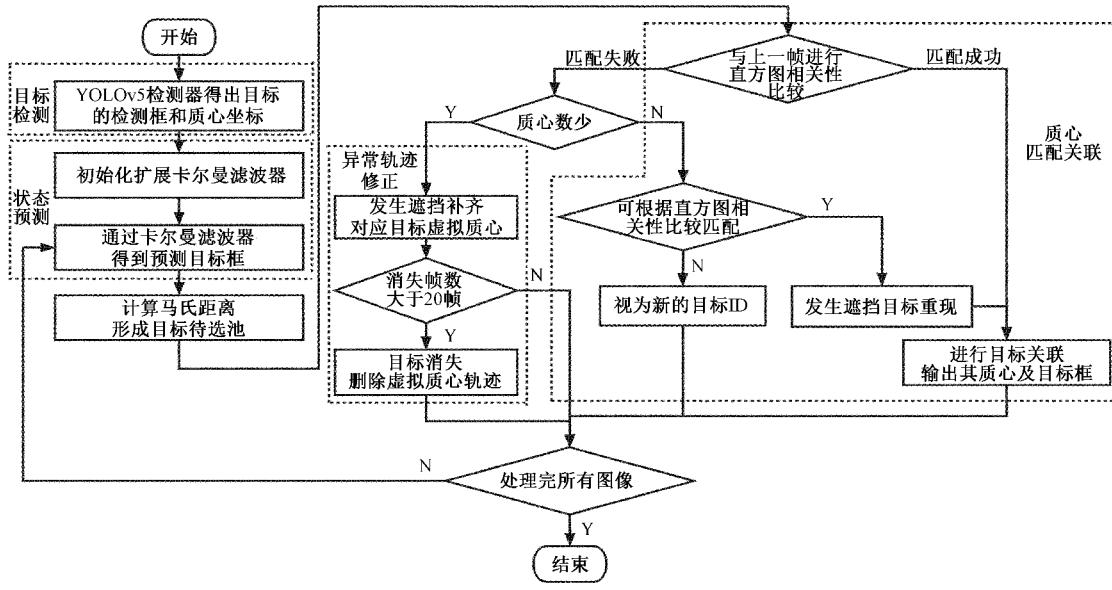


图 2 本文算法流程

2 实验结果与分析

2.1 数据集构建

数据集是深度学习检测领域研究必不可少的基础,已开源的安全帽数据集只有 SHWD(safety helmet wearing dataset),但该数据集不完全是取自工地场景的数据,不能直接用于本研究。为此,本研究构建了一个工地施工场景下安全帽佩戴检测数据集,主要过程为:数据采集筛选和数据归一化处理。

1) 数据采集

本文数据集所需的图像主要来源于施工现场图片采

坐标。

2) 通过深度卷积神经网络提取检测目标的特征,初始化扩展卡尔曼滤波器,输入第 1 帧图像的检测输出信息。

3) 通过扩展卡尔曼滤波算法,依据上一帧的目标框信息预测当前帧中的目标位置信息,得到预测目标框。

4) 计算马氏距离形成目标待选池。

5) 目标待选池非空,与上一帧的目标进行直方图相关性比较,若无匹配度高的目标,则扩大直方图相关性比较范围,对于匹配成功的目,进行目标关联,直接输出其质心及目标框坐标。

6) 若匹配失败,当前帧目标质心数少于上一帧目标数,拟定发生了遮挡,根据预测目标框位置补齐当前帧对应目标虚拟质心。后续连续 20 帧中若依然没有出现直方图相关性高的目标,则确定该目标为消失目标,删除虚拟质心轨迹。

7) 若当前帧目标质心数多于上一帧目标数,若可根据直方图相关性比较匹配,则为遮挡目标重现,否则视为新的目标 ID。

8) 处理完所有图像则结束,否则转步骤 3)。

集、施工现场视频分帧,自拍摄图片和网络图片筛选等。所采集的数据包括不同分辨率、不同场景下人员佩戴安全帽和未佩戴安全帽两种类型的图片,并在其中添加多组干扰图片,以此增强模型的鲁棒性及泛化能力。

采用的自建数据集图片均出自于自摄制视频、图片,及部分 SHWD 开源数据集。

2) 数据处理

本文自建数据集样本如图 3 所示。数据处理时要将数据集转换成 YOLOv5 训练需要用到的格式,具体步骤如下。

(1) 使用标注工具精灵标注助手 colabeler 对图像进行

手动标注,分为 2 个类别:佩戴安全帽的(helmet)、没有佩戴安全帽的(person),对图像中的人员进行分类标注。

(2)将标注形成的 xml 文件标注转换为 darknet 形的坐标标签,框坐标采用归一化的 xywh 格式。

(3)生成每个图片对应的标签文件,其中包含图片中各目标所属的类别及归一化的框坐标格式。



图 3 自建安全帽数据集样本图像示例

本研究最终得到包含多种施工场景的数据集共有 6 536 张图片,表 1 列出了该数据集中佩戴安全帽与不佩戴安全帽的目标具体信息。按照 4 : 1 的比例将数据集划分为训练集和测试集,训练集和测试集的图片数量分别为 5 228 和 1 308 张。

表 1 数据集类别分配

| 目标类别 | 训练集 | 测试集 | 标注目标 |
|----------|--------|--------|--------|
| | 目标数 | 目标数 | 总数 |
| 佩戴安全帽类别 | 58 416 | 13 480 | 71 896 |
| 未佩戴安全帽类别 | 75 735 | 15 560 | 91 295 |

2.2 实验环境

本文模型的构建、训练和测试均在 Pytorch 框架下完成,使用 CUDA 并行计算架构,实验环境具体配置如表 2 所示。

表 2 实验运行环境

| 类别 | 配置 |
|--------|--|
| 系统 | 64-bit Windows10 |
| CPU | Intel Core i7-10700K@3.80 GHz, 5.1 GHz, 8-Core |
| 软件 | Python 3.7.0 |
| 内存 | 16 GB |
| 硬盘 | 1T |
| 深度学习框架 | PyTorch 1.7.0+CUDA10.0 |

在模型经过训练构建成后,具体的功能测试所需实验硬件环境配置为 Intel Core i7-10700K CPU, 3.80 GHz 主频, 16 GB 内存的电脑, 跟踪可视化基于 OpenCV 实现, 在 Windows10 系统支持下, 使用 Python 语言及 PyTorch 1.7.0+CUDA10.0 集成实现整个检测跟踪系统。

2.3 算法测试

从图 4 中可以看出,当未佩戴安全帽的目标 2Pid 被其他人遮挡时,目标的轨迹根据算法得到了修正,解决了轨迹异常的问题。从图 5、6 中可以看出,目标在跟踪过程中的轨迹和跟踪结果较为准确。从图 4 中可以看出,修正后的轨迹更加接近真实的轨迹。

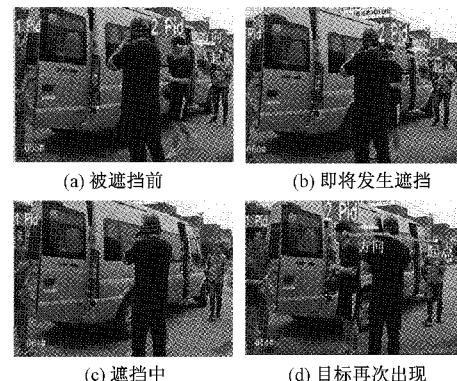


图 4 目标位置发生变化被遮挡时的轨迹追踪效果

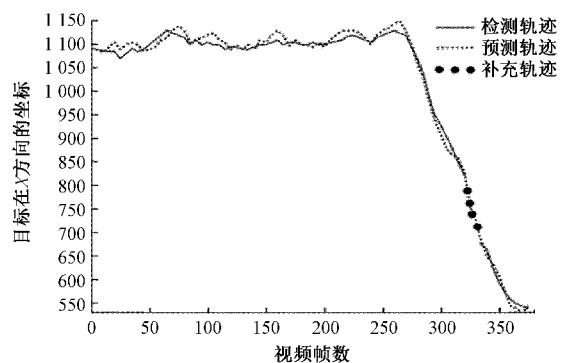


图 5 预测轨迹修正轨迹和检测轨迹在 X 方向上的坐标对比

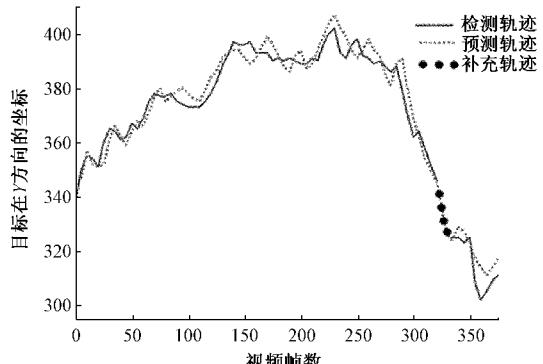
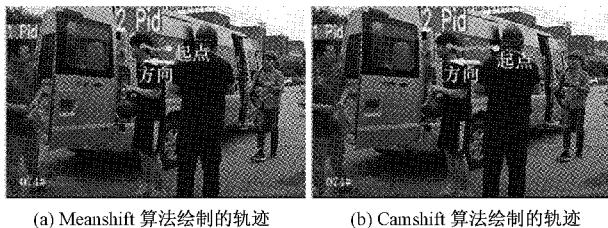


图 6 预测轨迹修正轨迹和检测轨迹在 Y 方向上坐标对比

图5和6中分别绘制了预测轨迹修正轨迹和检测轨迹在X和Y方向上的坐标对比,由图5和6可见,文中的方法可以在目标被遮挡时根据预测轨迹对异常轨迹进行修正,进而得到较为准确的检测轨迹。根据上述实验结果表明,本研究算法能够实现目标的轨迹追踪,并针对跟踪过程中目标的遮挡问题,可补充修正遮挡过程中目标的位置,进而修正目标轨迹,在一定程度上解决了跟踪过程中发生的目标遮挡、目标丢失等问题。

2.4 实验对比

为了反映本文提出方法的效果,本文和常见的2种目标追踪算法,即Meanshift和Camshift算法进行了对比,如图7所示。



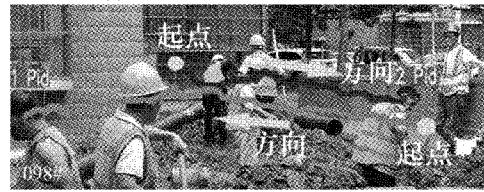
(a) Meanshift 算法绘制的轨迹 (b) Camshift 算法绘制的轨迹

图7 对应于图4的不同算法追踪效果图

在图8测试案例中可见,采用Meanshift、Camshift算法跟踪,当未佩戴安全帽的目标2Pid、1Pid先后被遮挡均引发了目标丢失而缺失部分检测轨迹,目标2Pid与1Pid发生路径相交时,目标1Pid因路径相交引发了身份互换而导致自身检测轨迹是两个不同目标部分轨迹的叠加,而本文算法在跟踪过程中有效解决了因发生目标遮挡等情况引起的目标互换和丢失等问题,从而获得了准确的目标轨迹。目标跟踪效果评价指标^[12]如表3所示,其中指标越小跟踪效果越好用箭头↓表示,指标越大跟踪效果越好用箭头↑表示。



(d) 用Camshift算法第88帧测得的轨迹



(e) 用本算法第98帧测得的轨迹



(f) 用Camshift算法第98帧测得的轨迹

图8 遮挡、路径相交时3种算法的追踪效果图

表3 目标跟踪效果评价指标

| 评价指标 ^[12] | 定义 |
|----------------------|-------------------|
| Avg Rank ↓ | 所有评价指标的平均度量值 |
| ID_Sw ↓ | 跟踪过程中发生目标身份互换的总数 |
| ML ↓ | 丢失的目标轨迹与真实的目标轨迹占比 |
| FN ↓ | 漏检的目标总数 |
| FP ↓ | 误检的目标总数 |
| MT ↑ | 成功跟踪目标轨迹与真实目标轨迹占比 |
| MOTA ↑ | 目标跟踪的精确度 |

与传统目标检测算法的对比结果如表4所示,可见本文算法在FP、AvgRank、ML、MT、ID_Sw、MOTA等几项指标上表现较好,目标身份互换情况得到缓解,较Meanshift算法有明显提升,成功跟踪的目标轨迹比率较Camshift算法提升14%,目标跟踪的精确度较Camshift算法提升近10%,较Meanshift算法提升近15%。以上对比结果表明,本文提出的方法有效解决了目标跟踪中由目标遮挡等情况引起的目标互换和丢失等问题,提高了跟踪的精确度。

表4 与其他算法在目标跟踪效果的实验对比结果

| 算法 | Avg | ID_Sw | ML↓ / % | FN↓ | FP↓ | MT↑ / % | MOTA↑ / % |
|-----------|-------|-------|---------|-------|-------|---------|-----------|
| | Rank↓ | Sw↓ | % | | | % | ↑ / % |
| 本文算法 | 27.6 | 389 | 19.9 | 2 802 | 1 146 | 47.2 | 70.4 |
| MeanShift | 41.2 | 721 | 30.7 | 3 579 | 2 397 | 25.8 | 55.1 |
| CamShift | 39.5 | 506 | 29.5 | 3 293 | 2 055 | 32.6 | 60.3 |

3 结 论

本文提出了一种基于 YOLOv5 和质心匹配算法的安全帽佩戴检测及轨迹追踪方法,在保证检测精度的同时,实现了对未佩戴安全帽者的实时检测与轨迹追踪。实验结果表明,本文算法在自建数据集上获得了 70.4% 的跟踪精确度,高出传统算法 10% 以上,且有效减少了目标身份互换次数和丢失的目标个数。本文提出的方法可以较好的满足在复杂施工场景下对未佩戴安全帽者的检测及目标跟踪的准确性需求,但它的时间复杂度较高。下一步研究的重心将围绕进一步提高跟踪准确度和实时性展开。

参考文献

- [1] 常欣,刘鑫萌.建筑施工人员不合理佩戴安全帽事故树分析[J].吉林建筑大学学报,2018,35(6):65-69.
- [2] 薛瑞晨,郝媛媛,张振,等.基于改进 YOLOv3 的头盔佩戴检测算法[J].电子测量技术,2021,44(12):115-120.
- [3] 王忠玉.智能视频监控下的安全帽佩戴检测系统的设计与实现[D].北京:北京邮电大学,2018.
- [4] 赵永强,饶元,董世鹏,等.深度学习目标检测方法综述[J].中国图象图形学报,2020,25(4):629-654.
- [5] 李一男.深度学习目标检测方法研究综述[J].中国新通讯,2021,23(9):159-160.
- [6] 周晓彦,王珂,李凌燕.基于深度学习的目标检测算法综述[J].电子测量技术,2017,40(11):89-93.
- [7] 储琪.基于深度学习的视频多目标跟踪算法研究[D].合肥:中国科学技术大学,2019.
- [8] 王忠民,段娜,范琳.融合 YOLO 检测与均值漂移的

目标跟踪算法[J].计算机工程与应用,2019,55(10):186-192.

- [9] 韩鹏,沈建新,江俊佳,等.联合 YOLO 和 Camshift 的目标跟踪算法研究[J].计算机系统应用,2019,28(9):271-277.
- [10] 任珈民,宫宁生,韩镇阳.基于 YOLOv3 与卡尔曼滤波的多目标跟踪算法[J].计算机应用与软件,2020,37(5):169-176.
- [11] 谢伟形.拥挤场景下视频多目标跟踪算法研究[D].杭州:浙江大学,2020.
- [12] 王春艳,刘正熙.结合深度学习的多目标跟踪算法[J].现代计算机(专业版),2019(6):55-59.
- [13] 唐建宇,唐春晖.基于旋转框和注意力机制的遥感图像目标检测算法[J].电子测量技术,2021,44(13):114-120.
- [14] 包本刚.融合多特征的目标检测与跟踪方法[J].电子测量与仪器学报,2019,33(9):93-99.
- [15] 李艳荻,徐熙平,陈江,等.动态特征块匹配的背景更新在运动检测的应用[J].仪器仪表学报,2017,38(2):445-453.

作者简介

许玥,本科生,主要研究方向为智能信号处理、图像处理、深度学习算法。
E-mail:vision06@qq.com

宋远伟,本科生,主要研究方向为智能信号处理、图像处理、深度学习算法。
E-mail:873417587@qq.com

赵华(通信作者),博士,副教授,主要研究方向为智能信号处理、光纤光栅、深度学习及智能仪器等。
E-mail:zhaohua@njnu.edu.cn