

一种基于视频分析的高速公路交通异常事件检测算法



姚 兰¹ 赵永恒¹ 施雨晴¹ 于明鹤²

1 东北大学计算机科学与工程学院 沈阳 110819

2 东北大学软件学院 沈阳 110819

摘 要 交通领域的异常事件检测对于预防和及时处理交通事故有着重要作用。当前大多数交通异常事件检测都是通过人工完成的,耗费了大量的人力,同时实时性也较差。文中针对高速公路的交通场景特点,利用深度学习中的目标检测算法,对视频中的车辆目标进行提取,提出了结合运动特征和表观特征的多目标追踪算法;在此基础上,又提出了一种基于车辆轨迹特征的异常事件检测方法,其中的追踪算法减少了轨迹提取过程对背景环境变化的依赖。在异常事件检测算法中充分结合高速公路实际场景,加入滑动窗口机制,提升了对远距离和复杂场景下异常事件的检测能力。利用面向真实交通视频的数据,与现有的事件检测算法进行对比,实验结果证明,所提方法在事件检测的准确率、召回率和F值指标方面都有良好的性能表现,能够有效地完成高速场景下的交通异常事件检测。

关键词: 视频监控;目标检测;目标追踪;异常事件检测;轨迹特征

中图法分类号 TP301

Highway Abnormal Event Detection Algorithm Based on Video Analysis

YAO Lan¹, ZHAO Yong-heng¹, SHI Yu-qing¹ and YU Ming-he²

1 College of Computer Science and Engineering, Northeastern University, Shenyang 110819, China

2 College of Software, Northeastern University, Shenyang 110819, China

Abstract Abnormal event detection in a traffic scenario is significant for accident prevention, on-call solution and other applications. While currently, the detection approaches are neither labor efficient, nor real-timing. A multi-target tracking algorithm combining motion characteristics and apparent characteristic for vehicle trace in highway traffic scenario is derived by introducing target detection in deep learning and extracting targets in a video. An abnormal event detection method which is based on vehicle trajectory feature is proposed. The proposed tracking algorithm declines the dependent on background during the procedure of trajectory extraction. The abnormal event detection algorithm is designated adequately for highway scenario with an additional strategy of sliding window to improve the performance on abnormal detection for remote and complex scenes. Through the experiments on practical video repository, the proposed method is compared with existing methods and shows a highlighted performance in the terms of Precision, Recall rate and F-value index. This method turns out to be solid and efficient in abnormal event detection in highway traffic scenario.

Keywords Video surveillance, Target detection, Target tracking, Abnormal event detection, Trajectory feature

1 引言

高速公路上车辆行驶速度快、车流量大,违停和逆行等异常事件一旦发生,极易引起交通事故,而且高速公路上的交通事故损失往往更为严重。为了避免高速公路交通事故的发生,及时检测交通异常事件就显得尤为重要。

在高速公路的交通场景下,违停、缓行和逆行等交通异常事件极易引发严重的交通事故,造成人员伤亡和财产重大损失,及时检测出此类交通异常事件,并采取快速有效的措施进行处理和解决,对保证高速交通安全至关重要。因此,基于视频的交通异常事件检测一直是智能交通领域的重点研究方向。基于视频的交通异常事件检测通常包括目标检测、多目

标追踪和交通事件检测 3 个步骤。本文采用基于目标检测的多目标追踪框架,使用 YOLOv3^[1] 目标检测算法从视频帧中提取车辆目标,并使用结合运动特征和表观特征的多目标追踪算法^[2] 对车辆目标进行追踪,最后通过自定义的交通异常事件模型对交通异常事件进行判定。

本文的主要贡献点有:1)详细分析了各种交通异常事件的目标运动特征;2)根据运动特征,定义了交通异常事件,提出了交通异常事件检测算法;3)在高速视频数据集上对异常事件检测算法进行实验,与现有方法进行对比,并实现了高速公路场景下异常事件的实时检测。

本文第 1 节阐述交通异常事件检测的背景和应用价值;第 2 节介绍交通异常事件检测方面已有的最新研究成果;第

到稿日期:2019-10-24 返修日期:2020-04-08

本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61433008,U1435216)

This work was supported by the National Natural Science Foundation of China (61433008,U1435216).

通信作者:姚兰(yaolan@mail.neu.edu.cn)

3 节介绍多目标追踪算法的形式化定义和实现方法;第 4 节介绍异常事件的相关概念以及符号定义,包括问题的形式化描述;第 5 节详细介绍异常事件检测算法的实现过程;第 6 节介绍实验细节,并分析实验结果;最后总结全文,并展望未来。

2 相关工作

确定道路交通异常事件的类别,需要对目标进行持续的跟踪,以获得车辆的运动特征、行驶轨迹和交通参数等。多目标追踪的主要工作是对给定的视频进行分析,将相邻视频帧中的同一目标进行关联,并记录目标的轨迹^[3]。

多目标追踪是行为识别和轨迹分析等高层应用的基础,是学术界一直关注的热点。CHANHO 等^[4]通过归一化的最小均方差优化算法引入表观模型来扩展 MHT 算法,取得了不错的多行人跟踪结果。Xiang 等^[5]采用了马尔可夫决策过程来推导每个轨迹生成的 MDP 跟踪算法,这是一种基于机器学习的确定性推导在线目标跟踪算法。近年来,随着深度学习的迅速发展,基于深度学习的多目标追踪算法也有了广泛的应用和突破性进展。例如,Leal 等^[6]采用了 Siamese 对称网络学习来表观特征相似度,通过降低梯度加强算法中分类器的融合运动特征,并利用线性规划优化算法得到多目标追踪结果。Si 等^[7]采用深度计算的类光流特征,结合表示能力更强的模型,得到了效果很好的多目标追踪结果。Amir 等^[8]设计了基于长短期记忆循环网络模型的特征融合算法,来学习轨迹历史信息与当前检测之间的匹配相似度,能够记忆历史信息,学习匹配相似性度量,从而增强多目标追踪的性能。Weiming 等^[9]在行为分析的相关研究中应用了多目标追踪算法;在将道路车辆目标作为兴趣目标方面,Roller 等^[10]将车辆作为研究对象,提出了新的多目标追踪算法,改善了由于遮挡导致的追踪准确率低的问题。Margrit 等^[11]减少了追踪算法的计算资源消耗,实现了多车辆的快速识别和实时跟踪。Maksai 等^[12]提出了一种迭代方式的训练方法,有效减少追踪过程中目标跳变的情况。基于深度学习的多目标追踪通常具有更佳的追踪表现,能更有效地处理目标遮挡等问题,但由于深度特征计算带来了较大的计算量,使得其运算速度表现不佳,难以满足实时性的要求。

在交通异常事件检测的相关研究中,Wang 等^[13]使用流量状态估计来检测交通事件,在诸如交通控制系统之类的应用程序中将其作为识别交通异常事件的一种手段。文献^[14]提出了一种基于时间序列特征的稳态分析法,用于检测高速公路的违停事件,取得了良好的效果。文献^[15]采用滑动窗口的方法来判断车辆的运动趋势,使用车辆轨迹的速度信息来判定交通异常事件的发生。文献^[16]提出了基于车辆轨迹模型的检测方法,将复杂的车辆轨迹分解为前行、反行、停滞和斜行 4 类轨迹元素,着重研究并分析了车辆跟踪得到的行驶轨迹点。文献^[17]针对现有智能交通系统功能性不足的情况,提出基于机器视觉的高速公路交通事件检测方法,补充其功能模块,能够检测出拥堵、行人、停车等交通异常的发生。文献^[18]通过背景差法获得运动目标前景,对其进行阴影去除后,通过卡尔曼滤波获得车辆轨迹,从而实现了对交通异常事件的检测。传统的异常事件检测通常使用背景差法提取目标前景,需要对图像进行阴影去除等操作,背景的变化会对检测结果产生严重影响,而使用基于检测的追踪算法能够有效避

免背景变化对多目标追踪带来的影响,从而提升事件检测算法的泛化能力。

基于以上工作,本文提出了一种基于视频的高速公路交通异常事件检测方法,对道路交通异常事件的检测工作展开了深入的研究。

3 多目标追踪

在异常事件检测中,首先使用目标检测算法对车辆目标进行检测,然后通过多目标追踪算法将帧间的同一车辆目标进行匹配关联,得到车辆目标的轨迹信息,最后根据车辆目标轨迹信息使用异常事件检测模型对异常事件进行判别。

3.1 问题描述

假设目标检测模块在 t 时刻的视频帧上获得 n 个检出对象,则 n 个检出对象在 t 时刻的静态状态集合为 $T^t = \{T_1^t, T_2^t, \dots, T_n^t\}$; n 个检出对象从开始时刻 t_s 到结束时刻 t_e 的静态状态集合可以表示为:

$$T^{t_s:t_e} = \{T_1^{t_s:t_e}, T_2^{t_s:t_e}, \dots, T_n^{t_s:t_e}\}$$

其中, $T_i^{t_s:t_e} = \langle T_i^{t_s}, T_i^{t_s+1}, \dots, T_i^{t_e} \rangle (i \in n)$ 表示检出对象 i 从 t_s 到 t_e 的静态状态序列,即 i 从 t_s 到 t_e 的轨迹。

设 D_i^t 表示 t 时刻获得的第 i 个观测对象,则 $D^t = \{D_1^t, D_2^t, \dots, D_m^t\}$ 表示 t 时刻中所有的 m 个观测对象的集合,所有目标从 t_s 到 t_e 的观测集合可以表示为 $D^{t_s:t_e} = \{D_1^{t_s:t_e}, D_2^{t_s:t_e}, \dots, D_m^{t_s:t_e}\}$ 。多目标追踪的目的就是找到所有对象匹配的状态序列,可以根据给定的所有观测序列状态的条件分布使用 MAP (Maximal a Posteriori) 来建模,如式(1)所示:

$$\bar{T}^{t_s:t_e} = \arg \max_{T^{t_s:t_e}} P(T^{t_s:t_e} | D^{t_s:t_e}) \quad (1)$$

3.2 轨迹预测与目标关联

在高速监控视频中,车辆相互遮挡问题是多目标追踪中的难点问题。由于车辆被遮挡,因此检测算法无法正确识别车辆的当前位置,故需要进行位置预测。其基本思想是:若追踪目标发生位移变换,则可根据历史轨迹信息对下一帧的目标位置进行预测。如前文所述, T_i^t 表示目标 i 在 t 时刻的时空状态,如式(2)、式(3)所示:

$$T_i^t = \langle Loc_{T_i^t}, TrackInfo_{T_i^t}, Features_{T_i^t} \rangle \quad (2)$$

其中,

$$\begin{cases} Loc_{T_i^t} = [(x, y), (x+w, y+h)]_{T_i^t} \\ TrackInfo_{T_i^t} = [\bar{v}, \bar{a}, k]_{T_i^t} \\ Features_{T_i^t} = [color, type]_{T_i^t} \end{cases} \quad (3)$$

其中, $Loc_{T_i^t}$ 表示对象 i 在 t 时刻的位置,包含左上角和右下角的坐标; $TrackInfo_{T_i^t}$ 表示对象 i 在 t 时刻的运动状态信息,包含速度 $\bar{v}$ 、加速度 $\bar{a}$ 和运动方向 k ; $Features_{T_i^t}$ 表示对象 i 在 t 时刻的特征信息,包含颜色特征 $color$ 和对象类别 $type$ 。本文使用颜色直方图提取颜色特征。

在进行位置预测时,根据当前速度、当前加速度和当前位置可计算出下一帧的预测位置,并结合目标检测得到的检测框,使用卡尔曼滤波进行位置修复。在目标关联中,首先使用余弦距离计算 T_i^{t-1} 和 T_i^t 的位置相似度 L_{sim} ;然后,使用直方图相交的方法计算 T_i^{t-1} 和 T_i^t 之间的颜色相似度 C_{sim} ;最后,综合位置相似性、颜色相似性和车型特征进行目标关联。

4 问题描述

设车辆目标的质心坐标列表为 $P = \{p_1, p_2, \dots, p_m\}$,其

中 $p_i = \{x_i, y_i\}$ 为目标的质心坐标。

定义 1(逆行事件) 设道路规定的行驶正方向向量为 $\vec{D}$, 车辆轨迹的方向向量为 $\vec{V}$, 若满足 $\vec{D} \cdot \vec{V} < 0$, 则判定目标正在逆行, 即发生车辆逆行事件。

定义 2(缓行事件) 设车辆质心的空间位置变化量为 Δp , 空间位置变化量阈值为 p_{thres} , 若连续满足 $\Delta p < p_{thres}$ 的时间超过 T , 则判定车辆正在缓速行驶, 可标记为缓行事件。

定义 3(停车事件) 设道路规定的禁停区域 S 的中心坐标为 (x_c, y_c) , 区域长度为 l , 宽度为 w 。对于缓行车辆, 当其空间位置变化量满足 $\Delta p = 0$ 且坐标 (x_m, y_m) 满足:

$$\begin{cases} x_m \in (x_c - w/2, x_c + w/2) \\ y_m \in (y_c - l/2, y_c + l/2) \end{cases}$$

则认为车辆停止行驶, 若其停止时间 T_{stop} 超过规定时间 T_{thres} , 即 $T_{stop} > T_{thres}$, 则判定发生停车事件。

其中, 车辆缓行指车辆行驶速度缓慢, 与正常行驶车辆相比, 其在单位时间内的位移通常相对较小; 停车事件从本质上可以看作是一种在空间位置变化和持续时间上同时做出特殊限制的缓行事件。基于视频的交通异常事件检测本质上是多类别多标签问题, 同一车辆可能同时存在多种异常行为, $C \subseteq \{S, P, R, N\}$ 代表视频的交通事件类别集合, S 代表缓行事件, P 代表停车事件, R 代表逆行事件, N 代表无异常。其中, S 与 N 为互斥事件, P 与 N 为互斥事件, R 和 N 为互斥事件。

5 基于轨迹特征的异常事件检测算法

高速公路上摄像头的观测位置和观测角度都是固定的, 因此在同一个监控视频中, 道路的正常行驶方向和禁停区域也是确定的。由问题定义可知, 车辆的不同异常行为均有其特定的运动特征, 这些运动特征可以从车辆的轨迹特征中提取。另外, 由于相邻帧时间间隔较短, 本文假设目标在相邻帧之间匀速运动。

车辆的运动轨迹是随时间不断更新的, 距离当前时刻越近的坐标, 越能体现车辆当前的状态, 因此, 本文采用滑动窗口机制, 使用观测坐标列表 P_w 来表示距离当前帧较近的坐标信息列表。若车辆目标的质心坐标列表为 $P = \{p_1, p_2, \dots, p_m\}$, 滑动窗口长度为 N_w , 则 $P_w = \{p_{m-N_w+1}, p_{m-N_w+2}, \dots, p_m\}$ 。

5.1 逆行事件的判定方法

图 1 给出了高速公路上出现的逆行事件, 从图中的路标指示可以看出车辆正在逆向行驶, 取视频的第 1 帧和第 50 帧, 对目标车辆的质心坐标变化进行分析, 并与同条道路正常行驶车辆的质心坐标变化进行对比, 结果如图 2 所示。从图 2(a)可以看出, 在该道路场景下, 逆行车辆与正常行驶车辆的横坐标变化无太大差别; 从图 2(b)可以看出, 逆行车辆的纵坐标在逐渐增大, 而正常行驶车辆的纵坐标在逐渐变小。



图 1 逆行事件

Fig. 1 Retrograde event




图 2 车辆质心坐标变化

Fig. 2 Vehicle centroid coordinate change

当车辆逆行时, 车辆的行驶方向一定与规定正方向相反, 利用最小二乘法可以得出车辆观测坐标列表 p_w 的拟合曲线

$y = \hat{a} + \hat{b}x$, 其计算方式如式(4)所示:

$$\begin{cases} \hat{a} = \frac{(\sum x_i^2)(\sum y_i) - (\sum x_i)(\sum x_i y_i)}{N_w(\sum x_i^2) - (\sum x_i)^2} \\ \hat{b} = \frac{N_w(\sum x_i y_i) - (\sum x_i)(\sum y_i)}{N_w(\sum x_i^2) - (\sum x_i)^2} \end{cases} \quad (4)$$

其中, $\hat{a}$ 表示拟合直线截距的最佳估计值, $\hat{b}$ 表示拟合直线斜率的最佳估计值, x_i 和 y_i 分别表示车辆轨迹中的横坐标和纵坐标。根据车辆的运动轨迹拟合直线可以得到车辆轨迹的平面向量 $\vec{V}$, 计算其与规定正方向 $\vec{D}$ 的乘积, 当 $\vec{V} \cdot \vec{D} < 0$ 时, 则可以判断车辆行驶方向与规定正方向相反, 发生了逆行事件。

5.2 缓行事件的判定方法

图 3 给出了高速公路上发生的车辆缓行事件, 图中车辆的行驶速度低于高速公路的最低限速, 车辆的坐标变化如图 4 所示。由于车辆行驶方向垂直于画面, 因此纵坐标的变化量能够反映车辆的行驶状态, 从图 4 可以看出, 从第 1 帧到第 30 帧, 车辆的位移在持续增加, 但其单位时间位移变化量低于正常行驶车辆的单位时间位移变化量, 即车辆行驶速度持续处于较低水平。



图 3 缓行事件

Fig. 3 Slow event




图 4 车辆质心坐标变化

Fig. 4 Vehicle centroid coordinate change

设车辆在第 i 帧的质心坐标 $p_i = \{x_i, y_i\}$, 则第 i 帧与第 $i+q$ 帧之间的坐标变化值为 $\Delta p_{(i,i+q)} (\Delta x_{(i,i+q)}, \Delta y_{(i,i+q)})$, 其计算式如式(5)所示:

$$\Delta p_{(i,i+q)} = \|\Delta x_{(i,i+q)} + \Delta y_{(i,i+q)}\| \quad (5)$$

其中, $\|\Delta p_{(i,i+q)}\|$ 表示第 i 帧与第 $i+q$ 帧坐标之间的欧氏距离。若连续 n_{thres} 帧内均满足 $\|\Delta p_{(i,i+1)}\| < p_{\text{thres}}$, 则说明在连续的 n_{thres} 帧内, 车辆的相邻帧间的位移变化量变小, 若同时满足 $\|\Delta p_{(i,i+n_{\text{thres}})}\| > 0 (n_{\text{thres}} > 1)$, 则说明车辆正在缓速行驶, 可以判定发生了缓行事件。

5.3 停车事件的判定方法

图 5 给出了高速公路上发生的停车事件, 截取视频第 46 帧、第 71 帧和第 96 帧。该视频展示的是目标车辆由正常行驶状态逐渐变为减速慢行状态, 最后变成停车状态的过程。从图 5 可以看出, 车辆由正常行驶开始逐渐减速行驶, 单位时间内的位移逐渐变小; 从图 5(b) 到图 5(c), 车辆由减速行驶变为停止状态, 且在该位置停止了一段时间。在第 46 帧到第 96 帧中, 该车辆的质心坐标变化和速度变化如图 6 所示, 可以发现车辆的位置变化量随时间变化逐渐变小, 最后趋于不变, 该车的速度随时间变化不断减小, 最后为 0。




图 5 停车事件
Fig. 5 Parking event

停车车辆通常是由缓行状态逐渐转变成停车状态。停车事件与缓行事件的不同之处在于, 缓行车辆虽然速度较慢但仍会持续产生位移, 而车辆停止时, 其位移变化量最后会变为 0, 即满足 $\|\Delta p_{(i,i+n_{\text{thres}})}\| = 0 (n_{\text{thres}} > 1)$ 。因此, 当车辆在连续 n_{thres} 帧内满足 $\|\Delta p_{(i,i+1)}\| < p_{\text{thres}}$, 则车辆处于缓行状态。进一步, 当 $\|\Delta p_{(i,i+n_{\text{thres}})}\| = 0$ 时, 则说明车辆在连续 n_{thres} 帧内都没有产生位移, 若此时车辆的坐标满足 $x_m \in (x_c - \frac{\tau w}{2}, x_c + \frac{\tau w}{2})$ 和 $y_m \in (y_c - \frac{l}{2}, y_c + \frac{l}{2})$, 则可判定车辆停于禁停区域, 发生了停车事件。

基于轨迹特征的异常事件检测算法如算法 1 所示。




图 6 停车位移和速度变化

Fig. 6 Displacement and speed change of park event

算法 1 基于轨迹特征的异常事件检测算法

输入: 车辆坐标列表 $p = \{p_1, p_2, \dots, p_q\}$, 车辆行驶正方向向量 $\vec{D}$, 位移变化量阈值 p_{thres} , 车辆禁停区域 S

输出: 异常事件类别 $C \subseteq \{S, P, R, N\}$

initialize set $C = \emptyset$

$\vec{V} = \text{compute_vector}(p_1, p_2, \dots, p_q)$

if $\text{vector_product}(\vec{D}, \vec{V}) < 0$

$C \leftarrow C \cup \{R\}$

for $i \rightarrow n$ do

if $\text{dist}(p_i, p_{i+1}) < p_{\text{thres}}$

$P_L \leftarrow P_L + p_i$

if $\text{count}(P_L) \geq n_{\text{thres}}$ and $\text{dist}(p_1, p_n) > 0$

$C \leftarrow C \cup \{S\}$

end if

if $\text{count}(P_L) \geq n_{\text{thres}}$ and $\text{dist}(p_1, p_n) = 0$ and $\text{locate}(p_n, S)$

$C \leftarrow C \cup \{P\}$

end if

end if

end for

if $C = \emptyset$

set $C = \{N\}$

end if

return C

6 实验结果与分析

6.1 实验方法

6.1.1 实验数据集

本文选取某高速公路不同场景的监控视频作为实验数据样本, 采用人工的方式对视频数据集进行异常事件的标注和分类。实验中分别截取了近距离场景视频和远距离场景视频, 视频的详细信息如表 1 所列。其中, 该高速公路小型车的最低限速为 80 km/h, 大型车的最低限速为 60 km/h。

表 1 实验视频信息

Table 1 Experimental video information

视频序列	视频场景	视频长度	轨迹总数	逆行数量	停车数量	缓行数量
Video1	近距离	00:13:15	186	3	15	3
Video2	近距离	00:17:01	175	3	11	2
Video3	近距离	00:24:19	212	6	16	6
Video4	远距离	00:11:37	164	2	9	4
Video5	远距离	00:20:45	279	4	14	7
Video6	远距离	00:32:26	581	5	15	11

近距离场景视频中, 车辆目标相对更易于检测和追踪, 能够检验异常事件检测算法在一般情况下的检测能力; 远距离场景能够检验算法在车辆目标较小时的检测能力。本文实验均在 Ubuntu16.04 系统下使用 C++11 语言实现。

6.1.2 实验评价指标

如前文所述, 异常事件检测本质上是一个多类别多标签问题, 即运动目标可能同时存在多种异常交通行为。基于此, 本文在实验中针对缓行、停车和逆行事件进行综合性能的验证, 评价指标为准确率 (Precision)、召回率 (Recall) 和 F-Score^[19]。人工的事件标注结果作为用于比较的事实标签, 当算法检测的异常事件类别与事实标签一致时, 则认为检测结果正确, 否则认为出现误检。特别地, 在高速公路场景中, 事件漏检的严重性通常高于事件误判的严重性, 即对异常事件召回率的关注度高于异常事件准确率, 为了使实验结果的评价更加全面, 本文使用 F2-Score 作为评价指标, 并使用 F1-Score 作为对比。

6.2 实验过程及评价

基于高速公路路侧监控的视频数据, 本文在不同场景下分别对逆行、停车和缓行的检测算法进行了性能测试, 并使用背景差与 HSV 阴影去除结合的检测方法 (BGD+HSV) 进行

对比实验。实验中对相关参数进行设置,将目标检测器的置信度阈值设置为 0.5,位移变化量阈值 p_{thres} 设置为 1.5 像素,滑动窗口长度设置为 25。最后得到的实验结果如表 2—表 4 所列。可以看出,在近距离和远距离场景中,本文方法在准确率和召回率方面均表现出了更好的性能。特别是在远距离场景中,本文方法的 F2-Score 更高,说明本文方法能够提升远距离场景的事件检测能力,有效地减少事件的漏检。采用背景差法与 HSV 阴影去除的方法对前景目标进行提取,当背景经常变化或者目标较小时,易将车辆过滤掉而导致车辆不能有效追踪,从而使得远距离场景下的异常事件准确性较低。本文使用 TBD 的追踪框架,综合考虑了车辆的运动特征和表观特征,提升了远距离场景下运动车辆的追踪能力,并最终提高了远距离场景下异常事件的检测性能。

表 2 逆行事件对比实验结果

Table 2 Retrograde event comparison experiment result

方法	场景	准确率	召回率	F1-Score	F2-Score
BGD+ HSV	近距离	0.90	0.92	0.91	0.92
	远距离	0.80	0.83	0.81	0.82
本文方法	近距离	0.95	0.92	0.93	0.93
	远距离	0.90	0.91	0.90	0.91

表 3 停车事件对比实验结果

Table 3 Parking event comparison experiment result

方法	场景	准确率	召回率	F1-Score	F2-Score
BGD+ HSV	近距离	0.91	0.90	0.90	0.90
	远距离	0.89	0.84	0.86	0.85
本文方法	近距离	0.94	0.95	0.94	0.95
	远距离	0.92	0.92	0.92	0.92

表 4 缓行事件对比实验结果

Table 4 Slow event comparison experiment result

方法	场景	准确率	召回率	F1-Score	F2-Score
BGD+ HSV	近距离	0.90	0.91	0.90	0.91
	远距离	0.85	0.81	0.83	0.82
本文方法	近距离	0.94	0.95	0.94	0.95
	远距离	0.90	0.91	0.90	0.91

结束语 本文针对高速公路的视频信息,完成了视频分析的异常事件检测工作。首先,利用目标检测算法对视频中的车辆进行目标检测;然后,提出了综合运动特征和表观特征的运动车辆追踪算法,来获取车辆的轨迹信息;最后,提出了基于轨迹特征的异常事件检测算法。实验结果表明,本文提出的高速公路异常事件检测算法能够提升远距离和复杂道路场景下的异常事件的检测能力,且具有良好的实时性能。

未来,一方面要研究其他的高速通行异常事件检测问题,例如行驶车辆的急减速、急变道等行为,从而能够更广泛地感知影响交通安全的路面状况;另一方面,研究各种交通状态与异常事件发生的关联关系,从而对可能发生的交通异常事件进行事前预警。

参 考 文 献

[1] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. arXiv:1804.02767, 2018.

[2] SIMON J J, JEFFREY K U. New extension of the Kalman filter to nonlinear systems [C]// International Society for Optics and Photonics (SPIE), 1997.

[3] LUO W H, JUN L X, XIAO Q Z, et al. Multiple object tracking: a review [J]. arXiv:1409.7618, 2014.

[4] CHANHO K, FUXIN L, ARRIDHANA C, et al. Multiple hy-

pothesis tracking revisited [C]// IEEE International Conference on Computer Vision (ICCV). 2015:4696-4704.

[5] XIANG Y, ALAHI A, SAVARESE S. Learning to track: online multi-object tracking by decision making [C]// 2015 IEEE International Conference on Computer Vision (ICCV). 2015: 4705-4713.

[6] LEAL T L, FERRER C C, SCHINDLER K. Learning by tracking: siamesecnn for robust target association [J]. CV-PR Workshops, 2016:418-425.

[7] SI Y T, BJOERN A, MYKHAYLO A, et al. Multi-person tracking by multicut and deep matching [M]. Computer Vision—ECCV 2016 Workshops, 2016:100-111.

[8] AMIR S, ALEXANDRE A, SILVIO S. Tracking the untrackable: learning to track multiple cues with long-term dependencies [J]. ICCV, 2017:300-311.

[9] WEIMING H, TIENIU T, LIANG W, et al. A survey on visual surveillance of object motion and behaviors [J]. IEEE Trans. Systems, Man, and Cybernetics, 2004, 34(3):334-352.

[10] ROLLER D, DANILDIS K, NAGEL H H. Model-based object tracking in monocular image sequences of road traffic scenes: [J]. International Journal of Computer Vision, 1993, 10(3):257-281.

[11] MARGRIT B, ESIN H, LARRY S D. Real-time multiple vehicle detection and tracking from a moving vehicle [J]. Machine Vision and Applications, 2000, 12(2):69-83.

[12] MAKSAI A, PASCAL F. Eliminating exposure bias and metric mismatch in multiple object tracking [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2019:4639-4648.

[13] REN W, DANIEL B W. Interactive multiple model ensemble Kalman filter for traffic estimation and incident detection [C]// International IEEE Conference on Intelligent Transportation Systems (ITSC). 2014:804-809.

[14] ZHAO M, ZHANG B, TANG Y, et al. Video detection algorithm for expressway violation parking in open air scene [J]. Computer Measurement & Control, 2014, 22(2):489-492.

[15] QIU L Y, HAN J, GU M. A method for detecting abnormal behavior of highway vehicles based on lane model [J]. Journal of Computer Applications, 2014, 34(5):1378-1382.

[16] ZHAO Y T, LI X Y, LUO D H. Research on automatic detection method of traffic events based on video vehicle trajectory model [J]. Journal of Sun Yatsen University (Natural Science), 2011, 50(4):56-60.

[17] YUAN Y Q, XIE C L. Research on traffic detecting method based on machine vision [J]. Computer Simulation, 2013, 30(10):189-193.

[18] SUI L, DANG J W. Research on detection algorithm of highway abnormal events based on moving target trajectory [J]. Computer Applications and Software, 2018, 35(1):246-252.

[19] GRIGORIOS T, IOANNIS K, IOANNIS V. Mining multi-label data [M]// Data Mining and Knowledge Discovery Handbook. Boston: Springer, 2009:667-686.



YAO Lan, born in 1977, Ph.D, associate professor. Her research interests include analysis on intelligent sensing data, data analysis and privacy protection in CPS.