

改进的基于时空累积图的车流量检测算法^{*}

郁佳佳 徐玉菁 左梅 黄卉 陆清茹

(东南大学成贤学院 电子与计算机工程学院 南京 210088)

摘 要: 针对传统的视频车流量检测算法采用的特征单一、天气鲁棒性差,易受车辆遮挡等问题,提出一种融合时空特征的车流量检测方法。以前景和背景图片的分块的互相关归一化值作为检测车辆经过的特征,在时间上累积得到时空累积特征图,在时空累积图上对特征值进行分析处理,并引入深度学习目标检测算法辅助进行背景更新和消除车辆因遮挡等问题所导致的漏检,并对行人、自行车等干扰因素进行校正,达到统计车流量的目的。实验表明,本文算法准确率一般能达到91%以上,在大部分情况下都优于传统的帧间差法和光流法,且实时性好,能较好满足车流量检测系统的要求。

关键词: 智能交通系统;时空累积;深度学习;车流量检测

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

Improved traffic flow detection algorithm based on
space-time accumulated figure

Yu Jiajia Xu Yujing Zuo Mei Huang Hui Lu Qingru

(Department of Electronic and Computer Engineering, Southeast University Chengxian College, Nanjing 210088, China)

Abstract: Aiming at the problems of the traditional video traffic flow detection algorithm, such as single feature, poor weather robustness and easy to be blocked by vehicles, a traffic flow detection method combining temporal and spatial features was proposed. To the cross-correlation of foreground and background image blocking normalized values as a feature of testing vehicles through accumulation plan get space-time characteristic figure on time, on time accumulated figure to analysis the characteristic value, and the introduction of deep learning target detection algorithm assisted background updating and eliminate the problem such as vehicles for shade caused by the leak, and correction for pedestrians, bicycles and other interference factors to achieve the objective of the statistics of the number of cars. Experimental results show that, the accuracy of the algorithm in this paper can generally reach more than 91%, which is better than the traditional frame difference method and optical flow method in most cases. Moreover, the real-time performance is good, which can better meet the requirements of the traffic flow detection system.

Keywords: intelligent transportation system; space-time accumulation; deep learning; traffic flow detection

0 引言

智能交通系统^[1](ITS)产生于20世纪60年代末70年代初,是当前世界交通领域发展迅猛的前沿技术之一,成为当代人解决城市交通问题的主要途径。它的首要问题是全方位获取道路交通信息,因此越来越多的学者把车流量统计算法的研究作为交通视频监控系统中一个必不可少的环节,它已经成为ITS领域的重要课题。车流量检测将为交通管理者提供大量有效的信息,对促进智能交通系统的长远发展起着举足轻重的作用。针对此现状,近年来人们使

用了各种各样的传感器,例如为车辆检测而设置的地磁传感器^[2],为普通监控而使用的视频传感器^[3],为跟踪车辆速度方位而使用的雷达、激光传感器等^[4]。这些传统的车流量获取方法往往存在一定的局限性,检测信息单一,安装成本较高,后期维修不方便,且很难适应一些复杂的交通场景。相对于传感器,视觉信号更方便获得,能同时提供大量交通数据信息,且环境适应性强。随着图像处理硬件设备和计算机的性能不断提高,用计算机视觉技术来解决车流量统计问题成为了车流量检测技术^[5]的发展趋势。

文献[6]结合帧间差分方法,对原始的Vibe运动检测

收稿日期:2021-03-30

^{*} 基金项目:东南大学成贤学院青年教师科研发展基金项目(Z0037)资助

算法进行了改进,能快速检测出前景目标。该算法计算内存资源占比小,但是当连续视频帧出现光照突变时,模型恢复缓慢,容易丢失检测目标,不利于后面的分析与识别。光流法^[7]能够检测独立的运动对象,不需要预知场景的任何信息,如文献[8]应用了金字塔LK光流法,来预测未来时刻运动目标的特征点位置,并通过做仿射变换消除背景运动带来的误差。但光流法检测出的前景目标轮廓易出现残缺情况,且光流的计算采用迭代的方法,计算复杂耗时,不利于实时检测。文献[9]在基于传统的背景差分法的基础上,利用颜色特征和纹理特征建立时空背景模型进行自适应运动目标检测,对较复杂场景具有一定的鲁棒性。然而该算法适宜处理背景为静态信息的图像,在背景发生变化的情况下效果不理想。

在本文前期工作中^[10-11],已经应用了一种新颖的基于统计参数的行车计数算法,通过在道路中开设虚拟检测窗,并用软件实现。在对单车道、多车道视频进行检测时,主要选用方差统计参数、NCC统计参数作为检测窗的输出信号,为了改善算法的阴影抑制能力,加入了纹理统计参数作为辅助统计参数,用这些参数时序上的变化来表征车辆经过检测窗的过程,进而对车辆进行计数。考虑到NCC统计参数对阴影具有很好的抑制作用,但是损失了亮度信息,并进一步又提出了一种改进算法,引入与亮度值相关的特征量进行亮度补偿,进一步提高算法鲁棒性。

近些年,深度学习目标检测算法在计算机视觉、图像识别领域得到了广泛的应用,文献[12]采用YOLOv3网络,利用one-stage算法实时性好的特点,对模型参数进行配置,实现车流量统计。文献[13]采用SSD目标检测模型,对原始SSD网络的区域候选框、损失函数等方面作了改进,进一步提高了车辆目标检测的准确性。但是深度学习目标检测算法的实时性和准确性一般都需要兼顾,因此需要进行反复试验。

本文研究了一种基于虚拟检测窗的行车计数算法,统计检测窗内特征值并生成时空累积图,监测通过虚拟检测窗的车辆,并结合基于深度神经网络^[14]的目标检测算法,对车辆遮挡、行人、自行车等干扰因素进行校正,达到统计车流量的目的。

1 算法设计

1.1 基础算法

1) 设置检测窗

摄像机一般架设于城市道路的正上方,高度一般在5~20 m,摄像头俯视于交通路面,检测范围主要设置在摄像头的正前方。考虑到实际的交通道路监控中,车辆并不是严格按照车道行走,特别是当有特殊情况如车辆超车或变换车道时,车辆一般没有在车道中央位置。为了避免这些情况引起的车辆漏检问题,即多车道共同开设一个检测窗。如图1所示,图1(a)为交通视频采集示意图,

图1(b)为虚拟检测窗设置方法。




图1 设置虚拟检测窗

2) 多车道车流量检测算法步骤

多车道车流量检测算法主要由5部分组成:

- (1)背景初始化:运用混合高斯建模方法提取初始背景;
- (2)图像预处理:主要完成虚拟检测窗设置、RGB图像灰度化、滤波平滑等操作;
- (3)特征值选择:对检测窗内进行分块处理,对子块图像分别计算NCC特征值,并将得到的NCC特征值进行加权水平投影,得到主统计量。具体做法是:把当前帧与背景图像的检测窗内图像都依次划分为若干子块,然后再对各子块分别求特征统计值,如图2所示。水平投影,得到对应的特征向量 N ,示意图如图3所示:将得到的各分块互相关归一化^[15](normalized cross correlation, NCC)特征值进行加权;




图2 分块计算特征值示意




图3 特征向量生成方法

(4)车辆计数:在步骤(2)和(3)的基础上,设定驶入和驶出阈值,依照统主统计量在时序上的变化情况进行车辆计数;

(5)背景更新:运用混合高斯模型^[16]进行背景更新。多车道车流量检测算法流程如图4所示。




图 4 算法流程图

3) 基于亮度比的辅助特征值

为了补偿 NCC 特征值中关于图像亮度信息方面的损失,引入与亮度值相关的特征量。特征统计量必须满足两个条件:(1)能有效区分背景和车辆;(2)必须要迎合背景和阴影的共同特性,即能把阴影归为背景那一类。其中第二个条件是关键,为了分析背景和阴影在灰度方面的相关性,做了以下仿真实验。图 5 中显示了含运动阴影的视频图像的分析结果,图 5(a)选取原先的大矩形框阴影区域,图 5(b)从算法中的分块计算角度出发,选取了图像小块阴影区域作为研究对象。图 5(c)和图 5(d)分别对应的是图 5(a)、图 5(b)阴影区域与各自背景的灰度比值分布图,横坐标表示阴影区域内各像素点,纵坐标表示对应灰度比值。




图 5 背景与阴影的灰度比值分析

从上图中可以明显看出,阴影区域阴影与背景灰度值一直保持比较稳定的振荡幅度,本文中采用新的基于亮

度比的辅助统计量 Ratio 来表征这种关系,具体表达式如式(1)所示。

$$\text{Ratio} = \text{std}_k \left(\frac{F(i,j)}{BG(i,j)} \right) \quad (1)$$

其中 $F(i,j)$ 表示当前帧检测窗内像素点灰度值, $BG(i,j)$ 为该像素点对应的背景灰度值,对于某分块计算的区域,均可通过上式计算该分块区域的辅助统计量 Ratio。加入基于亮度比的辅助统计值之后的时空累积图像 TS 的二值化过程如式(2)所示。

$$\text{TS} = \begin{cases} 255, & \text{前景} (\text{NCC} \leq \text{thresholdN}) \cup (\text{Ratio} \geq \text{thresholdR}) \\ 0, & \text{背景} (\text{NCC} > \text{thresholdN}) \cap (\text{Ratio} < \text{thresholdR}) \end{cases} \quad (2)$$

其中 thresholdN、thresholdR 分别是实验中设定的 NCC 特征值和 Ratio 特征值的阈值,只有同时满足这两个特征值条件时才被判定为背景,反之则为前景目标车辆。

1.2 基于时空累积图像的改进算法

1) 时空累积图像介绍

以上算法主要是针对当前帧图像的空间特征进行计算统计值的,而对图像的空间信息利用不足,并没有考虑到各相邻帧之间的相关性。为了把时序上的特征信息综合起来,本文提出了改进方法,即引进时空累积图像的概念。首先把每帧图像计算得到的特征向量作为当前帧图像的空间信息,依次作为时空累积图像的每一行值。按照时间顺序从上到下铺设,形成一个新的图像。该过程通过把单帧检测窗特征量累积成多帧特征量,由于对检测窗图像采用分块计算的方式,可有效提高算法抗干扰的性能。如图 6 显示的是由 200 帧图像生成的时空累积图像的示意图。




图 6 时空累积图像示意图(200 帧)

由于时空累积图像中包含了连续多帧视频图像的统计值空间和时间特征,可形象化描述了视频中运动车辆驶过检测窗的时序过程,再对时空累积图像二值化,通过基本的形态学处理和连通域分析,能更直观地对累积时间段内出现在检测窗区域中的车辆进行标记和计数。融入时空累积

图像后的改进算法流程如图 7 所示。




图 7 改进算法流程

2) 基于深度神经网络的目标检测算法的联通域计数校准

由于车辆相近时可能出现最终的响应图上的连通域粘连,导致连通域个数统计时出错,同时去除小的行人自行车等非统计目标的相应完全依赖经验取值。目前基于深度神经网络的目标检测算法,如 YOLO^[17]、SDD^[18]等,其准确性和速度已经达到了实用程度,YOLO 的识别速度甚至可以达到 50 帧/s,基于大量样本,可以轻松训练出能够识别车辆、人、自行车、电动车的模型,对画面中的所有车进行目标检测,然后仅取和检测框相交的 bbox,统计一段时间内,所有检测帧中保留的 bbox 的宽度,得到宽度的高斯分布。然后依据宽度的高斯分布,分别检查最终累积响应图中连通域的宽度。某一联通域的车辆计数 Num 计算公式如式(3)所示。

$$Num = \begin{cases} W/E, & (W \geq (E - 2 \times Std)) \\ 0, & (W < (E - 2 \times Std)) \end{cases} \quad (3)$$

其中, W 为该联通域的宽度, E 为 bbox 与检测框相交宽度的期望, Std 为标准差。若连通域宽度小于(期望-2×标准差),说明很可能是人、自行车、电动车等小目标干扰得到的联通域,不纳入连通域计数;若连通域宽度大于(期望-2×标准差),可能是一辆车的联通域,也可能是多个车辆重叠造成的联通域,为了得到合理的估计,将宽度除以期望,四舍五入得到整数,作为该连通域的数目。

为了减少运算量,避免对整张图片进行目标检测,本文设置一个能够覆盖虚拟检测窗的区域,作为目标检测区域。经试验,如图 8 所示,设置目标检测区域的宽度和虚拟检测窗一致,高度为虚拟检测窗的 3 倍,既满足目标检测的需要,又能有效减少运算量,效果较好。

3) 背景更新算法的改进

提取背景是该算法的基础,而运用混合高斯模型进行背景更新,其更新的时机不好掌握,依赖一些预设的统计性




图 8 目标检测区域设置

的经验参数,天气、光照条件的变化,都会影响其准确率。可以直接使用目标检测模型,持续对待检测区域检测,如果在一段时间阈值 T 内,没有检测到任何车辆、人、电动车等目标出现,即可进行背景更新。经测试,大部分场景下, T 设为 2 s 比较合适,若遇到车流量较大的场景,阈值可以适当减少。

2 实验结果及分析

本文实验环境如下:操作系统为 Windows XP,处理器为 AMD Athlon 2.81 GHz,2 GB 内存,英伟达 gtx1070 显卡,编程环境为 Visual Studio 2010+OpenCV 视觉库。为了验证本文中车流量检测算法的精确度和稳定性,选取南京市区内拍摄的几段交通场景视频(主要是白天的场景)作为测试对象,分辨率为 720×576 ,帧率为 25 帧/s。下文分别对各算法实验结果进行讨论。

2.1 实验结果与讨论

1) 三车道测试视频

测试视频图像如图 9 所示,按照初始设置好检测窗口,即可以进行车辆计数。由于算法中采用分块计算统计参数的方法,算法复杂度降低,使得算法的实时性能满足实际应用要求。本文以检测窗内图像作为研究对象,计算分块后各子块图像的反映背景帧与当前帧相似度的 NCC 统计参数,并将其量化后与色彩空间的颜色相对应,图 10(a) 显示了 3 种不同车型经过检测窗的特征值响应情况,图 10(b) 显示了从车辆驶入检测窗到完全驶出检测窗统计参数值的变化情况,车辆完全进入时统计值会有个峰值。本文车辆计数算法也是基于该统计值的特性而设计的,当检测窗区域没有出现车辆目标时,当前检测窗图像和背景图像很相似,则特征值响应较低;当检测窗出现车辆目标时,引起了检测窗图像的改变,随着车辆目标逐渐覆盖背景,当前帧与背景图像的差别会越来越大,特征值响应值幅度越高;当车辆完全驶出观测窗时,特征值响应值又恢复较小值。根据观测车辆进入和离开观测窗统计特征值的渐变过程,监控车辆的驶入驶出过程。从图 11 可以看出,该算法对车尾阴影有很好的抑制作用,当车辆马上离开检测窗时,此时的特征值响应已经很小了,车尾阴影并不会干扰车辆计数的过程。




图 9 三车道测试视频图像




图 10 统计特征值可视化效果图




图 11 消除车尾阴影影响示意图

2) 四车道测试视频

如图 12 显示了 4 种车型的车辆即将驶入检测窗区域时的特征统计值情况,由于受光照阴影,此时车头位置处的阴影比较强烈,投射在检测窗区域内。从特征统计值显示情况可以看出,此时车头处阴影得到了有效的抑制。图 13 显示了算法对邻道运动阴影干扰的处理效果,图 13(a)、图 13(b)中的虚线框内分别标记出了两种情况中邻道阴影区域对应的统计特征值情况,可以看出此时计算得到的特征值很小,对车辆计数不会产生干扰。图 14 显示了前后车分别经过检测窗时的情况,此时虚线框内统计特征值也被抑制得很小,表明前后车阴影不具有干扰作用,两车可以很好的区分开,很好地满足了车辆计数的实际要求。

2.2 改进算法实验结果

本文中在联合 NCC 特征值和 Ratio 特征值的改进方法基础上,结合得到的时空累积图对车辆视频进行车流量




图 12 4 种车型车头阴影抑制情况




图 13 处理邻道运动阴影干扰




图 14 处理前后车阴影干扰

检测。下面给出实验结果,选取两段拍摄自南京市玄武大道的交通视频如图 15 所示,图 15(a)和图 15(b)分别对应车辆行驶方向的两种情形。图 16(a)为该测试视频 1 的第 438 帧和 637 帧图像,作为图 16(b)、(c)时空投影图像的起始参照帧。图 16(b)是只采用 NCC 特征值的 200 帧时空累积二值化结果图像,图 16(c)是引入了 Ratio 特征值后改进之后的 200 帧时空累积二值化结果图像。可以看出,只采用 NCC 特征值时候往往得不到完整的车辆目标区域,由于计算特征值时损失了亮度信息,目标内部空洞或缺损现象比较严重,此时目标分割效果欠佳。而加入 Ratio 辅助

特征值之后,可以看出分割的二值图效果大大改善了,从图上可以清晰的分辨出车辆的运行区域,进而使得车辆计数的结果更加准确。




图 15 测试视频图像






图 16 测试视频 1 的时空累积二值化图像

同样取图 15(b)测试视频 2 进行实验,图 17(a)、(b)、(c)分别显示了各车型的时空响应图,都能较为准确的投射出运动车辆的运动形态,团块的大小与车型和车速都有直接关系,一般情况下在车速相近的情况下越大型的车辆投影得到的团块也越大。图 18 显示的是另外一种特殊情况下的累积图像响应图,即当车辆驶入检测窗区域时突然停止在该区域时,此时时空响应得到的并不是一个规则的团块,而是一长条响应区域,该响应区域会维持到车辆驶离检测窗为止。由于本文算法中是对独立团块进行计数,当车辆离开时再进行计数,因此这种情况并不会影响计数结果。

实际情况下电动车、自行车的数目不应该计入最终车流量中,因此算法中对获得的时空投影二值图像进行分析时,会根据联通域的面积大小进行筛选,如图 19(a)、(b)显示的是电动车对应的投影图中的团块,可以明显看出其面积很小。目标检测算法会统计车辆的宽度的高斯分布,若联通域宽度小于(期望 $-2 \times$ 标准差),说明很可能是人、自行车、电动车等小目标干扰得到的联通域,不纳入联通域计数。为了更好地验证本文算法在不同的天气和速度情况下的性能,选取了各个时间段的交通视频来对算法进行测试,



(a) 小型卡车时空响应图



(b) 中型卡车时空响应图



(c) 大型工程车时空响应图

图 17 其他类型车辆响应情况




图 18 驶入车辆静止的响应情况

并选取传统帧间法和光流法作为对比算法,测试结果如表 1、2 所示。




图 19 电动车干扰情形下的响应情况

表 1 天气晴好时的检测结果

车速天气 状况	采集 时间	实际 车流	时空累积算法		帧间差法		光流法	
			检测车流	准确率/%	检测车流	准确率/%	检测车流	准确率/%
车速小于 60 km/h 晴好天气	9:00	49 辆	47 辆	96	35	71	46	94
	12:00	62 辆	60 辆	97	47	76	59	95
	16:00	52 辆	48 辆	92	41	79	48	92
车速大于 60 km/h 晴好天气	9:00	66 辆	63 辆	95	62	94	52	79
	12:00	49 辆	45 辆	92	45	92	33	67
	16:00	72 辆	69 辆	96	70	97	57	79

表 2 阴雨天时的检测结果

车速天气 状况	采集 时间	实际 车流	时空累积算法		帧间差法		光流法	
			检测车流	准确率/%	检测车流	准确率/%	检测车流	准确率/%
车速小于 60 km/h 阴雨天气	9:00	43 辆	39 辆	91	27	63	25	58
	12:00	51 辆	47 辆	92	42	82	36	71
	16:00	58 辆	53 辆	91	49	84	39	67
车速大于 60 km/h 阴雨天气	9:00	71 辆	66 辆	93	67	94	45	63
	12:00	82 辆	77 辆	94	75	91	49	60
	16:00	69 辆	63 辆	91	61	88	57	83

由表格中的实测数据可以看出,优化的时空累积算法在不同的车速和天气条件下,车流量检测的准确率一般能达到 91% 以上,当天气晴好能见度较高的情况下准确率更理想,且算法处理速度也较快,在本文的测试硬件条件下处理速度约为 0.024 s/帧,完全能满足车流量检测系统的实时性要求。不同算法之间对比后发现,优化的时空累积算法在大部分情况下都优于帧间差法和光流法。帧间差法在车辆高速运动条件下效果较好,准确率接近时空累积算法,但因为无法检测低速或静止物体,导致低速条件下效果较差。光流法在低速且光照条件好时,准确率接近时空累积算法,但由于对光照条件要求较高,且计算量较大导致实时性差,在光照条件较差时或者车辆很多时,准确率较低。

3 结 论

本文以固定摄像机获取的交通视频作为研究对象,对

车流量统计算法进行了研究,本文在基于统计参数的行车计数算法基础上,创新性的构建了时空累积图,将前后帧间的特征值紧密联系起来,同时引入与亮度值相关的特征量,来补偿原 NCC 特征值中关于图像亮度信息方面的损失,提高了算法对外界环境干扰的鲁棒性。同时,引入基于深度神经网络的目标检测算法,对虚拟检测框附近的车辆宽度进行统计,得到其高斯分布,从而过滤掉严重偏移分布的数据,有效缓解车辆过近导致的漏数和经验值取不准导致小的行人自行车等被纳入统计的问题,本文对基于视频的车流量检测做了若干研究探索,取得了一定的成果。实验结果表明,本文算法准确率一般能达到 91% 以上,实时性好,能较好满足车流量检测系统的要求。但限于条件,本文没有在大雾、雪天等恶劣天气条件下进行实验,对夜晚时候的交通视频检测也未作涉及,在这些特殊条件下的算法适应情况需要进一步的研究和改进,力求寻找可全天候运行的检测算法;同时在处理车辆遮挡等情况

也值得进一步探究更好的解决方法,以保证算法有更广的适应性。

参考文献

- [1] 赵娜,袁家斌,徐晗. 智能交通系统综述[J]. 计算机科学, 2014, 41(11): 7-11.
- [2] 张增超,李强,孙红雨,等. 基于地磁传感器和 UWB 技术的停车位车辆检测方法与实践[J]. 传感技术学报, 2019, 32(12):159-164.
- [3] 吴志伟. 基于视频的车流量检测技术研究[D]. 广州: 华南理工大学, 2012.
- [4] 余辰,张丽娟,金海. 大数据驱动的智能交通系统研究进展与趋势[J]. 物联网学报, 2018, 2(1): 56-63.
- [5] 戚秀真,李娜. 基于视频的车流量统计算法[J]. 现代计算机, 2017(32):79-81.
- [6] 韩悦,金晖宏,郭旭,等. 视频序列中的运动目标检测算法研究[J]. 电子测量技术, 2019, 42(13): 103-106.
- [7] CAO B G. A new car-following model considering driver's sensory memory[J]. Physica A: Statistical Mechanics and Its Applications, 2015, 42(6): 218-225.
- [8] 夏婷,星烁,邹卫军. 动态背景下基于金字塔 LK 光流的运动目标检测[J]. 导航与控制, 2018, 71(17): 98-103.
- [9] 李伟业,车国霖,欧阳鑫. 李善超融合时空特征的自适应运动目标检测方法[J]. 电子测量技术, 2020, 43(23):84-89.
- [10] YU J, ZUO M. A video-based method for traffic flow detection of multi-lane road [C]. 2015 Seventh International Conference on Measuring Technology and Mechatronics Automation, IEEE Computer Society, 2015: 68-71.
- [11] YU J, ZUO M. A novel traffic flow detection method using multiple statistical parameters[C]. 2015 Seventh International Conference on Measuring Technology and Mechatronics Automation, IEEE Computer Society, 2015: 51-54.
- [12] 查伟伟,白天. 公路视频实时车辆检测分类与车流量统计算法[J]. 微型机与应用, 2020, 39(3):62-67,72.
- [13] 陈冰曲,邓涛. 基于改进型 SSD 算法的目标车辆检测研究[J]. 重庆理工大学学报(自然科学版), 2019, 33(11):64-69,135.
- [14] 张婷婷,章坚武,郭春生,等. 基于深度学习的图像目标检测算法综述[J]. 电信科学, 2020, 36(7): 92.
- [15] DEMIR H S, AKAGUNDUZ E. Filter design for small target detection on infrared imagery using normalized-cross-correlation layer[J]. 2020, 48(11): 287-298.
- [16] 马德智,李巴津,董志学. 基于高斯混合模型的运动目标检测方法研究[J]. 电子测量技术, 2013, 36(10): 47-50.
- [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] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. European conference on computer vision, 2016: 21-37.

作者简介

郁佳佳,工学硕士,讲师,主要研究方向为图像处理、计算机视觉、机器学习技术等。

E-mail:efujnh3999@163.com