

基于深度学习的无人机航拍车流量监测

牛康力 谌雨章 张龚平 谭前程 王绎冲 罗美琪

湖北大学计算机与信息工程学院 武汉 430062

(perfnkl@stu.hubu.edu.cn)

摘要 随着智慧城市概念的普及,交通道路智能化管理已成为学者关注的热点。针对道路的车流量统计问题,文中基于深度学习方法,提出了基于残差网络的无人机航拍车流量监测算法,该算法引入了全连接的多尺度残差学习分块(FMRB),在解决梯度弥散现象的同时使得图像特征能够被更好地提取和学习。现有的车辆检测算法准确率较低,且大多数仅能对车辆进行检测,不能对车流量进行统计。文章结合视频帧估计方法,实现了车流量的实时监测与统计。在车辆检测性能上将所提算法与SSD, YOLOv2, YOLOv3 算法进行对比,结果表明,在自建数据集训练的条件下,所提算法引入多尺度残差学习分块(FMRB)对遥感图像进行车辆识别,能够取得更高的识别精度;在实地车流量监测中,所得结果误检率小于1%,具有较强的实用效果。

关键词: 深度学习; 残差网络; 车辆识别; 车流量监测; 智能交通

中图分类号 TN911.73; TP183

Vehicle Flow Measuring of UVA Based on Deep Learning

NIU Kang-li, CHEN Yu-zhang, ZHANG Gong-ping, TAN Qian-cheng, WANG Yi-chong and LUO Mei-qi

School of Computer and Information Engineering, Hubei University, Wuhan 430062, China

Abstract With the popularization of the concept of smart city, the intelligent management of traffic road has become the focus of scholars. In order to solve the problem of road traffic statistics, this paper proposes a residual network based UAV aerial traffic flow measuring algorithm based on residual network. The fully connected multi-scale residual learning block (FMRB) is introduced into the method network to solve the gradient dispersion phenomenon and make the image features better extracted and learned. At present, the accuracy of the existing vehicle detection algorithms is low, and most of them can only detect the vehicle, and can not count the traffic flow. In this paper, combined with video frame estimation method, real-time monitoring and statistics of traffic flow is realized. Compared with SSD, YOLOv2 and YOLOv3 algorithms in vehicle detection performance, the results show that, under the condition of self built data set training, this method introduces multi-scale residual learning block (FMRB) for vehicle recognition of remote sensing image, and can achieve higher recognition accuracy. In the field traffic flow monitoring, the error detection rate is less than 1%, which has strong practical effect.

Keywords Deep learning, Residual network, Vehicle recognition, Traffic flow measuring, Intelligent transportation

1 引言

如今随着无人机技术的兴盛,无人机被广泛运用到资源勘探、防控侦查等领域,成为了解决行业需求的主要工具。目前有许多学者致力于无人机遥感技术的发展和运用。Yin等^[1]将无人机作为一个稳定的空中平台,提出了一种便携式、低成本、可重复的无人机辅助雷达定标技术,利用无人机携带金属球体,飞越雷达照明区域,完成天气雷达的校准。Zhang等^[2]针对卫星和无人机平台的抖动问题,提出了一种能自动从单一遥感影像中学习重要的场景特征的深度学习框架,利用网络对抖动方式进行估计,从对变形影像进行补偿和复原。针对农业中的植物病害问题, Tetila等^[3]将无人机拘技术运

用到农业,利用小型廉价无人机获取的大豆叶片病害图像,采用神经网络对叶片病害进行准确、自动的鉴定,有助于制定早期的防治措施,极大程度地减少了经济损失。

目标识别领域近年来也得到了极大的发展和提升。Yu等^[4]提出了一种自适应双阈值稀疏傅立叶变换(ADT-SFT)算法,能够在杂波背景下进行运动目标检测。仿真分析和实测海杂波数据表明,ADT-SFT算法适合杂波背景,有较好的检测性能;与传统的子空间检测(SD)算法相比,ADT-SFT算法只需搜索少量的可疑目标多普勒频率即可建立检测器,降低了计算复杂度。Ao等^[5]提出了一种手写字符识别的跨模式原型学习(CMPL)方法,能够对手写字体进行精确识别。Santra等^[6]提出了一种车辆识别方法,能够从实时捕获的图

基金项目:教育部产学合作协同育人项目(201802153126);湖北省自然科学基金面上项目(2019CFB733);大学生创新创业训练计划项目(湖北省级 S201910512024,国家级 202010512020);湖北大学楚才学院科研立项(20192222011)

This work was supported by the Ministry of Education Industry University Cooperation Collaborative Education Project(201802153126), General Project of Natural Science Foundation of Hubei Province (2019CFB733), Innovation and Entrepreneurship Training Program for College Students (Hubei Provincial S201910512024, National Level 202010512020) and Research Project of Chucai College of Hubei University(20192222011).

通信作者:谌雨章(hubucyz@foxmail.com)

像中检测出移动的车辆,检测某个点上存在于道路的车辆数量,并分析任何交通信号灯在任何指定时间点的车辆密度。

随着“智慧城市”概念的普及与推广,城市交通的智能化发展作为智慧城市的核心模块,成为了亟待解决热点难题。如何在复杂场景下进行车辆识别和车流量检测成为许多学者关注的重点问题之一。无人机作为体积小巧、灵活性高的新型工具,能够广泛拍摄当前路段的车辆信息并进行随航监控,因此利用无人机遥感图像进行车流量的测算与监控成为当前智慧城市交通范畴的重点研究方向之一,具有极为广阔的应用前景。

目前,道路通常采取固定摄像头进行录像以及车辆检测,并用相应的算法进行测算,记录相应时间段内车流量大小。但是这种方法存在许多弊端与缺陷:1)从硬件方面来说,普通摄像头位置固定,只能从单一位置对道路情况进行拍摄,拍摄范围具有局限性;2)从软件方面来说,上述大多数车辆检测与车流量监测算法仅仅依赖传统算法模型,对于高速移动的车辆极易产生检测错误、目标遗失等问题,算法的实时性和准确性都有待提高和改进。

随着卷积神经网络的不断发展,许多强力的目标识别模型陆续被提出,利用深度神经网络代替手工构建特征进行目标识别正成为学者关注的热点。Nasrabadi等^[7]提出了一种基于深卷积神经网络的自动目标识别方法。这些深度学习方法随着如今数据量的增长与算力的增强,能够更好地适用于

实际场景,并且拥有更高的准确度。Mou等^[8]提出了一种基于改进的快速R-CNN的海洋目标检测方法,通过对不同条件下雷达实测数据的采集,建立了自己的海上目标数据集,并基于Faster R-CNN建立了自己的目标检测方法。He等^[9]提出了一种基于光级卷积神经网络的雷达图像目标识别方法,并利用卷积特征提出了一种无监督检测方法,结果表明该方法在分类任务中获得了较高的精度,有效地实现了无监督目标检测。

为了更好地将深度学习目标识别算法与无人机技术相结合,本文使用无人机代替道路摄像头进行航拍,从而扩大拍摄广度,摆脱拍摄范围限制的困境;之后利用残差学习网络对车辆图像进行训练与学习,能够对航拍视频中的车辆进行识别与检测;最后,将视频帧估计方法与残差学习网络相结合,构成本文的车流量智能检测系统。视频帧预测技术不仅提高了深度学习网络检测的精度和准度,也使其能够对相应时间段内的车流量进行统计,大大降低了目标漏检的风险,提高了检测的进度和准度,达到了“智慧城市”中车流量监测的目的。

2 本文方法

2.1 基于残差网络的车辆识别模型

基于无人机遥感图像分辨率高、探测范围广的特点,本文建立了基于残差网络的车辆识别方法,对遥感图像中的车辆进行识别和检验,具体的网络结构如图1所示。




图1 具体的网络结构图

Fig. 1 Network structure of vehicle measuring

本文模型将未经处理的遥感图像作为输入,通过网络处理获取车辆检测结果。模型的结构主要包括:1)提取LR低层信息的卷积层,由一个conv组成;2)用于学习高层信息的多尺度残差学习网络,包含32个全连接多尺度残差分块(FMRB);3)用于层次特征融合的瓶颈层,由1个Bottleneck组成;4)包含1个NMS的目标检测层。其中FMRB为本文提出的全连接多尺度残差分块,能够对图像信息进行多尺度的分解和提取,使得网络能够获得更好的学习效果。现有的基于深度学习的目标识别算法的网络深度较浅,不能对图像信息进行较好的提取,而本文算法具有更深的网络深度,由32层FMRB组成的多尺度残差学习网络能够使处理后的图像具有更好的识别效果。同时对于普通深度学习网络由于层数过多引起的梯度弥散现象,本文网络通过FMRB中各个单元全连接的方式,完美避免了弥散问题,同时也降低了计算的复杂度,大大提升了网络的运行效率。

2.2 图像特征的提取

残差网络对遥感图像的特征提取主要由两部分组成:层次特征融合结构(HFFS)和全连接多尺度残差分块(FMRB)。

文献^[10]指出,随着网络深度的增加,网络对图像的重建

能力会越好。但是如果由于网络的弥漫现象导致随着网络深度的增加,图像特征在传输过程中逐渐消失,重建的效果则不如浅层的网络结构。在这一问题的驱使下,许多学者提出了相应的解决方法,其中最为简单的解决方法是建立密度连接的卷积神经网络(如文献^[11]),这种方法使得网络中任意的两层都有直接连接,每一层的输入都是之前所有层的并集,有效解决了梯度弥散现象。但是这种方法不能充分利用输入图像的特征,并且在处理时会产生过多的冗余信息。

本文提出了多尺度的残差学习网络,不仅通过残差分块的方式有效解决了梯度弥散问题,在分块中也同样采取了全连接的方式,使图像信息能够受到不同尺度卷积层的处理和提取,有效地避免了上述方法不能充分利用图像信息的问题。并且对于信息冗余现象,本文提出了一种简单的层次化特征融合结构,引入一个以 1×1 的卷积核为结构关键的瓶颈层,从所有层次特征中自适应地提取有用的信息,极好地解决了信息冗余的问题,减少了网络计算的复杂度。层次特征融合结构(HFFS)的输出可以表示为:

$$F_{LR} = \omega * [M_0, M_1, M_2, \dots, M_N] + b \quad (1)$$

其中, M_0 是第一卷积层的输出, M_i 表示第*i*个FMRB的输

出, $[M_0, M_1, M_2, \dots, M_N]$ 表示级联操作。

全连接多尺度残差分块(FMRB)能够学习不同卷积下图像的特征,充分利用了图像的信息,其结构如图2所示。FMRB包含两部分:多尺度特征融合和局部残差学习。




图2 全连接多尺度残差分块(FMRB)的结构图

Fig. 2 Fully connected multiscale residual block

对于多尺度特征融合,我们构造了一个双旁路网络,不同的旁路使用不同的卷积核。这样,这些旁路之间的信息可以相互共享,从而能够检测出不同尺度下的图像特征。可以用公式表示为:

$$\begin{cases} A_1 = \delta(\omega_{3 \times 3}^1 * M_{n-1} + b^1) \\ A_2 = \delta(\omega_{3 \times 3}^2 * [A_1, B_1] + b^2) \\ A_3 = \delta(\omega_{3 \times 3}^3 * [A_1, A_2, B_1, B_2] + b^3) \\ B_1 = \delta(\omega_{5 \times 5}^1 * M_{n-1} + b^1) \\ B_2 = \delta(\omega_{5 \times 5}^2 * [A_1, B_1] + b^2) \\ B_3 = \delta(\omega_{5 \times 5}^3 * [A_1, A_2, B_1, B_2] + b^3) \\ S' = \omega_{1 \times 1}^3 * [A_3, B_3] + b^4 \end{cases} \quad (1)$$

$$S' = \omega_{1 \times 1}^3 * [A_3, B_3] + b^4 \quad (2)$$

其中, ω 和 b 分别表示权重和偏差,上标表示它们所在的层的数量,下标表示该层中使用的卷积核的大小。其中 $\delta(x) = \max(0, x)$ 表示 ReLU 函数, $[A_1, B_1], [A_1, A_2, B_1, B_2]$ 表示这些特征图像的融合。 M 表示发送到 FMRB 的特征映射的数量。因此,第一卷积层的输入和输出具有 M 个特征映射,第二卷积层有 $2M$ 个特征映射,这些特征映射被连接起来并发送到 1×1 卷积层。该层将这些特征映射的数目减少到 M ,因此 FMRB 的输入和输出具有相同数目的特征映射,这种体系结构使得多个 FMRB 能够同时使用。

对于局部残差学习部分,为了提高网络的效率,我们对每个 FMRB 都采用残差学习,在形式上,全连接多尺度残差分块(FMRB)可以表示为:

$$M_n = S' + M_{n-1} \quad (3)$$

其中, M_{n-1} 和 M_n 分别代表 FMRB 的输入和输出, $S' + M_{n-1}$ 通过在各个元素间快捷连接而执行,这种局部残差学习的方法使得计算的复杂性大大降低,同时也提高了网络对图像特征的提取性能。

3 基于视频帧估计的目标配准

本节提出了基于视频帧估计的目标配准方法,利用残差学习网络进行目标检测,结合前一帧的目标位置,对当前帧目标的位置做出判断和匹配;对于丢失的目标,将结合前两帧进行目标运动估计,得出目标候选项,最后根据特征的相同性进行目标匹配,实现对丢失目标的重新找回,避免相同车辆多次计数,从而达到车流量统计的目的和效果。基于视频帧估计目标配准的具体框架结构如图3所示。

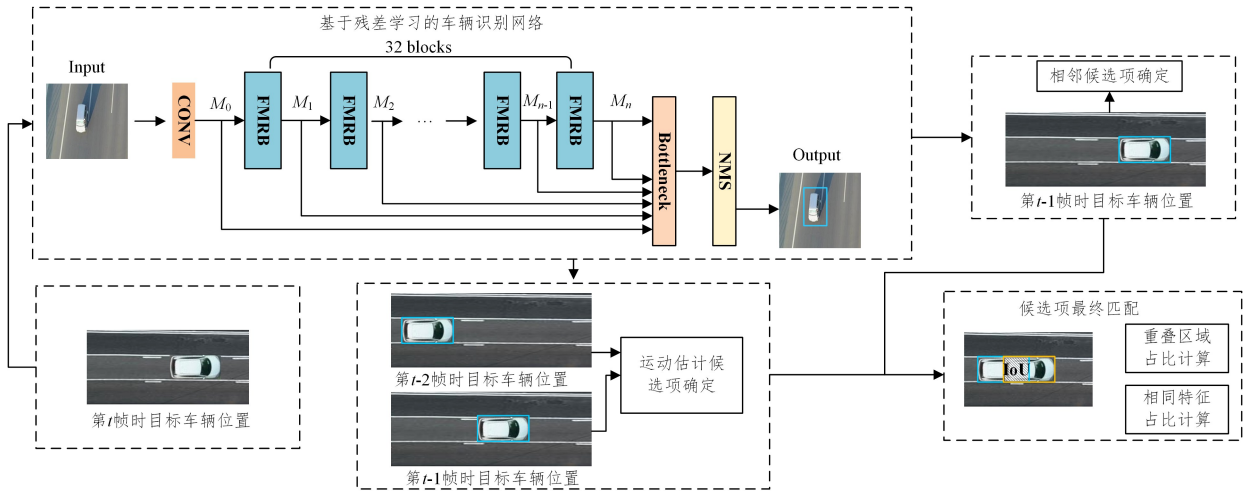


图3 基于视频帧估计的目标配准框架结构

Fig. 3 Structure of target registration based on video frame estimation

3.1 基于前一帧的相邻候选项确定

如今无人机拍摄视频每帧的播放时间大约 26 ms,同时由于无人机拍摄位置较高,一般情况下拍摄对象在图像上的位移不会太大,相同目标对应的检测框之间具有较大的重叠。因此结合前一帧车辆的位置,可以根据其相邻目标的临近程度作出相应的匹配与判断。对于“临近程度”指标的衡量,本文通过交并比(Intersection over Union)进行判断和比较,其定义为:

$$IoU = \frac{A(T_n) \cap A(T_{n-1})}{A(T_n) \cup A(T_{n-1})} \quad (3)$$

其中, T_n 和 T_{n-1} 分别表示对应车辆目标在第 n 帧的检测框和在第 $n-1$ 帧的检测框, $A(T_n)$ 和 $A(T_{n-1})$ 分别表示其检测框对应的面积区域,具体如图4所示。其中,黄色区域代表目标车辆在第 n 帧的检测区域,即 $A(T_n)$,蓝色区域代表目标车辆在第 $n-1$ 帧的检测区域,即 $A(T_{n-1})$ 。具有重叠区域的检测框会成为对相应目标的候选匹配项。




图4 基于前一帧的相邻候选项确定(电子版为彩色)

Fig. 4 Adjacent candidate determination based on previous frame

3.2 基于前两帧的运动估计目标匹配

本文提出基于前两帧的目标运动匹配法,通过目标前两帧的位移距离,判断当前帧在可能出现的位置,从而得到新的候选匹配项。根据前两帧的目标位置,当前帧的估计位置可以表示为:

$$I(x_t, y_t) = I(x_{t-1} + \Delta x, y_{t-1} + \Delta y) \quad (4)$$

$$\begin{cases} \Delta x = x_{t-1} - x_{t-2} \\ \Delta y = y_{t-1} - y_{t-2} \end{cases}$$

其中, $x_i, y_i (i < t)$ 为第 i 帧时目标框对角线中心距左边界的距离和距下边界的距离。 Δx 和 Δy 分别为目标在前两帧相距左边界的距离差以及相距下边界的距离差。 $I(x_t, y_t)$ 为当前帧的目标预测区域,区域大小与前一帧的检测框大小相同。与预测区域具有交集的检测框均成为匹配候选项。检测框与预测区域的重叠面积可以表示为:

$$IoU = \frac{A(T_n) \cap FA}{A(T_n) \cup FA} \quad (5)$$

其中, FA 表示当前帧的目标预测区域。具体的目标运动估计匹配示意图如图5所示,蓝色检测框即为匹配候选项。




图5 基于前两帧的目标运动估计(电子版为彩色)

Fig. 5 Target motion estimation based on the first two frames

3.3 匹配候选项的最终确定

未离开的目标在通常情况下存在一个或多个候选项,确定最终的匹配结果成为关键。此时需要结合区域交并比,交并比越大,匹配的概率越大。通过系统进行目标特征匹配,相同特征越多的目标候选项成功匹配的概率越大。具体的公式表达如下:

$$FP = \frac{SF}{AF} \quad (6)$$

$$MP = \frac{IoU + FP}{2} \quad (7)$$

其中, SF 表示相同的特征数, AF 表示总共的特征数, FP 表示相同特征在总特征中的占比, MP 表示成为确定匹配项的概率。 MP 最高的候选项将与目标成功匹配。若通过上述两种方法仍旧没有匹配候选项,则判断目标离开。若有多余的

检测框无法与前一帧目标进行匹配,则判断为新目标出现。

4 实验过程与结果分析

本文自建数据集,分别进行了3组实验:1)单张图片实验,使用自建数据集中的图片进行车辆的识别与检测,观察标记结果,主观判断网络的检测能力;2)视频实验,通过VIS-Drone公共数据集所提供的视频进行检验,测量标记精确度、召回率、平均精度以及检测速度,比较4种方法的性能优劣;3)实地实验,通过在武汉市内4地进行实地飞行,通过实时传输,测量当前区域的车流量,检测算法的实用性。

4.1 自建数据集的建立与训练过程

对于车辆识别的残差学习网络,我们通过自建数据集的方式进行网络的训练。为保证实验数据的多样性,我们使用大疆御2 pro(Mavic 2 Pro)在武汉市内多处进行遥感车辆图片的采集。经过后期挑选,我们排除了清晰度低、模糊失焦的图片,从而选取了7000张清晰度高、成像质量好的车辆遥感图像,并从公共数据集UAVDT^[12]中添加了1000张遥感车辆图像。最后,我们通过随机旋转、水平翻转、随机裁剪等数据增强方法,对已有数据集进行扩充,最终得到了含有10000张图像自建数据集。我们将这10000个数据样本分成10组,每组含有1000个样本,采用交叉训练的方法投入网络中进行训练,即每一轮训练都会选取9组样本对作为训练集,剩下的1组将用作测试集,并用其对网络参数进行调节,每一轮的测试集都不同,以此种方式循环10轮,构成了交叉训练。通过此方式能有效地筛选出对网络训练更有利的数据集,防止因为部分训练集效果不佳而对网络整体效果产生影响。经过10轮交叉训练,本文网络取得了良好的训练效果效果,PSNR值达到了32.10 db,具体的交叉训练结果如图6所示。




图6 交叉训练结果

Fig. 6 Cross training results

4.2 实验配置

本实验的训练平台为:操作系统为Ubuntu 14.04,CPU为Core i7-7700K(Quad-core 4.2 GHz),显卡为NVIDIA GTX 1080ti。训练测试平台为CUDA8.0,cuDNN5.1,Pytorch0.4,python3.6。在主要参数学习率的设置上,本文采用的是学习率衰减的办法,这样能有效防止训练时间过长。设定初始学习率为0.001,每迭代100000次,学习率降为原来的1/10,采用随机梯度下降法(Stochastic Gradient Descent,SGD)对网络进行训练。

4.3 评价指标的选取

本文分别从检验速度和检验精度两方面对不同视频检测方法及进行对比和评估。其中,检测速度主要通过相应方法每秒处理的帧数进行衡量。检验精度主要使用精确率(Precision)、召回率(Recall)和平均精度(Average Precision)3个指

标来进行判断,具体的数学表达式如下:

$$P = \frac{TP}{TP + FP} \quad (8)$$

$$R = \frac{TP}{TP + FN} \quad (9)$$

其中, P 表示精确率, R 表示召回率, TP 表示识别正确的正样本, FN 表示识别错误的负样本, FP 表示错误的负样本。

由于改变检测阈值时,精确率和召回率变化趋势大体上总是相反,而平均精度却解决了精确度、召回率的局限性,能够全局反映检测方法的精准度,可以表示为:

$$AP = \int_0^1 P(R) dR \quad (10)$$

4.4 实验结果

我们首先进行公自建数据集实验,通过自建数据集中的无人机遥感图像进行车辆入侵检验和图像测试,观察标记结果,主观判断网络的检测能力。具体检测结果如图7所示。

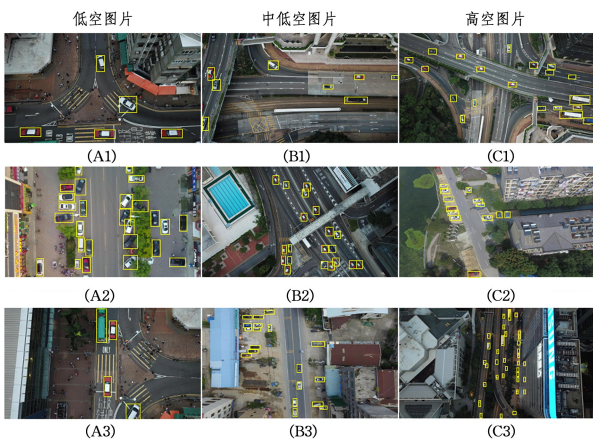


图7 本文方法对于车辆的检测结果

Fig. 7 Vehicle detection results of proposed method

从图7检测结果可以看到,除了图像边界的部分车辆难以识别以外,其余车辆均被正常识别,可见本文网络对于车辆检测的准确性较高。并且,无论是较近场景中尺寸较大的车辆还是较远场景中尺寸极小的车辆,都能够被本文网络所检测,由此说明改进后的模型可以极好地适应目标尺度的变化,能够对不同尺度大小的特征进行有效的提取和分析。但是由图(C3)中的检测结果可知,部分玻璃上的车辆倒影也被网络误检,使得结果存在一定的误差。

以上仅仅是使用单张图片进行效果与检测,网络在视频中的检测性能仍有待考证。为了更加公正客观地评价本文方法,我们选取 VisDrone 公共数据集所提供的测试视频,在相同的实验条件下选取 SSD^[13],YOLOv2^[14],YOLOv3^[15] 3种方法进行对比。表1列出了不同方法对于测试视频的检验结果。

表1 不同方法检测结果对比

Table 1 Comparison of detection results of different methods

检测方法	$P/\%$	$R/\%$	$AP/\%$	检测速度/(帧/s)
SSD	73.56	33.28	65.33	22.19
YOLOv2	74.12	32.14	67.21	35.56
YOLOv3	83.66	26.52	78.87	28.77
Proposed	91.02	18.82	85.02	27.21

由表1可得,在评价指标上,本文精度均值比YOLOv2高出了18个百分点,比YOLOv3高出了6个百分点;在精确

度和召回率上,本文方法也都优于其他3种方法,体现了本文方法对于车辆目标检测的高准确性。对于检验速度,由于本文提出的网络结合了帧估计算法,所以使目标的检测时间有所降低,其虽然慢于YOLOv2和YOLOv3,但是也能起到实时检测的作用,对于实际使用并无影响。综合来看,本文方法检验效果最好。

为了测验本文方法对于车流量监测的准确度,我们避开了无人机禁飞区,于2020年6月19日分别在湖北省宜昌市兴山县内4地进行实地录像,并进行实时传输分析,每次实验航行拍摄时长为90min。我们对4地的车流量进行了统计,相关的结果如表2所列。

表2 现场实验结果

Table 2 Field experiment results

地点	时间	统计车流量	实际车流量	误检率/%
地区1 昭君路	9:00-10:30	1226	1219	0.5709
地区2 湖南路	11:00-12:30	1568	1566	0.1206
地区3 桂苑路	13:00-14:30	1385	1382	0.2166
地区4 龙珠路	15:00-16:30	892	891	0.1121

其中实际车流量为后期人工统计获得,根据计算结果可以看出本文方法车流量的误检率均处于1%以内,具有较高的准确性和实时性,能够起到极强的实用效果。

结束语 本文通过构建深度残差学习网络,能够适应无人机遥感图像的尺度变换特性,具有极好的车辆检测效果。通过将视频帧处理技术与监测网络相融合,利用相邻匹配和运动估计匹配法,将视频中相同车辆进行了准确匹配,避免了“一车多计”的情况,达到了车流量监测的实用效果。

如今,随着“智慧城市”概念的普及,交通道路的智能化管控将成为关注热点。虽然本文提出的网络模型基于遥感视频图像能够对车辆进行准确实时且全方位的检测,但是由于部分楼房玻璃的反光效果,使得车辆的倒影被网络误检,使得检验存在一定的误差。因此如何消除倒影检验误差,将是我们后续研究的重点。

参考文献

- [1] YIN J, HOOGEBOOM P, UNAL C, et al. UAV-Aided Weather Radar Calibration [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(12): 10362-10375.
- [2] ZHANG Z X, IWASAKI A, XU G. Attitude Jitter Compensation for Remote Sensing Images Using Convolutional Neural Network [J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(9): 1358-1362.
- [3] TETILA E C. Automatic Recognition of Soybean Leaf Diseases Using UAV Images and Deep Convolutional Neural Networks [J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(5): 903-907.
- [4] YU X, CHEN X, HUANG Y, et al. Radar Moving Target Detection in Clutter Background via Adaptive Dual-Threshold Sparse Fourier Transform [J]. IEEE Access, 2019, 7: 58200-58211.
- [5] AO X, ZHANG X, YANG H, et al. Cross-Modal Prototype Learning for Zero-Shot Handwriting Recognition [C] // 2019 International Conference on Document Analysis and Recognition (ICDAR). Sydney, Australia, 2019: 589-594.
- [6] SANTRA S, ROY S, SARDAR P, et al. Real-Time Vehicle De-

tection from Captured Images[C]//2019 International Conference on Opto-Electronics and Applied Optics (Optronix), Kolkata, India, 2019: 1-4.

- [7] NASRABADI N M. DeepTarget: An Automatic Target Recognition Using Deep Convolutional Neural Networks [J]. IEEE Transactions on Aerospace and Electronic Systems, 2019, 55(6): 2687-2697.
- [8] MOU X, CHEN X, GUAN J, et al. Marine Target Detection Based on Improved Faster R-CNN for Navigation Radar PPI Images [C]//2019 International Conference on Control, Automation and Information Sciences (ICCAIS). Chengdu, China, 2019: 1-5.
- [9] HE H, WANG S, YANG D, et al. SAR target recognition and unsupervised detection based on convolutional neural network [C]//2017 Chinese Automation Congress (CAC). Jinan, 2017: 435-438.
- [10] HE K, 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.
- [11] CHEN L B, CHEN Y Z, WANG X C, et al. Underwater image super-resolution reconstruction method based on deep learning [J]. Application Research of Computers, 2019, 39(9): 2738-2743.
- [12] DU D, QI Y, YU H, et al. The unmanned aerial vehicle benchmark: Object detection and tracking [C]//Proceedings of the

European Conference on Computer Vision. Berlin: Springer, 2018: 370-386.

- [13] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single Shot MultiBox Detector [C]// European Conference on Computer Vision. Springer, Cham, 2016.
- [14] REDMON J, FARHADI A. YOLO9000: Better, Faster, Stronger [C]//IEEE. 2017: 6517-6525.
- [15] REDMON J, FARHADI A. YOLOv3: An Incremental Improvement [J]. arXiv: 1804. 02767, 2018.



NIU Kang-li, born in 2000, postgraduate. His main research interests include artificial intelligence and image processing.




CHEN Yu-zhang, born in 1984, Ph. D., associate professor. His main research interests include laser and LED in water, night vision or underwater scattering medium radiation transmission theory and computer simulation, image acquisition and restoration and reconstruction algorithms, image processing algorithms embedded including the research of Android development.

(上接第 274 页)

- [20] FREUND Y, SCHAPIRE R E. A decision-theoretic generalization of on-line learning and an application to boosting [J]. Journal of Computer and System Sciences, 1997, 55(1): 119-139.
- [21] WANG L L. Research on Ensemble Learning Algorithm [D]. Guangxi University, 2006.
- [22] SHEN X H, ZHOU Z H, WU J X, et al. Survey of Boosting and Bagging [J]. Computer Engineering and Applications, 2000, 12: 31-32, 40.
- [23] ATANASSOV K T. On Intuitionistic Fuzzy Sets Theory [M]. Springer Berlin Heidelberg, 2012.
- [24] XU X S. Approaches to Multiple Attribute Decision Making with Intuitionistic Fuzzy Preference Information [J]. Systems Engineering-Theory & Practice, 2007, 11: 62-71.
- [25] XU Z S, SUN Z D. A Method Based on Satisfactory Degree of Alternative for Uncertainly Multi-Attribution Decision-Making [J]. Systems Engineering, 2001, 3: 76-79.
- [26] XU Z. A survey of preference relations [J]. International Journal of General Systems, 2007, 36(2): 179-203.
- [27] BUSTINCE H, PAGOLA M, MESIAR R, et al. Grouping, Overlap, and Generalized Bientropic Functions for Fuzzy Modeling of Pairwise Comparisons [J]. IEEE Transactions on Fuzzy Sys-

tems, 2012, 20(3): 405-415.

- [28] XU Z. Intuitionistic preference relations and their application in group decision making [J]. Information Sciences, 2007, 177(11): 2363-2379.
- [29] MOU Q, XU Z S, LIAO H C. A graph based group decision making approach with intuitionistic fuzzy preference relations [J]. Computers & Industrial Engineering, 2017, 110: 138-150.
- [30] DUA D, GRAFF C. UCI Machine Learning Repository [D]. School of Information and Computer Sciences, 2017.



DAI Zong-ming, born in 1995, postgraduate. His main research interests include text classification and fuzzy decision.



GUO Ya, born in 1977, Ph.D., professor, Ph.D supervisor. His main research interests include system modeling and control, and deep learning.