

基于视频深度学习的铁路周界入侵 检测算法研究

王 瑞¹, 李霄峰², 史天运^{*3}, 邹 琪²

(1. 中国铁道科学研究院研究生部, 北京 100081; 2. 北京交通大学 轨道交通与数据挖掘
北京市重点实验室, 北京 100044; 3. 中国铁道科学研究院集团有限公司, 北京 100081)

摘 要: 基于视频智能分析的铁路周界入侵检测算法相比于雷达、振动光纤, 具有成本低、误报率低的优点。针对视频中存在不同分辨率目标的问题, 提出一种改进的Cascade Mask R-CNN(CMR)模型, 使用级联结构获得目标的准确定位。为增强模型对小目标的检测能力, 在原始模型的基础上, 增加基于特征金字塔网络(FPN)的多尺度特征提取模块和基于空洞金字塔汇聚(ASPP)子网络的空间上下文增强模块。在实际铁路周界入侵场景视频中验证了模型的有效性。结果表明, 该模型可实现不同场景下的铁路周界入侵检测, 相较于原始模型, 新模型对小目标检测的F-measure提高了0.24。模型既解决了不同场景下铁路周界入侵检测问题, 又有效地提高了视频智能分析对小目标检测的准确率。

关键词: 铁路运输; 视频智能分析; 深度学习; 周界入侵检测; 特征金字塔; 空洞卷积

Railway Perimeter Intrusion Detection Algorithms Based on Video Deep Learning

WANG Rui¹, LI Xiao-feng², SHI Tian-yun³, ZOU Qi²

(1. Graduate School of China Academy of Railway Science, Beijing 100081, China; 2. Beijing Key Laboratory of Rail Transit and Data Mining, Beijing Jiaotong University, Beijing 100044, China; 3. China Academy of Railway Sciences Corporation Limited, Beijing 100081, China)

Abstract: Compared with radar and vibration optical fiber, the railway perimeter intrusion detection algorithm based on video intelligent analysis has the advantages of low cost and low false alarm rate. Aiming at the simultaneous detection of large and small targets in videos, this paper proposes an improved Cascade Mask R-CNN (CMR) model. The model uses the cascaded structure to locate the target accurately. At the same time, a multi-scale feature extraction model is added to the original model to enhance the expressive ability for small targets. Multi-scale module is implemented by feature pyramid networks (FPN). The spatial context enhancement module is implemented through an atrous spatial pyramid pooling (ASPP) subnetwork. The effectiveness of the proposed model was verified by the actual railway scene videos. The results show that the new model improves the F-measure of small targets detection by up to 0.24 compared with the original model. The proposed model enhances the detection capability of railway perimeter intrusion in different scenarios, and improves the accuracy of video detection for small targets.

Keywords: railway transportation; video intelligent analysis; deep learning; perimeter intrusion detection; feature pyramid networks; atrous spatial pyramid pooling

收稿日期: 2019-10-23

修回日期: 2019-12-19

录用日期: 2019-12-30

基金项目: 中国国家铁路集团有限公司科技研究开发计划/Science and Technology Research and Development Program of China National Railway Group Co., Ltd.(K2018T002, SY2017-T001).

作者简介: 王瑞(1985-), 男, 山西太原人, 副研究员, 博士生.

*通信作者: tyshi@rails.cn

0 引言

截至2018年底,我国高速铁路运营里程已超过2.9万km,随着路网规模的扩大和列车运行速度的不断提高,列车运行安全被提到了新高度.高铁周界入侵事件时有发生,严重威胁列车运行安全,周界入侵主动防范能力还有待进一步加强.高铁沿线布设有综合视频监控系统,如何利用现有资源对周界入侵行为进行有效地防范是高铁周界安防一个行之有效的解决思路,而基于视频的目标检测算法是视频用于铁路周界入侵检测的核心.

基于视频的周界入侵检测受光线、天气、相机抖动、动态背景等情况影响,传统算法很难同时有效处理各种不同情况^[1-5],提出一种改进的Cascade Mask R-CNN,使用目标检测的方法检测铁路周界入侵.铁路沿线综合视频监控系统摄像头设置距离较远,视频中会出现大量的小目标,很容易对其产生漏检的情况,故在原始模型中增加基于特征

金字塔网络(FPN)提取多尺度特征,同时增加基于空洞金字塔汇聚(ASPP)子网络增强空间上下文信息,改进的模型将多尺度特征与上下文信息融合,增强了模型对小目标的表达能力.

1 基于Cascade Mask R-CNN的视频周界入侵检测

传统基于视频的目标检测算法(如运动前景检测方法)极易受到现实因素影响:相机抖动,如图1所示;动态背景,即风吹动树叶等,如图2所示;目标间歇运动,如图3所示.图1~图3分别给出3种情况下,经典的运动前景检测算法(Lobster^[6], PAWCS^[7], Subsence^[8])的结果,其中白色区域表示运动前景,当检测结果中存在白色区域时报警.可见,传统的运动检测方法在相机抖动和动态背景的情况下会产生大量的误检,在目标间歇运动的情况下会产生大量漏检.




图1 运动目标检测在相机抖动问题上的表现

Fig. 1 Performance of moving target detection algorithm on camera jitter




图2 运动目标检测在动态背景问题上的表现

Fig. 2 Performance of moving target detection algorithm on dynamic background




图3 运动目标检测在间歇运动问题上的表现

Fig. 3 Performance of moving target detection algorithm on intermittent movement

为改善传统方法对现实因素的鲁棒性,提出基于深度学习的方法进行周界入侵检测,使用检测准确性及稳定性都较高的CMR(Cascade Mask

R-CNN)^[9]网络作为基础网络.为更好地检测小目标,在网络中加入特征金字塔网络和空洞卷积,融合多尺度特征与上下文信息.本文算法总的框架

结构如图4所示.




图4 基于改进CMR的铁路周界入侵检测框架图

Fig. 4 Overall framework for railway intrusion detection based on improved CMR

1.1 基于金字塔网络的小目标增强

铁路综合视频中存在着不同分辨率的行人,最小的行人约为 $9\text{ pixel} \times 15\text{ pixel}$ 的分辨率(约占整个图像的 0.0065%),故在基于视频的周界入侵检测中如何解决多尺度的问题成为一个关键,尤其是针对小分辨率对象的检测.原始的 Cascade Mask R-CNN 只利用基础网络得到最上层的特征,如图5中的F4,忽略底层特征,丢失了很多细节信息和小目标的位置信息.本文在原始模型中增加特征金字塔网络FPN,以关注不同尺度的图像特征,更好地保留不同分辨率目标的细节和位置信息.具体过程如图5所示:首先,通过基础网络resnet101的前向计算得到多尺度的特征{F1, F2, F3, F4};然后,采用自上而下的方式对上面的特征进行上采样,通过横向连接进行融合来增强特征.以P2和F1融合得到P1为例,图5中虚线部分所示,经过2倍上采样的P2与经过 1×1 卷积的F1通过像素间做加法融合方式得到P1.这样自下而上再自上而下的方法得到最终的特征图{P1, P2, P3, P4, P5}.最终FPN模块输出的特征图为融合了多个尺度特征的P1.

1.2 基于空洞卷积的上下文信息增强

空洞卷积也称为扩张卷积,基本出发点是扩大视野,而不增加学习参数的数量.在卷积层中引

入“扩张率”,表示卷积核进行卷积操作处理数据时的间距.使用该结构是由于pooling层会导致信息损失,而该结构可以在不用pooling层且计算相当的情况下提供更大的感受野.




图5 FPN的结构

Fig. 5 Structure of FPN

ASPP 是使用空洞卷积的经典结构,如图6所示,输入为通过基础网络和FPN之后得到特征图P1,即图5中P1,然后通过具有不同扩张率的多个卷积层和最大池化层得到多个尺度的特征,采用4个并行的不同扩张率的空间卷积对特征图进行处理能够有效地捕获多尺度信息.FM5通过全局平均池化得到.最后按照深度的方向连接得到的特征图FM1-FM5并通过卷积层, BatchNormalization, Relu 和 SpatialDropout 层得到最终的特征图 Feature map.




图6 ASPP的结构

Fig. 6 Structure of ASPP

1.3 CMR

CMR是Mask R-CNN和Cascade R-CNN两种结构的结合^[9],采用级联结构,如图4中Cascade Mask R-CNN,将上一阶段的输出作为下一阶段的输入,使得周界检测的结果更加准确,不受复杂背景变化的影响.本文CMR中的输入是经过基础网络、FPN和ASPP得到的最终特征图,即图6的Feature map输出为最终的检测结果.

2 网络训练

2.1 参数设置

实验在TITAN Xp GPU上完成,使用pytorch框架,采用的是3个阶段的级联,基础头网络使用resnet101,并在头网络后面使用了FPN和ASPP.在一个GPU上进行的网络训练,迭代次数为12次,初始学习率为0.25,迭代到第6次和第10次时学习率都下降0.1倍.实验采用SGD进行优化.

2.2 网络模型

使用端到端的方法进行网络训练,在每个阶段 t ,box头网络都有分类分数 c_t 和回归偏移量 r_t ,mask头网络预测每个ROI区域的像素级掩码 m_t .整个多任务网络的代价函数为

$$L = \sum_{t=1}^T (L_{\text{bbox}}^{(t)} + L_{\text{mask}}^{(t)}) \quad (1)$$

式中: L 为总的代价函数,由边界框预测的代价函数 $L_{\text{bbox}}^{(t)}$ 和掩码预测的代价函数 $L_{\text{mask}}^{(t)}$ 组成; T 为总的级联阶段数,本文选取了3个级联, $T=3$.

$$L_{\text{bbox}}^{(t)}(c_t, r_t, c'_t, r'_t) = L_{\text{cls}}(c_t, c'_t) + L_{\text{reg}}(r_t, r'_t) \quad (2)$$

式中: L_{cls} 使用交叉熵代价函数; c_t 为预测类别指示变量,取值0或1; c'_t 为实际类别的预测概率; L_{reg} 为smoothed L1损失函数; r_t 为预测框的位置; r'_t 为真实框的位置.

$$L_{\text{cls}}(c_t, c'_t) = - \sum_{m=1}^M (c'_t^{(m)} \cdot \ln c_t^{(m)}) \quad (3)$$

$$L_{\text{reg}}(r_t, r'_t) = \sum_{i \in \{x, y, w, h\}} \text{smooth}_{\text{L1}}(r_t^{(i)} - r'_t^{(i)}) \quad (4)$$

$$\text{smooth}_{\text{L1}}(x) = \begin{cases} 0.5(x)^2, & |x| < 1 \\ |x| - 0.5, & \text{otherwise} \end{cases}$$

式中: M 为分类类别数; x 和 y 表示框的左上角坐标; w 和 h 分别表示框的宽高; i 表示具体框的位置,如 $r_t^{(i)}$ 表示预测框的具体位置; $\text{smooth}_{\text{L1}}()$ 表示使用smoothed L1损失函数.在阶段 t 时掩码预测的代价函数 $L_{\text{mask}}^{(t)}$,使用的是带有逻辑回归的二进制交叉熵代价函数,即

$$L_{\text{mask}}^{(t)}(m_t, m'_t) = - \{ m'_t \ln \sigma(m_t) + (1 - m'_t) \ln [1 - \sigma(m_t)] \} \quad (5)$$

式中: m_t 表示预测的掩码; m'_t 表示实际的掩码,对于每个RoI,其编码分辨率为 $a \times a$ 的 M 个二进制掩码 m_t ,对于与类 M 的真实值相关联的RoI, L_{mask} 仅在第 k 个掩模上定义,其他掩模输出不会导致损耗; σ 为Sigmoid函数,将预测掩码的每个值转为[0,1]范围内.

3 结果分析

3.1 数据集

coco数据集包括82 783个训练图像、40 504个

验证图像及40 775个测试图像,80个不同类别,如自行车,人,鸟,狗等.数据集包含不同尺度的目标,约24%的大目标,34%的中等目标,41%的小目标,大目标指面积大于96 pixel × 96 pixel的目标,小目标指面积小于32 pixel × 32 pixel的目标,中目标指面积介于大小、目标之间的目标,而面积是指分割掩码中像素的数量.

铁路周界视频数据集为非公共数据集,是由自己采集及标注,目前共有55段视频.包含大中尺寸目标的视频7段,小目标的视频46段,不包含任何目标的视频2段;视频中存在相机抖动情况3段,动态背景情况2段,间歇运动情况10段,正常情况40段.

3.2 评价标准

AP(Average Precision)是coco数据集的评价标准,是IOU为0.50~0.95阈值时的平均AP. AP_s , AP_m , AP_l 分别表示针对小、中、大目标的AP值.

准确率(Accuracy, Acc)是图像中预测正确的像素点个数与所有像素点个数的比值,即预测为前景实际也为前景的像素点和预测为背景实际也为背景的像素点的总和与总的像素点个数的比值.

F-measure是精确率与召回率的调和平均值. E_{TP} 为真正例,表示该像素点实际是前景,检测时也检测为前景; E_{FP} 为假正例,表示实际为背景,但检测成了前景; E_{FN} 为假反例,表示实际为前景,但

检测为背景.精确率、召回率及F-measure值 F_1 的计算公式为

$$P = E_{TP} / (E_{TP} + E_{FP}) \quad (6)$$

$$R = E_{TP} / (E_{TP} + E_{FN}) \quad (7)$$

$$F_1 = 2PR / (P + R) \quad (8)$$

3.3 实验分析

(1) 在coco数据集上验证.

为了验证改进算法是否有效,在coco数据集上进行测试,实验结果如表1所示.其中 AP_{50} 和 AP_{75} 分别表示IOU为0.50和0.75时的AP.从表1中可以看出,增加FPN后,检测结果有了很大的提升,尤其是小目标和中等目标的检测效果,这主要是FPN融合了5个不同尺度的特征图,包含了更多底层的信息.增加ASPP之后,对小目标的检测效果降低,对大目标的检测效果提高,主要是ASPP只在最后的特征上使用,可以得到更大的感受野,有更广的全局特征,但在过程中引入了更多的噪声,增加了误检率.在原始模型上同时使用FPN和ASPP,模型可取得最好的效果,框的平均精确率提高了3.8,掩码的平均精确率提高了3.9,针对小目标平均精确率(AP_s)从16.4提升到了23.0,针对大目标平均精确率(AP_l)从55.2提升到了63.0,即改进的方法针对小目标和大目标的检测效果得到同步提升.

表 1 4种方法在coco数据集上的表现

Table 1 Performance of four methods on coco datasets

方 法	Box AP	Mask AP	AP_{50}	AP_{75}	AP_s	AP_m	AP_l
CMR	39.0	33.0	57.6	42.0	16.4	43.9	55.2
CMR-FPN	42.2	36.3	60.7	46.0	23.2	45.1	54.1
CMR-ASPP	31.3	26.8	46.2	33.6	10.8	43.9	63.4
CMR-FPN-ASPP	42.8	36.9	60.8	46.5	23.0	45.2	63.0

(2) 在实际铁路周界检测中的应用.

在铁路周界检测中尝试传统方法和基于深度学习的方法,很多基于深度学习的方法都是基于特定场景的^[12-14],这些方法在某一场景下训练也只在这一场景的测试效果较好,对其他场景的实用性较差,故不对这类方法进行比较.除去这些基于特定场景的方法,其他深度学习方法还有DeepBS^[15]等.对比本文方法与DeepBS,以及传统的

LOBSTER^[6]、PAWCS^[7]及SuBSense^[8]算法的检测结果.

① 针对不同情况的算法有效性验证.

为了验证算法在不同条件下的有效性,在铁路周界视频数据集集中进行测试.图7分别为不同方法在相机抖动(第1行)、动态背景(第2行)、间歇运动(第3行)情况下的检测结果.结果显示,本文提出的方法鲁棒性最好,在相机抖动和动态背景时

无误检,在间歇运动时无漏检.3种情况下的准确率如表2所示,动态背景情况下样本均为反例,故

无法计算精确率和F-measure.




图7 不同算法在不同情况下的检测结果

Fig. 7 Comparison of detection results of different algorithms in different situations

表2 各种方法在不同情况下的准确率
Table 2 Accuracy of various methods on different videos

方法	CMR-FPN-ASPP	DEEPBS	LOBSTER	PAWCS	SuBSENSE
相机抖动	0.98	0.92	0.78	0.88	0.86
动态背景	0.99	0.93	0.83	0.91	0.88
间歇运动	0.97	0.94	0.93	0.92	0.93

② 针对多尺度目标的算法有效性验证.

图8为不同方法在部分视频上的检测结果:对于大目标(第1行)、中目标(第3行),CMR和本文方法分割准确;对于小目标(第2行),传统方法和DeepBS的方法检测效果差且存在误检,CMR法只

能检测到两个稍大一点的目标,本文方法可以检测到全部的4个小目标,且分割效果好,无漏检;第4行是在最远处有个极小目标,只有本文方法可以检测到目标.




图8 不同算法对视频帧的检测结果

Fig. 8 Comparison of detection results of different algorithms for video frames

表3为不同方法在不同视频上的F-measure,与之前方法相比,本文方法有很大突破,改进方法

针对小目标的检测效果更好.需要指出的是,本文方法没有在任何铁路周界视频上训练过,仅仅是

在公开的目标检测训练集 coco 上训练过,说明本文方法与特定场景无关,而目前大多数基于深度

学习的方法需要针对特定场景进行训练.

表 3 各种方法在不同视频上的 F-measure

Table 3 F-measures of various methods on different videos

方 法	CMR-FPN-ASPP	CMR-ASPP	CMRFPN	CMR	DEEPBS	LOBSTER	PAWCS	SuBSENSE
大中目标视频	0.91	0.89	0.90	0.89	0.57	0.54	0.38	0.58
小目标视频	0.51	0.25	0.32	0.27	0.18	0.20	0.06	0.17

与中目标检测相比,小目标检测的 F-measure 较低,主要是小目标的召回率偏低,相对于现有的其他方法,本文方法针对视频中的小目标已极大地降低了漏检率.

4 结 论

针对基于综合视频的铁路周界入侵检测问题,本文根据实际场景检测需要,提出使用 Cascade Mask R-CNN 网络进行检测的算法,为了提升周界入侵中较大目标及非常小目标的检测效果,在网络中增加了 ASPP 和 FPN,对基础网络进行了改进.实验结果表明:相较于原始模型,改进模型可有效检测出目标,尤其对小目标,算法表现出了较优的性能;另外,该方法几乎不受相机抖动、动态背景的影响,可广泛应用于铁路周界入侵的检测中.

参考文献:

[1] 李一凡. 高速铁路周界入侵报警系统关键技术研究及应用[J]. 铁道通信信号, 2017, 53(7): 53-55, 85. [LI Y F. Study and application of key technologies of perimeter intrusion alarming system for high speed railway[J]. Railway Signalling & Communication, 2017, 53(7): 53-55, 85.]

[2] 关晟. 高速铁路周界防护技术研究[J]. 高速铁路技术, 2015, 6(2): 63-67. [GUAN S. Technology research on perimeter protection on high-speed railway[J]. High Speed Railway Technology, 2015, 6(2): 63-67.]

[3] CATALANO A, BRUNO F, PISCO M, et al. An intrusion detection system for the protection of railway assets using fiber bragg grating sensors[J]. Sensors, 2014, 14 (10): 18268-18285.

[4] 牛宏侠, 张肇鑫, 宁正, 等. 铁路轨道异物完整性检测与跟踪算法研究[J]. 交通运输系统工程与信息, 2019, 19(1): 45-54. [NIU H X, ZHANG Z X, NING Z, et al. Detection and tracking algorithm of foreign integrity in

railway tracks[J]. Journal of Transportation System Engineering and Information Technology, 2019, 19(1): 45-54.]

[5] 李荣增. 基于视频识别的铁路入侵检测研究与实现 [D]. 武汉: 武汉理工大学, 2016. [LI R Z. Research and implementation of railway intrusion detection based on video recognition[D]. Wuhan: Wuhan University of Technology, 2016]

[6] BILODEAU G A, JODOIN J P, SAUNIER N. 2013 international conference on computer and robot vision-change detection in feature space using local binary similarity patterns[C]// International Conference on Computer & Robot Vision, IEEE Computer Society, 2013: 106-112.

[7] ST-CHARLES P L, BILODEAU G A, BERGEVIN R. A self-adjusting approach to change detection based on background word consensus[C]// 2015 IEEE Winter Conference on Applications of Computer Vision (WACV), IEEE Computer Society, 2015: 990-997.

[8] ST-CHARLES P L, BILODEAU G A, BERGEVIN R. SuBSENSE: A universal change detection method with local adaptive sensitivity[J]. IEEE Transactions on Image Processing, 2014, 24(1): 359-373.

[9] CHEN K, PANG J, WANG J, et al. Hybrid task cascade for instance segmentation[J]. 2019, arXiv: 1901.07518.

[10] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE Computer Society, 2017: 2117-2125.

[11] CHEN L C, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation[J]. 2017, arXiv:1706.05587.

[12] ANG L L, HACER Y K. Foreground segmentation using convolutional neural networks for multiscale feature encoding[J]. Pattern Recognition Letters, 2018(112): 256-262.

[13] WANG Y, LUO Z, JODOIN P M. Interactive deep learning method for segmenting moving objects[J]. Pattern Recognition Letters, 2016(96): 66-75.

[14] LONG A L, KELES H Y. Learning multi-scale features for foreground segmentation[J]. 2018, arXiv:1808.01477.

- [15] BABAE M, DINH D T, RIGOLL G. A deep background subtraction[J]. Pattern Recognition, 2017 (76): 635-649.

中国系统工程学会第21届学术年会征文通知

中国系统工程学会第21届学术年会将于2020年10月31日~11月1日在西安曲江国际会议中心召开,主题为“系统工程与百年变局之新机遇”。征文通知如下。

征文采用在线(sesc2020.csp.escience.cn)投稿方式,接收摘要(投稿期均可)和全文(仅限第1轮)。在投稿平台注册后进入摘要投稿界面进行投稿,投稿时请选择主题、分会场或专题论坛。第1轮全文投稿时,需提交全文内容(pdf或者Word),选择期望推荐的期刊名称。投稿由年会学术委员会评审,录取稿件至少一位作者注册会议后安排会议宣讲。会议与《系统工程理论与实践》《系统工程学报》《交通运输系统工程与信息》《Journal of Systems Science and Systems Engineering》《Journal of Systems Science and Information》等合作。全文根据评审意见由学术委员会决定最终推荐的期刊,推荐稿件的作者至少一名首先注册会议,年会才将推荐名单转给期刊,投稿期刊后需遵照期刊处理稿件流程,推荐不保证期刊录用;未推荐稿件建议作者以摘要投稿。

投稿参考范围:系统科学理论和方法,系统工程理论和方法,“百年大变局”中系统科学与系统工程的创新研究,系统科学与工程在社会、经济、金融、工程技术、军事、能源资源、医药卫生、教育文化、交通运输、生态环境、行业经济与行业发展等领域的应用研究和应用基础研究,AI等新IT技术在系统工程中的发展与应用,重大突发公共卫生事件治理的系统工程理论与方法,与系统科学和系统工程有关的其他领域创新研究成果。

重要日期:第1轮摘要和期刊推荐全文投稿截止时间为2020年5月18日;期刊推荐论文录用通知为2020年6月30日;期刊推荐论文若投稿期刊,注册会议和投稿期刊截止为2020年7月15日;第2轮摘要投稿开始时间为2020年7月15日,截止时间为2020年8月20日;分会场及专题论坛投稿录用截止时间为2020年8月31日(建议作者在两轮摘要投稿期间直接在线投稿,分会场和专题论坛亦可约定时间集中投稿);摘要录用通知时间为2020年9月3日;录用摘要(包括分会场和专题论坛)至少1名作者注册截止时间为2020年9月15日。

会议注册费标准:前期,会员1300元,非会员1500元,学生700元;后期及现场,会员1400元,非会员1600元,学生800元。

注意事项:投稿作者需避免署名权争议,作者排序以初投稿为准;投稿评审结果通过投稿系统发送;期刊推荐仅限于第1轮投稿且投稿给一般专题,分会场和专题论坛的全文投稿不推荐给期刊。

论文投稿事宜通过在线平台或sesc_paper@iss.ac.cn咨询。分会场和专题论坛申请,请参见2020系会字1号“关于征集第21届学术年会协办单位、分会场及专题论坛的通知”或会议网站相关消息。年会一般联络:sesc@iss.ac.cn。