

图1 基于 Faster R-CNN 的车辆目标检测网络结构图




图2 RoI 的生成过程

感兴趣区域 (RoI) 生成过程中, 输入的是图像, 输出是候选区域. 如果  $IoU>0.7$ , 候选区域被视为正样本,  $IoU<0.3$ , 候选区域被视为负样本, 当  $0.3<IoU<0.7$  时, 候选区域视为放弃.

监督训练过程输入是图像和标签, 输出是候选区

域的置信度得分和坐标. 回归层用于微调候选区域的位置. 候选区域可以通过分类层获得置信得分, 通过回归层和分类层获取对象和对象的位置, 通过候选区域的置信得分和坐标来获得候选窗口. 具体过程如图3所示.




图3 监督训练过程

### 2.3 增量学习

随着人工智能和机器学习的发展, 出现了很多机器学习算法, 这些算法大都是批量学习模式, 即假设在训练前可一次性获取所有训练样本, 学习已知样本后, 学习过程即终止. 对已学习到的模型, 存在各种缺陷, 若只使用同一样本反复训练, 机器学习到的特征有限, 会限制模型的有效性. 增量学习算法可以渐进地更新知识, 对机器学习增加新的样本知识, 可修正和加强以前的知识, 使更新后的模型更完善.

在本文中, 对 VOC2007 数据集中车辆目标的检测存在两个问题: (1) 车辆目标形变较大, 小目标车辆较多, 使用 VOC2007 数据集训练所得的模型对小目标车辆的检测效果不太理想; (2) VOC2007 数据集中图像背景比较复杂, 机器学习不能更为准确地提取单一车辆目标的特征, 导致待检图像中一些截断式车辆目标被漏检. 为解决这两个问题, 选用了 MIO-TCD 数据集作

为增量数据集对原模型进行重新训练测试, 选择理由主要有两个: (1) 该数据集中小目标车辆较多, 可以很好地学习小目标车辆的形态特征; (2) 该数据集的图像背景较为单一, 可以更加精准地学习车辆目标的特征, 减少了很多区域框内的背景干扰因素.

### 2.4 算法描述

对道路上车辆目标的检测存在很多问题影响检测效果, 本文以 VOC2007 数据集的检测结果为, 直观分析在 VOC2007 数据集上进行的车辆目标检测效果, 可以发现: (1) 图像中远处小目标出现错检漏检的情况; (2) 对图像边缘截断式待检目标出现漏检; (3) 对待检目标重叠遮盖区域部分出现错检漏检. 为解决这些问题, 本文提出一种基于增量学习的车辆检测方法, 该方法分为两个阶段, 即训练阶段和测试阶段. 在训练阶段, 重新训练在 ImageNet 上预训练后的初始参数的卷积神经网络, 以获得车辆检测模型; 在测试阶段, 将测试

样品输入检测模型以获得测试结果。

为证明本文方法的有效性,在训练阶段首先使用 VOC2007 数据集训练网络得到车辆检测模型 A,并使用 VOC2007 数据集测试模型 A,得出测试结果;其次,选用 MIO-TCD 数据集作为增量学习的数据集,将 MIO-TCD 数据集加入到 VOC2007 数据集中重新训练网络,得到车辆检测模型 B,使用原测试集加 MIO-TCD 数据集中分配出的测试集测试模型 B;最后,对比模型 A 和模型 B 的测试结果.整个方法流程如图 4 所示。

### 3 实验分析

#### 3.1 实验环境与数据集

实验选取了 Faster R-CNN+VGG16、Faster R-CNN+ResNet101 对使用增量学习数据集和原数据集进行对比,实验环境:操作系统为 Ubuntu18.04,训练 GPU 为 2 块 1080Ti,内存为 448 GB。

实验所用数据集包括原数据集与增量学习数据集,原数据集使用的是来自 VOC2007 数据集中 bus、bicycle、car、motorbike 等 4 类车辆图像,共计 3599 张带标签图像;增量学习数据集为 MIO-TCD 数据集中随机挑选出 1000 张包含 bus、bicycle、car、motorbike 等 4 类车辆图像,4 类图像平均分布,使用 labelImg 标注工具,将 1000 张车辆图像按照 VOC2007

格式进行标注。

#### 3.2 实验结果及分析

实验首先对原数据集按照训练集与测试集 8:2 的比例随机分配,将训练集输入到网络中通过训练迭代得到车辆目标分类模型,再将测试集输入到训练好的模型进行测试,测试结果如图 5 所示。

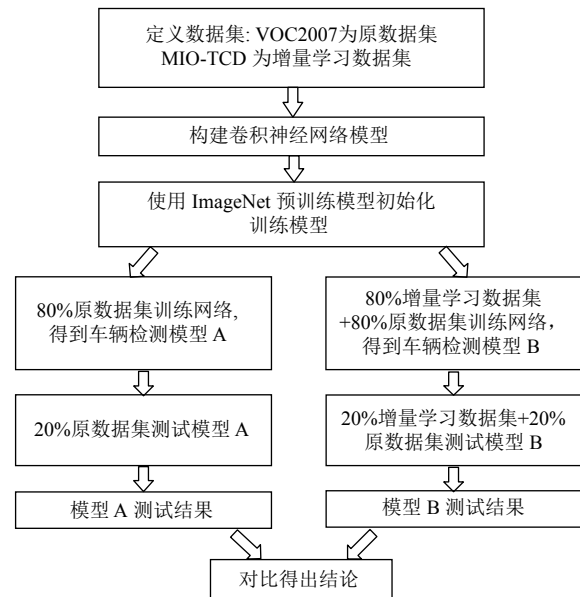


图 4 基于增量学习的车辆目标检测方法流程图



图 5 使用模型 A 测试结果示例图

由图 5 可以看出,使用 Faster R-CNN 网络训练出的车辆分类检测模型去检测车辆目标,检测能力方面体现出非常优秀的效果.对背景清晰单一并且重叠遮盖较少的待检目标,检测区域置信度高达 0.98 以上,但是,在复杂的背景下,如背景干扰目标较多、待检目标互相遮挡重叠、待检目标车体大部分超出图片区域等,此时容易出现漏检错检或检测框置信度较低的情况。

为解决这些问题,我们将增量学习数据集按照训练集与测试集 8:2 的比例随机分配,再将增量学习数据集与原数据集合并,将新的训练集输入到卷积神经网络中重新训练车辆目标分类模型,最后将测试集输入到新的模型进行测试.为直观的区别使用增量学习数据集为车辆目标分类任务带来的改进,我们在原测试结果与新的测试结果中分别挑选出 4 组相同的图像进行对比,对比图如图 6。

由图 6 可以看出,图 6(a)虽检测到汽车遮挡截断的左前方车辆,但区域建议置信度只有 0.946,且对右前方截断式的 car 目标完全漏检,而使用增量学习数据集重新训练并测试后,图 6(e)不仅对左前方遮挡截断式的 car 目标提高了置信度到 0.990,并且也检测到了

右前方 car 目标. 同样, 图 6(b) 中, 对远处小目标有良好的检测效果, 但对图片左右边缘处的截断式 car 目标漏检, 而图 6(f) 对图 6(b) 中漏检的目标做了很好的修正. 对重叠严重的 bicycle 目标图 6(c), 区域建议框标注并不十分准确, 置信度相对较低, 且对远处模糊的目标

出现漏检错检情况, 在图 6(g) 中, bicycle 目标检测框明显变得更为准确, 置信度比原图像的置信度要高, 对远处目标检测也给出了修正结果. 更为明显的图 6(d) 与图 6(h) 对比, 可以明显看出使用增量学习数据集方法对重叠的待检目标有良好的检测效果.



图 6 对截断式和重叠区待检目标测试结果对比图

在主观评价后, 表 1 中使用具体数据对实验结果进行了客观展示. 由于召回率准确率存在单点值局限性的问题, 所以本文采用 AP 值来反映检测结果. AP 值为平均准确率, 是一个能够反应全局性能的指标, 准确率召回率曲线下的面积即为 AP 值. mAP 值为所有不同类 AP 值的平均值, mAP 值越大, 检测效果越好.

表 1 实验结果

模型	方法	Bus	Bicycle	Car	Motorbike	mAP
A	VGG16	0.806	0.808	0.876	0.803	0.823
	ResNet101	0.823	0.853	0.874	0.798	0.837
B	VGG16	0.895	0.816	0.875	0.885	0.868
	ResNet101	0.896	0.895	0.881	0.894	0.891

#### 4 结论与展望

本文提出一种增量学习和 Faster R-CNN 的车辆分类识别的方法. 该方法有效地利用了 Faster R-CNN 算法端到端的网络结构, 能够快速、鲁棒地检测车辆目标. 实验结果表明, 使用 Faster R-CNN 卷积神经网络结构结合增量学习数据集创新性地训练图像, 能够从图像中提取更加全面丰富的目标特征, 使用所得车辆目标分类检测模型测试数据集, 从主观和客观两个角度

来分析, 能够明显看出本文方法存在的优势. 然而, 我们从结果中也发现很多不足的地方, 包括: (1) 对远处的小目标仍会出现漏检错检情况; (2) 在昏暗背景下对目标的检测, 给出的区域建议框置信度较低; (3) 在更为复杂的背景下, 如闹市背景目标重叠度太大、背景干扰目标较多等, 检测效果仍需改进. 因此, 在接下来的研究中, 解决上述问题是未来研究的关键.

#### 参考文献

- 张全发, 蒲宝明, 李天然, 等. 基于 HOG 特征和机器学习的工程车辆检测. 计算机系统应用, 2013, 22(7): 104-107. [doi: 10.3969/j.issn.1003-3254.2013.07.023]
- Zhang YZ, Sun PF, Li JF, *et al.* Real-time vehicle detection in highway based on improved Adaboost and image segmentation. Proceedings of 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems. Shenyang, China. 2015. 2006-2011.
- Qiu QJ, Liu Y, Cai DW. Vehicle detection based on LBP features of the Haar-like characteristics. Proceedings of the 11th World Congress on Intelligent Control and Automation. Shenyang, China. 2014. 1050-1055.
- 武凯利, 全宗和, 张鹏升, 等. 基于深度学习的复杂气象条

- 件下海上船舶识别. 科学技术与工程, 2019, 19(3): 130–135. [doi: [10.3969/j.issn.1671-1815.2019.03.022](https://doi.org/10.3969/j.issn.1671-1815.2019.03.022)]
- 5 Girshick R. Fast R-CNN. Proceedings of 2015 IEEE International Conference on Computer Vision. Santiago, Chile. 2015. 1440–1448.
- 6 Ren SQ, He KM, Girshick R, *et al.* Faster R-CNN: Towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137–1149. [doi: [10.1109/TPAMI.2016.2577031](https://doi.org/10.1109/TPAMI.2016.2577031)]
- 7 Li SX, Zhang ZL, Li B. A plane target detection algorithm in remote sensing images based on deep learning network technology. Journal of Physics: Conference Series, 2018, 960: 012025. [doi: [10.1088/1742-6596/960/1/012025](https://doi.org/10.1088/1742-6596/960/1/012025)]
- 8 He KM, Gkioxari G, Dollar P, *et al.* Mask R-CNN. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018. [doi: [10.1109/TPAMI.2018.2844175](https://doi.org/10.1109/TPAMI.2018.2844175)]
- 9 曹诗雨, 刘跃虎, 李辛昭. 基于 Fast R-CNN 的车辆目标检测. 中国图象图形学报, 2017, 22(5): 671–677.
- 10 桑军, 郭沛, 项志立, 等. Faster-RCNN 的车型识别分析. 重庆大学学报, 2017, 40(7): 32–36.
- 11 陈超村, 蔡晓东, 赵勤鲁, 等. 基于多层次特征的高效车脸定位方法. 电视技术, 2017, 41(9–10): 161–165.
- 12 Zhang YJ, Wang J, Yang X. Real-time vehicle detection and tracking in video based on faster R-CNN. Journal of Physics: Conference Series, 2017, 887(1): 012068.
- 13 徐乐先, 陈西江, 班亚, 等. 基于深度学习的车位智能检测方法. 中国激光, 2019, 46(4): 0404013.
- 14 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv: 1409.1556, 2015.
- 15 宋焕生, 张向清, 郑宝峰, 等. 基于深度学习方法的复杂场景下车辆目标检测. 计算机应用研究, 2018, 35(4): 1270–1273. [doi: [10.3969/j.issn.1001-3695.2018.04.067](https://doi.org/10.3969/j.issn.1001-3695.2018.04.067)]