

卷积神经网络在车辆目标快速检测中的应用*

陈宏彩^{1,2}, 程煜^{1,2}, 张常有³



¹(河北省科学院应用数学研究所, 河北 石家庄 050081)

²(河北省信息安全认证工程技术研究中心, 河北 石家庄 050081)

³(中国科学院 软件研究所 并行软件与计算科学实验室, 北京 100190)

通讯作者: 张常有, E-mail: changyou@iscas.ac.cn

摘要: 我国机动车保有量急速增长, 产生一系列严重的安全与交通问题. 与此同时, 视频图像文件呈爆炸式增长, 为公安的监控、刑侦以及案件的侦破带来了很大的困扰. 车辆目标检测与识别越来越受到人们的关注, 研究一种高效而准确的车辆目标检测方法意义重大. 在 YOLO 目标检测框架的基础上, 设计了一种卷积神经网络的车辆检测及其车型粗粒度识别方法. 网络结构采用多层感知机卷积层, 增加特征映射的非线性处理能力; 移除原来模型中的全连接层, 利用锚点框预测目标的边界框, 在降低模型复杂度的同时提高了目标检测的召回率. 实验结果表明, 与主流的目标检测方法相比, 该车辆目标检测方法在处理速度和准确度上都有提高, 在迭代 20 000 次的情况下, 平均准确率为 94.7%.

关键词: 车辆检测; 卷积神经网络; 多层感知机; 粗粒度; 车辆识别

中文引用格式: 陈宏彩, 程煜, 张常有. 卷积神经网络在车辆目标快速检测中的应用. 软件学报, 2017, 28(Suppl. (1)): 107-114. <http://www.jos.org.cn/1000-9825/17011.htm>

英文引用格式: Chen HC, Cheng Y, Zhang CY. Convolutional neural network applied on fast vehicle objects detection. Ruan Jian Xue Bao/Journal of Software, 2017, 28(Suppl. (1)): 107-114 (in Chinese). <http://www.jos.org.cn/1000-9825/17011.htm>

Convolutional Neural Network Applied on Fast Vehicle Objects Detection

CHEN Hong-Cai^{1,2}, CHENG Yu^{1,2}, ZHANG Chang-You³

¹(Hebei Academy of Sciences Institute of Applied Mathematics, Shijiazhuang 050081, China)

²(Hebei Authentication Technology Engineering Research Center, Shijiazhuang 050081, China)

³(State Key Laboratory of Computing Science, Institute of Software, The Chinese Academy of Sciences, Beijing 100190, China)

Abstract: With the rapid growth of the number of motor vehicles in China, inevitably there would appear a series of severe problems concerning safety and traffics. At the same time, the video image files are increasing at an explosive speed, which has brought a lot of trouble to the public security monitoring, criminal investigation and the case detection. It is important to research an efficient and accurate vehicle detection algorithm. This paper proposes a new deep convolution neural networks frame for vehicle detection and coarse grained recognition based YOLO method. Multilayer perceptron convolution layers are added in the new network structure framework to enhance nonlinear ability of feature mapping. This framework deletes fully connected layers and predicts the bounding boxes using anchor boxes. The new framework improves recall rates of object detection and effectively reduces computational complexity. Experimental results show that the improved method has an average accuracy of 94.7% for vehicle detection under iteration 20000 times. Compared with other detection methods, the processing speed and accuracy of the new method have been improved.

Key words: vehicle detection; convolution neural networks; multilayer perceptrons; coarse-grained; vehicle recognition

* 基金项目: 国家自然科学基金 (61379048, 61672508); 河北省重点研发计划(17395602D)

Foundation item: National Natural Science Foundation of China (61379048, 61672508); Key Research and Development Program of Hebei Province (17395602D)

收稿时间: 2017-05-15; 采用时间: 2017-09-23

随着我国机动车数目的急速增长,产生了一系列严重的安全与交通问题.交通堵塞、车辆被盗、汽车超速、超载、闯红灯以及驾驶汽车犯罪等事件与日俱增.与此同时,交通路口视频图像文件呈爆炸式增长,给公安和交管等执法部门处理事后的车辆检索工作带来了很大的困扰,尤其随着车辆的增多,涉车案件也越来越多.车辆及其感兴趣区域检测识别越来越受到人们的关注,但是目前相关目标检测识别系统的处理性能和准确率还有待提高,所以,设计一种高效而准确的车辆检测方法意义重大.

近年来,深度学习理论迅速发展,与传统依赖先验知识的特征提取算法不同,神经网络可在训练数据驱动下自适应地构建特征描述,具有更高的灵活性和普适性.作为实现深度学习的一项重要技术,卷积神经网络(convolutional neural networks,简称 CNN)^[1]成功地训练了首个深层神经网络结构,已在图像识别^[2-4]、语音识别^[5]等领域取得了卓越的成绩.它类似于生物神经网络的权值共享网络结构可产生生物视觉中的局部感受野效应,在降低网络模型复杂度^[3]、减少权值数量的同时,对平移、比例缩放、倾斜等视觉形变均具有高度的抵抗能力.文献[6]中使用卷积神经网络训练行人特征用于行人检测.此方法对光照、变形和遮挡都有较好的鲁棒性.张勇^[7]利用基于深度学习思想对深度卷积神经网络模型解决复杂环境下人脸和车牌的检测问题进行了深入研究,并且在公开数据集上获得了较好的性能评价.谭志刚^[8]提出了一种非对称卷积神经网络的算法.该算法可以从场景图像中检测交通标志,并且有效地保证了目标检测的速率和准确率.

本文利用深度卷积神经网络技术构建车辆目标检测算法,与传统卷积神经网络结构相比具有以下优势:第一,在网络结构中引入数据批量规范化处理,在去除噪声的同时增强了目标检测特征的表达能力;第二,新的网络结构采用多层感知机卷积层,增加了特征映射的非线性处理能力;第三,移除原来模型中的全连接层,利用锚点框(anchor box)预测目标的边界框,在降低模型复杂度的同时,提高目标检测的召回率.

本文第1节介绍当前主流的目标检测方法.第2节详细阐述本文设计的基于卷积神经网络的车辆目标检测及其车型粗粒度识别方法.第3节对构建的基于卷积神经网络的车辆检测方法实验测试,并对实验结果进行分析.第4节总结全文,并对未来的研究方向进行初步探讨.

1 目标检测常用方法介绍

所谓图像的目标检测就是给定一张图像,定位出图像中所有目标的位置,并给出每个目标的具体类别.传统的目标检测方法一般使用滑动窗口的框架.这些方法存在一定的弊端:一是应用滑动窗口区域选择方法时间复杂度较高,存在窗口冗余现象;二是手工设计的特征缺乏通用性,鲁棒性较差.

当前,基于深度学习的目标检测算法是主流.大体分为两类,一类是基于候选区域(region proposal)的算法,另一类是基于回归的目标检测方法.2014年,文献[9]提出了使用 CNN 结合候选区域方式来进行目标检测,设计了 R-CNN 框架,其基本流程是:输入待检测原始图像,使用选择性搜索算法从中选择出区域候选框;把每个候选框缩放到指定大小并输入到 CNN 网络中,从而实现特征的提取;使用支持向量机(support vector machine,简称 SVM)对提取到的特征进行分类,以回归的方式对边框的大小和位置进行调整.R-CNN 框架的优势在于不需要人工选择设计特征,但它的一大弊端是运行速度慢.2015年,Girshick 提出了 Fast-R-CNN 算法^[10],修改了 R-CNN 网络结构,在末尾卷积层之后增添了一个感兴趣区域池化层并运用改进的多任务损失函数替换原来的损失函数,同时,在 CNN 的训练过程中包含了边框回归操作,与 R-CNN 相比,在检测速度和精度上都有较大的提升.Ren 等人提出了 Faster-R-CNN 算法^[11].该算法中使用一种专门的神经网络 RPN(region proposal network,简称 RPN)来提取候选框,代替了 R-CNN 框架中的选择搜索,在不影响候选区域质量的前提下,使检测速度大为提高.

尽管 Faster-R-CNN 算法处理速度比之前方法有了很大的提升,但仍然无法满足实时性的需求.2016年,文献[12]提出了一种基于回归的目标检测算法,简称 YOLO 算法.YOLO 的本质仍然是一个卷积神经网络,与普通 CNN 不同之处在于,运行 1 次,网络就可以预测出多个边框位置和目标的类别,在真正意义上做到了端到端的目标检测和识别^[12],极大地提高了检测速度.再者,YOLO 直接使用整图对模型训练,有利于排除背景干扰.但是,YOLO 只使用 7×7 的网格回归,使得目标不能精准定位,而且召回率不如候选区域的方法.Liu 等人^[13]提出了

一种基于回归策略的 SSD 检测模型. SSD 方法结合了 YOLO 方法中的回归思想和 Faster R-CNN 的机制,使用图像各个位置的多尺度区域进行回归,根据锚点直接对目标进行分类和回归边框,既保持了 YOLO 方法速度快的特性,也保证了窗口预测精准度.

2 基于 YOLO V2 的车辆目标检测方法

YOLO V2 方法^[14]是在 YOLO 方法基础上使用一系列的技巧对其改进,新方法在保持原有速度的同时提高了精度,而且检测速度比 SSD 快 2 倍~10 倍.

本文建立的车辆目标检测方法借鉴 YOLO V2 算法,将主流的图像分类网络 GoogleNet 模型^[3]作为车辆检测网络主题框架,其车辆检测模型包含 19 个卷积层、5 个最大值池化层、1 个 Avgpool 层和 1 个 Softmax 层.

2.1 构建多层感知机卷积层

在卷积层我们采用 3×3 的卷积核,并且借鉴文献^[15]提出的网络中的网络工作思想,新的网络结构采用多层感知机卷积层(multilayer perceptrons convolution,简称 Mlpconv),图 1 是一个 Mlpconv 层结构示意图.在新的网络中使用全局平均池化进行预测,把 1×1 的卷积核置于 3×3 的卷积核之间,用来压缩特征,这可以看成是每个卷积的局部感受野中还包含一个微型的多层网络.

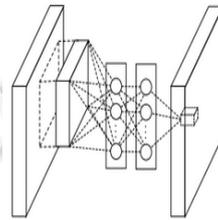


Fig.1 Mlpconv layer

图 1 多层感知机卷积层

普通的 CNN 层,局部感受野的运算仅仅是一个单层的神经网络,其计算如公式(1)所示.

$$f_{i,j,k} = \max(\omega_k^T x_{i,j}, 0) \quad (1)$$

在车辆检测框架中增加多层感知机卷积层后,对每个局部感受野的神经元进行运算,计算 Mlpconv 层每张特征图,其计算如公式(2)所示.

$$\begin{cases} f_{i,j,k_1}^1 = \max(\omega_{k_1}^1 T x_{i,j} + b_{k_1}, 0) \\ \vdots \\ f_{i,j,k_n}^n = \max(\omega_{k_n}^n T f_{i,j}^{n-1} + b_{k_n}, 0) \end{cases} \quad (2)$$

为了增强模型的检测能力,本文去掉 GoogleNet 模型中最后一个卷积层,在网络结构后面新增加 3 个 3×3 的卷积层,并且在每个卷积层后面增加一个 1×1 的卷积层,输出个数是检测目标所需要的数量.

2.2 数据批量规范化处理

车辆图像来自不同卡口,背景比较复杂,而且会受到光照、雾霾等噪声影响.通常卷积神经网络每层输入数据的分布总是发生变化.为了降低噪声对图像的影响,在车辆检测模型中引入数据批量规范化(batch normalization,简称 BN)处理. BN 操作的步骤是:在每个卷积池化处理之后,激活函数作用之前,对每个输出数据规范化处理(均值为 0,方差为单位 1),如公式(3)所示.对于一个输入层是 d 维的数据 $x=(x^{(1)}, \dots, x^{(d)})$,标准化每一维.

但是,仅仅做简单的归一化操作,会将原来非线性分布的数据处理成近似线性分布数据,降低模型表达能力.为了保持模型的表达能力,本文参考文献^[16]的方法,引入两个可学习参数,增强其模型的表达能力,于是最后的

输出可以表示为公式(4).

$$\hat{x}^{(k)} = \frac{x^{(k)} - E[x^{(k)}]}{\sqrt{Var[x^{(k)}]}} \quad (3)$$

$$y^{(k)} = \gamma^{(k)} \hat{x}^{(k)} + \beta^{(k)} \quad (4)$$

这里,公式(4)中的 $\gamma^{(k)}$ 和 $\beta^{(k)}$ 可以和网络模型原始参数一起学习获得.

2.3 锚点预测目标边界框

YOLO 算法^[12]使用全连接层数据进行目标边界框预测,而且在 7×7 的网格上处理,这样会丢失较多的空间信息,特别是当目标比较小时,容易造成定位不准确.本文的车辆检测方法借鉴 Faster R-CNN 方法中的锚点机制^[11],将 YOLO 模型中的全连接层去掉,再利用锚点预测车辆目标的边界框,如图 2 所示,在卷积特征图上进行滑动窗口采样,每个中心预测 9 种不同大小和比例的边界框.与原始 YOLO 算法每个单元格仅预测 2 种边界框相比,新方法将会提高目标检测的召回率.由于新的网络都是卷积操作不需要重新调整参数,这样可以很好地保留目标的空间信息,最终特征图的每个特征点和原图的每个单元格一一对应,而且用预测相对偏移取代直接预测坐标,既简化了问题,又方便了网络学习.

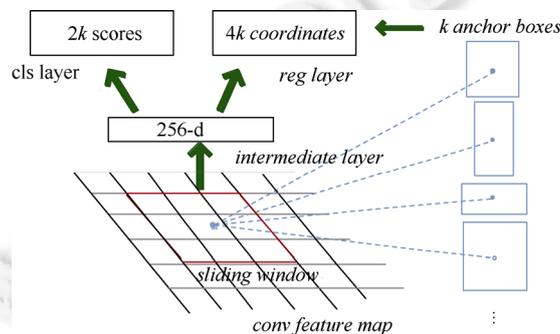


Fig.2 Anchors predict bounding boxes of object

图 2 锚点预测目标的边界框

本文车辆目标检测方法使用锚点预测检测目标边界框.具体步骤如下:

- (1) 去掉 YOLO 网络最后的池化层保证输出的卷积特征图具有更高的分辨率.
- (2) 缩减网络,将图像输入分辨率设置为 416×416 .
- (3) 卷积层下采样,采样因子设为 32,使得输入卷积网络的 416×416 图片最终得到 13×13 的卷积特征图.
- (4) 把预测类别的机制从空间位置中解耦,利用锚点同时预测目标类别和坐标.因为 YOLO 每个单元格负责预测类别,每个单元格对应的 2 个边界框负责预测坐标.本文方法中不再将类别的预测与每个单元格的空間位置绑定一起,而是将其全部放到锚点框中.

3 实验

3.1 测试环境

本文在 AMAX 服务器上进行实验测试.实验环境如下:CPU 为 Intel(R)E5-2650 @2.60GHz,GPU 为 Tesla K40m,系统环境为 Ubuntu14.04 和 CUDA7.5.

车辆测试数据集是从某市交通卡口获取的原始图像.检测的目标类别包括小轿车、客车/公交车、货车、面包车、自行车、摩托车、行人 7 个类别,每类目标训练样本数约为 500 张~1 000 张不等,总共 5 520 张训练图像,测试数据集共 5 500 张图像,每张图像的分辨率大小为 2048 像素 \times 1536 像素.

3.2 车辆目标检测模型参数测试

本节主要选择合适的卷积神经网络结构参数.通过大量对比实验来确定迭代次数、Dropout 率大小、学习率等问题,实验测试并分析确定最终方案.实验过程中,测试的结果都是以数据集中 7 类目标的检测为例进行测试.

在网络结构和训练及测试数据集不变的情况下,先固定 Dropout 率为 0.5,测试训练卷积神经网络迭代次数对检测性能的影响.表 1 给出了测试效果较好的 5 组实验.

Table 1 Comparative experiment results of different iteration times

表 1 不同迭代次数实验对比结果

实验	迭代次数	Dropout 率	准确率(%)
1	5 000	0.5	80.3
2	10 000	0.5	86.0
3	15 000	0.5	91.4
4	20 000	0.5	95.7
5	25 000	0.5	92.5

从表 1 可以看出,迭代次数设定为 20 000 时检测的效果要好于迭代次数 15 000 或者 25 000 的检测效果.结合实验结果分析得出,如果迭代次数过少,会使网络训练不充分,而迭代次数过多,会使整个网络模型更依赖于当前的样本集,这样容易导致过拟合.如图 3 所示,测试 2 张不同的车辆图像,其中,图 3(a)~图 3(d)分别是网络模型迭代 15 000 次、20 000 次、25 000 次和 20 000 次的检测效果图,其中,图 3(a)出现了漏检,而图 3(c)出现了误检和漏检.根据车辆目标检测结果,本文在实际训练过程时,将迭代次数设定为 20 000.

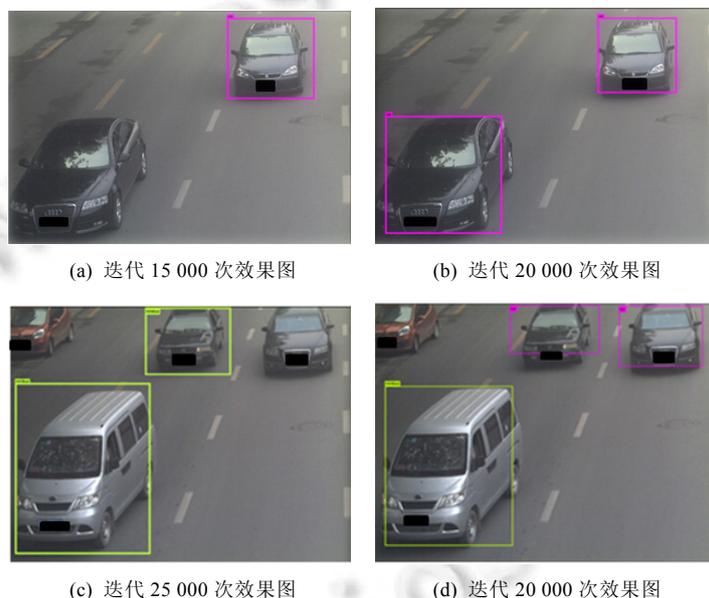


Fig.3 Detection results of different iteration times

图 3 不同迭代次数下检测结果

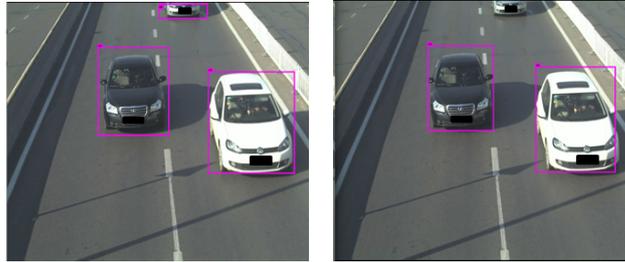
Dropout 层由 Hinton 等人^[17]提出并加入到了 CNN 结构中,其作用是能够有效地降低训练过程发生过拟合现象的概率.当训练权重参数较多而训练样本较少时,模型训练过程容易产生过拟合现象.在网络结构、数据集和迭代次数不变的情况下分别采用不同 Dropout 率训练检测的方式,实验结果见表 2.

从表 2 可以看出,使用 Dropout 层后,准确率有较大提升,并且 Dropout 率为 0.5,准确率较高,在实际车辆检测中采用 Dropout 率为 0.75,因为该参数可以有效地过滤采集不完整的车辆,提升检测速率.单张图像测试结果如图 4 所示,图 4(a)和图 4(b)图分别由 Dropout 率为 0.5 和 0.75 实验得到.

Table 2 Comparative experiment results of different Dropout ratios

表 2 不同 Dropout 率实验结果对比

实验	Dropout 率	迭代次数	准确率(%)
1	0	20 000	91.2
2	0.5	20 000	95.7
3	0.75	20 000	94.1



(a) 0.5dropout 率效果图

(b) 0.75dropout 率效果图

Fig.4 Detection results of different Dropout ratios

图 4 不同 Dropout 率检测结果

检测模型训练一段时间后,我们才能看到学习率是否真的太慢或真正不稳定.在网络结构、数据集不变的情况下,设定网络结构中 Dropout 率为 0.5,批处理大小为 64,对 7 类交通目标进行训练,对比不同学习率的测试情况.图 5 给出了学习率为 $1e-3$ 和 $1e-5$ 的情况.从图中可以看出,设置学习率 $1e-3$ 效果更好.因而在实际训练过程中,设定学习率为 $1e-3$.

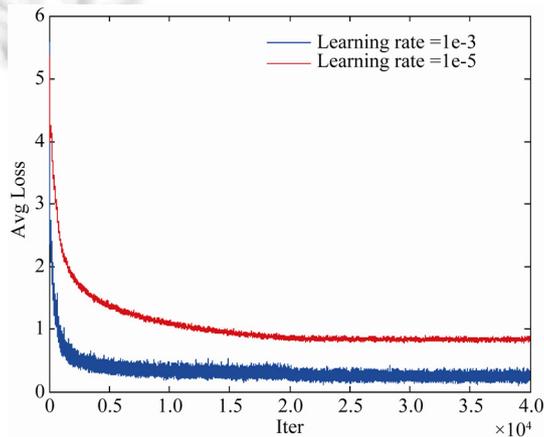


Fig.5 Avg Loss of different learning ratios

图 5 不同学习率下的 Avg Loss

综合以上实验结果,本文车辆目标检测模型参数设置为 Dropout 率为 0.75,训练迭代次数 20 000 次,初始化学习率为 $1e-3$.

3.3 不同目标检测方法实验结果及分析

本文构建的车辆目标检测方法不仅能够定位车辆位置,而且能够对交通场景中常见的目标进行粗粒度分类.图 3 和图 6 给出了交通目标粗粒度识别情况.本方法能够较为准确地定位出车辆目标位置及大小信息,而且还可以识别出图像中的小轿车、公交车、面包车、摩托车、行人等目标.

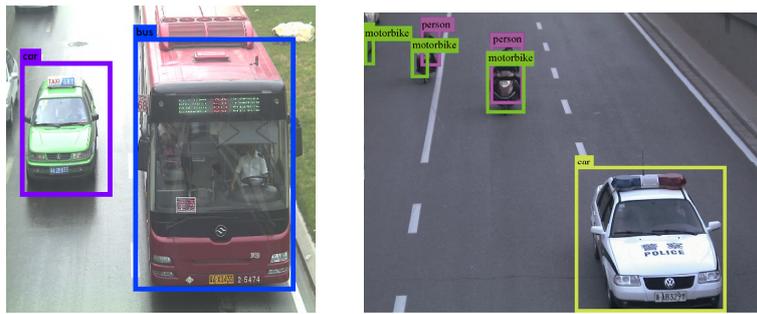


Fig.6 Coarse-Grained classification of traffic objects

图 6 交通目标粗粒度识别

为了验证基于卷积神经网络的车辆目标检测方法的效率,我们测试了 4 类交通目标(轿车、客车、货车、面包车).表 3 列出了实验结果,包括单目标检测识别准确率、平均准确率以及每检测识别 1 张图像平均花费的时间.

Table 3 Detection results of different vehicle object detection algorithms

表 3 不同车辆目标检测算法结果比较

检测方法	轿车(%)	客车(%)	货车(%)	面包车(%)	平均准确率(%)	检测时间(ms)
R-CNN	86.6	87.0	84.2	81.0	84.7	344.73
Faster R-CNN	90.1	88.9	87.0	85.2	87.8	244.73
YOLO	81.4	82.6	79.3	77.8	80.3	58.73
SSD300	95.2	94.4	93.6	91.3	93.6	60.72
Ours	96.7	95.2	94.9	92.1	94.7	50.00

从表 3 可以看出,本文设计的车辆目标检测算法平均检测准确率达到 94.7%,要优于其他几种主流目标检测算法.在检测时间上,本文方法与原始 YOLO 算法接近,检测 1 张高清图像平均花费 50ms,而 SSD300 则需要 60ms,R-CNN 和其加速算法则需要超过 200s.

4 总 结

本文首先介绍了两类主流的基于卷积神经网络的目标检测算法,分析了每个方法的优缺点.然后,在快速的目标检测方法——YOLO 算法基础上设计了一种基于卷积神经网络的车辆目标检测框架.新的检测框架在网络结构设计和模型优化上做了一些工作.在模型结构上,新方法构建了多层感知机卷积层,去掉了复杂的全连接层,在一定程度上增加了特征映射的非线性处理能力;通过锚点框预测车辆目标的类别和坐标,增加了预测目标的数目,提高了目标检测的召回率.通过在神经网络每层引入数据批量规范化处理,进一步提高了目标检测的准确率.最后,通过实验讨论了车辆目标检测模型的参数配置.实验结果表明,本文提出的车辆目标检测算法无论在处理性能还是检测准确率上都优于其他几个方法.

本文的实验都是在单机单 GPU 卡上进行的,为了在工程中应用,达到更快的处理速度,接下来,我们将进一步研究单机多 GPU 卡的目标检测模式以及多机多 GPU 卡的分布式并行处理模式.

References:

- [1] Li YD, Hao ZB, Lei H. Survey of convolutional neural network. Journal of Computer Applications, 2016,36(9):2508–2515 (in Chinese with English abstract).
- [2] Lecun Y, Boser L, Denker JS, Henderson D, Howard RE, Hubbard W, Jackel LD. Backpropagation applied to handwritten zip code Recognition. Neural Computation, 1989,1(4):541–551.
- [3] Szegedy C, Liu W, Jia YQ, Sermanet P, Reed S. Going deeper with convolutions. In: Proc. of the IEEE Conf on Computer Vision and Pattern Recognition (CVPR). 2015. 1–9.

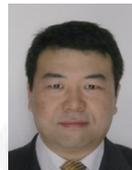
- [4] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556, 2015.
- [5] Han K, Wang DL. Neural network based pitch tracking in very noisy speech. IEEE/ACM Trans. on Audio, Speech, and Language Processing, 2014,22(12):2158–2168.
- [6] Ouyang WL, Wang XG. Joint deep learning for pedestrian detection. In: Proc. of the IEEE Int'l Conf. on Computer Vision (ICCV). 2013. 2056–2063.
- [7] Zhang Y. Research on license plate detection and face detection based on deep convolution neural network [Ph.D. Thesis]. Zhengzhou: Zhengzhou University, 2015 (in Chinese with English abstract).
- [8] Tan ZG. Traffic sign detection and recognition based on multiresolution convolution network [Ph.D. Thesis]. Dalian: Dalian University of Technology, 2015 (in Chinese with English abstract).
- [9] Girshick R, Donahue J, Darrell T, Malik J. Region-Based convolutional networks for accurate object detection and segmentation. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2016,38(1):142–158.
- [10] Girshick R. Fast R-CNN. In: Proc. of the IEEE Int'l Conf. on Computer Vision (CVPR). 2015. 1440–1448.
- [11] Ren SQ, He KM, Girshick R, Sun J. Faster R-CNN: Towards real-time object detection with region proposal networks. In: Advances in Neural Information Processing Systems. 2015. 91–99.
- [12] Redmon J, Divvala S, Girshick R, Farhadi A. You only look once: Unified, real-time object detection. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). 2016. 779–788.
- [13] Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu CY, Berg AC. SSD: Single shot multibox detector. In: Proc. of the European Conf. on Computer Vision (ECCV). Springer Int'l Publishing, 2016. 21–37.
- [14] Redmon J, Farhadi A. YOLO9000: Better, faster, stronger. arXiv preprint arxiv:1612.08242v1, 2016.
- [15] Lin M, Chen Q, Yan SC. Network in network. arXiv preprint arXiv:1312.4400, 2013.
- [16] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: Proc. of the 32nd Int'l Conf. on Machine Learning (ICML). 2015. 448–456.
- [17] Srivastava N, Hinton GE, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. Journal of machine learning research, 2014,15(1):1929–1958.

附中文参考文献:

- [1] 李彦冬,郝宗波,雷航.卷积神经网络研究综述.计算机应用,2016,36(9):2508–2515.
- [7] 张勇.深度卷积神经网络在车牌和人脸检测领域的应用研究[博士学位论文].郑州:郑州大学,2015.
- [8] 谭贞刚.基于多分辨率卷积网络的交通标志检测与识别[博士学位论文].大连:大连理工大学,2015.



陈宏彩(1981—),女,河北唐山人,助理研究员,CCF 专业会员,主要研究领域为图像处理,机器学习.



张常有(1970—),男,博士,教授,CCF 专业会员,主要研究领域为并行与分布式软件,智能信息网络.



程煜(1974—),男,博士,研究员,CCF 高级会员,主要研究领域为图像处理,机器学习.