

基于轻量级网络的 PCB 元器件检测

产世兵,刘宁钟,沈家全

(南京航空航天大学 计算机科学与技术学院,江苏 南京 211106)

摘要:随着电子工业的迅速发展,电路板元器件的缺陷检测愈加重要。传统的人工检测方法效率很低,而且容易因为视觉疲劳造成错误检测,可靠性低,速度慢。目前广泛应用的自动光学检测设备,缺点明显,速率低,对直插元器件的检测精度低,无法适应电路板元器件的多样性检测。随着对卷积神经网络的深度研究,神经网络在目标检测方面已经达到了优秀的效果,但是常见的网络对 PCB 元器件中的小目标以及实时检测并不理想。对基于 Faster RCNN 和 PeleeNet 网络的研究,实现了轻量级小目标检测模型;通过先验知识修改了 RPN 网络的包围框大小;针对 PCB 元器件样本的小目标样本少的问题,利用了小目标样本扩增技术,提高了整体的检测速度以及精度。通过消融实验体现了改进部分对 PCB 元器件实时检测的重要性;通过对比实验,该方法在保证检测精确度降低很小的同时,缩小了模型的大小,在数据集上具有 0.858 的 mAP,检测时间为 0.034 s,相比 Faster RCNN(基础网络为 VGG16 或 ResNet50)的检测速度有了不错的提高。

关键词:PCB 元器件;卷积神经网络;轻量级网络;小目标检测;实时检测

中图分类号:TP391.4

文献标识码:A

文章编号:1673-629X(2020)10-0014-07

doi:10.3969/j.issn.1673-629X.2020.10.003

PCB Component Detection Based on Lightweight Network

CHAN Shi-bing, LIU Ning-zhong, SHEN Jia-quan

(School of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics,
Nanjing 211106, China)

Abstract: With the rapid development of electronic industry, defect detection of circuit board components has become increasingly important. Traditional manual detection method is inefficient and easy to cause error detection due to visual fatigue, low reliability and slow speed. At present, the widely used automatic optical detecting equipment has obvious disadvantages, low speed, low detection precision for the components directly inserted, which cannot be adapted to the diversity detection of the circuit board components. With the in-depth study of convolutional neural networks, the neural network has achieved excellent results in target detection, but the common network is not ideal for small targets and real-time detection in PCB components. Based on the research of Faster RCNN and PeleeNet network, the lightweight small target detection model is realized. The bounding box size of the RPN network is modified by prior knowledge. Aiming at the problem of small target samples for PCB component, the small target sample augmentation technology is used to improve the overall detection speed and accuracy. Through the ablation experiment, the importance of the improved part to the real-time detection of PCB components is reflected. Through the comparison experiment, the proposed method greatly reduces the size of the model under the premise of ensuring that the detection accuracy does not change much. In the data set, the mAP is 0.858, and the detection time is 0.034 s, which is a much higher rate than the Faster RCNN (VGG16 or ResNet50).

Key words: PCB components; convolutional neural network; lightweight network; small target detection; real-time detection

0 引言

近年来电子工业技术发展迅速,PCB(printed circuit board)电路板从简单板向现在的高密度、高精度、多层化和多样化板方向发展。同时,在体积缩小、性能提高、污染减少、品种增多等方面也在不断进步,这些使得电路板在未来还会保持强大的市场潜力以及生命力。

目前大多数工业流水线上都是由人工配合机器进行生产,这种生产方式可能会因为人类的视觉疲劳等因素,造成电路板上出现一些缺陷,例如元器件误插和漏插等问题。但是,在严密的工业和国防应用的领域中,为了实现信息化和智能化的要求,需要大量的 PCB 电路板,这种精密的部件不能容忍半点差错,否则会导致系统运行不畅甚至是无法运行。所以,在

收稿日期:2019-11-20

修回日期:2020-03-30

基金项目:国家自然科学基金(61375021)

作者简介:产世兵(1994-),男,硕士,研究方向为计算机视觉和模式识别;刘宁钟,教授,博导,研究方向为计算机视觉和模式识别。

PCB 电路板投入使用之前必须对其进行缺陷检测。

对于 PCB 电路板的传统检测方式有人工检测和自动光学设备检测等。PCB 电路板作为大批量生产的产品,需要一种与之契合的快速的、高效的检测方式。随着制造技术的高速发展,传统的检测方式根本无法满足生产的高效性要求。为了提高元器件检测的准确度和速度,该文提出了一个轻量级的目标检测网络,实现了对 PCB 电路板元器件的快速识别与精确定位。

1 相关工作

自动光学检测设备^[1],用于在生产过程中对 PCB 板的品质检测。自动光学检测设备集光学、精密机械、识别诊断算法和计算机技术于一体。检测时,设备通过电荷耦合器件或激光自动扫描 PCB,采集图像后,利用计算机处理,再与数据库中的标准数据进行对比,检测出 PCB 板上的缺陷。尽管自动光学检测能够解决人类检测的一些弊端,但是该技术的可靠性仍然不够,严重依赖于计算机图像处理技术,如果图像处理算法不够有效,将导致误判。

在机器视觉方面,主要包括传统的图像检测算法和基于深度学习的目标检测算法。传统的图像检测算法主要包括图像预处理、特征提取、ROI 提取^[2]等步骤,实现待检测元器件的提取。图像预处理是对图像进行灰度化、增强和平滑的处理;特征提取是利用 Harris^[3]算子的角点检测算法来提取角点;ROI 提取是一种根据角点坐标确定 ROI 区域的方法,能提取出待检测元器件所在区域的图像。

深度学习作为计算机科学研究领域的一个热点,受到了学术界和工业界的广泛关注,并取得了一系列显著的成果,近年来,深度神经网络在目标检测领域表现出了巨大的优势。

近年来,一系列基于深度卷积神经网络的目标检测算法被开发出来,例如, Faster RCNN^[4]、YOLO^[5]、SSD^[6]和 RefineDet^[7]。Faster RCNN 采用区域建议网络(RPN)从候选框中确定目标,然后通过分类定位来进行分类。Faster RCNN 是一种端到端的目标检测方法,实现了接近实时的速率和最优的性能。在 YOLO

中,目标检测任务被视为回归任务,边界框的坐标和框中包含的目标的置信度以及各个类别的概率都是直接从整个图像的所有像素获得。使用 YOLO,每个图像只需要“瞥一眼”就可以知道图像中包含的目标类别以及位置分布。SSD 在整个图像上采用了多尺度的局部特征回归,在保持快速检测的同时保证高精度。在 RefineDet 中,它在检测框架中引入了传输连接块和对象检测模块,可以在保持高效率的同时提高精度。

这些基于深度卷积神经网络的检测模型已经实现了很高的检测精度。但是,深度卷积模型附带大量参数,并且会产生大量计算成本,从而无法有效地进行实时检测。由于处理资源有限,因此将 CNNs 用于实时应用需要高效的计算方法。最近,在学术界出现了大量的轻量级网络,例如 GoogleNet^[8]、MobileNet-v2^[9]、ShuffleNets^[10-11]、PeeleeNet^[12]和 Xception^[13]。与 CNNs 相比,它们都具有较低的计算成本,同时保持了相近的甚至更高的精确度。ShuffleNet-v1^[10]使用逐点分组卷积和通道混合的方式来减少计算成本,与使用 Faster RCNN 检测算法的 MobileNet-v2 相比,具有优越的性能。ShuffleNet-v2^[11]提出了轻量级网络的四个设计标准。根据这些设计,作者指出了 ShuffleNet-v1 的一些缺点,并在此基础上进行了改进。在 PeeleeNet 中,作者提出了 DenseNet^[14]体系结构的一种变体,称为 PeeleeNet,它改用传统的卷积运算方式,该模型旨在满足对内存和计算预算上的严格约束。

2 模型和方法

该文提出的基于 Faster R-CNN 和 PeeleeNet 网络结合实现的轻量级小目标检测网络,可以用于快速准确地定位 PCB 电路板上的元器件并且进行准确识别。

受 PeeleeNet 和 Faster RCNN 的启发,建立了一个用于小目标检测的轻量级网络,该网络可以有效地从小目标中提取特征,同时减小网络开销。轻量级小目标检测网络总体结构如图 1 所示,该结构一共包含五个阶段。前四个阶段是特征提取网络,不同于原本的 PeeleeNet 结构,舍弃了原文结构的最后一个阶段,并且舍弃了阶段 3 的平均池化层,获得一个 256 维的特征图用于区域建议网络和 ROI Pooling。

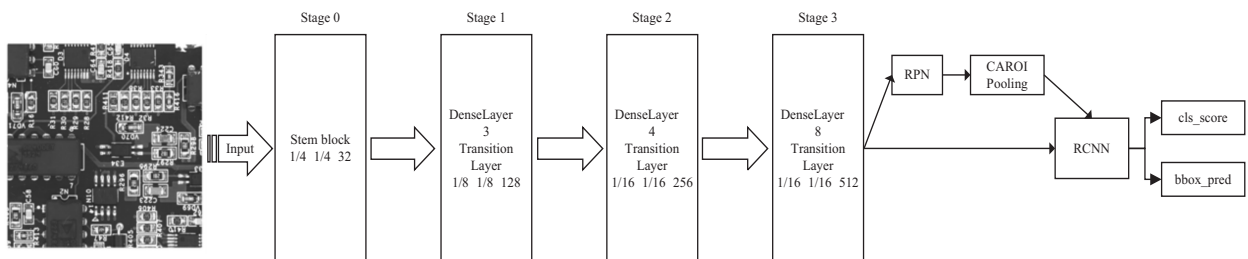
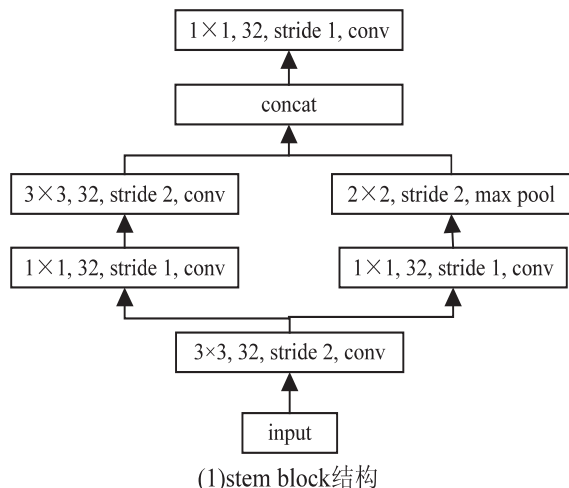


图 1 网络结构

2.1 模型

PeleeNet 是一种轻量型的卷积神经网络,如图 2 所示,它主要由两种结构组成:stem block 和 dense block。stem block 结构,在增加很少的额外计算量的前提下,增强了网络的特征表达能力,使特征图的语义信息更加丰富。它利用双通道的方式进行特征提取并进行融合。不同于原始的 stem block 结构,该文首先在 max pool 前添加一个 1×1 conv 层,这是因为在越深的网络层中语义信息更加抽象,感受野更大,普通的



3×3 卷积核无法提取小物体的特征,使用 1×1 卷积核来提取特征,该特征具有相对较小的感受野,在深层网络对提取小目标特征有利。而且 1×1 卷积核执行非线性运算,可以大大提高模型的非线性特征表达能力。另一个通道使用 1×1 大小和 3×3 大小的卷积核来提取特征,然后对两个通道进行融合。其中, 3×3 卷积核在小物体特征提取的初始阶段具有较大的视野,可以减少特征提取初始阶段的信息丢失。

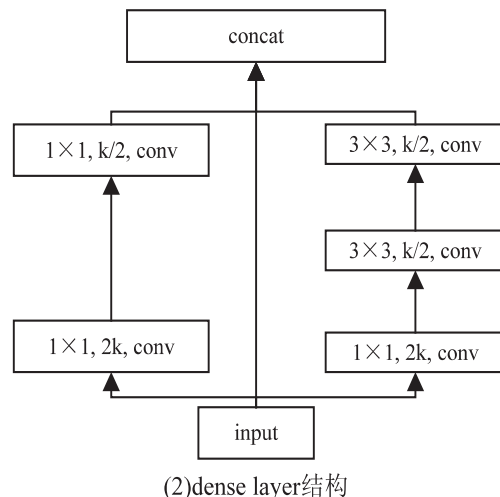


图 2 PeleeNet

其次,受到 shuffleNet-v2 的启发,相同的网络结构,卷积层的输入输出通道数会大大影响模型的速度。假设一个 1×1 卷积层的输入特征通道数是 c_1 , 输出特征尺寸是 h 和 w , 输出特征通道数是 c_2 , 那么经过 1×1 卷积层的浮点计算量 (float-point operations, FLOPs) 的公式如下:

$$\text{FLOPs} = hwc_1c_2 \quad (1)$$

接下来计算内存访问消耗时间 (memory access cost, MAC), 经过 1×1 的卷积后, 输入和输出的特征的尺寸大小并不变化, 那么计算公式如下:

$$\text{MAC} = hw(c_1 + c_2) + c_1c_2 \quad (2)$$

根据均值不等式, 可以得到式 (3):

$$\text{MAC} \geq 2\sqrt{hw\text{FLOPs}} + \frac{\text{FLOPs}}{hw} \quad (3)$$

把式 (1) 和式 (2) 代入式 (3), 可以得到 $(c_1 - c_2)^2 \geq 0$, 该等式的成立条件是 $c_1 = c_2$, 也就是输入输出特征通道数相等时, 在 FLOPs 给定的前提下, MAC 可以达到最小值。shuffleNet-v2 通过实验证明输入输出特征通道数相同时, 模型的检测速度最快。这也就表明了输入输出通道数相同时, 内存访问消耗时间最小, 模型的速度最快。所以为了提升模型的检测速度, 分别统一了 stem block 和 dense layer 中的输入输出特征通道数。

最后, 在 PeleeNet 中, 作者结合 SSD 构建目标检

测网络, 但是 SSD 在小目标检测中表现并不好, 所以该文结合 Faster RCNN 构建目标检测网络。在原始的 Faster RCNN 中, 作者利用 ROI Pooling 层使生成的候选框映射成固定大小的特征图。但是, ROI Pooling 会使小目标在 pooling 之后导致物体结构失真, 会影响后层的目标框的回归定位, 对于大目标的检测准确率影响不大, 但对小目标的影响很大。为了解决小目标在 ROI Pooling 时结构失真的问题, 受 S1Net^[15] 的启发, 使用 Context-Aware ROI Pooling 代替原文中的 ROI Pooling 层。如图 3 所示, 分别为原文 ROI Pooling 和 CAROI Pooling 的结果, 其中 (1) 为原图; (2) 为原图的建议区域; (3) 为 ROI Pooling 的结果, 会有重影; (4) 为 CAROI Pooling 的结果, 没有重影。




图 3 ROI Pooling 和 CAROI Pooling 的结果

该文使用 Context-Aware ROI Pooling 代替 ROI Pooling 层, 解决了 Pooling 后物体失真的问题, 明显提

升了小目标检测的精度。

2.2 训练过程

RPN 区域建议网络将优化的 PeleeNet 网络提取的特征图作为输入,文中特征图大小为原图大小的 1/16,输出为一系列的提议框,每个提议框都有得分。




图 4 RPN 层

在 Faster RCNN 原文中,特征图的大小为原图大小的 1/32,也就是特征图上的每个点对应原图上的 32×32 个像素点,原文采用的建议框比例和尺度分别为(0.5,1,2)和(8,16,32),建议框映射到原图上的大小也就是(256,512,1 024)。该文前面提到了用作 RPN 网络输入的特征图大小为原图大小的 1/16,所以将建议框的尺度改为(16,32,64),映射到原图上的大小为(256,512,1 024)。但是这样的建议框的大小用在文中的数据集上并不合适,根据先验知识和实验表明,文中的数据集最适合的建议框的比例和尺度为(0.5,1,2)和(8,16,32),映射到原图上的大小为(128,256,512)。

在使用 ImageNet 与训练模型初始化文中的网络时,实验结果表现并不好,这是由于 ImageNet 数据分布和文中的 PCB 板元器件数据集分布完全不同,差异较大。所以在网络初始化时,利用 Kaiming^[16]初始化方式,实验结果表明效果很好。

在训练时,模型的迭代次数为 300 k,区域建议网络的批量大小为 256,在每次迭代中,模型都会预测建议框的类别和边界框。然后将预测框 B_p 与真实框 B_g 的交并比大于 0.7 的作为正样本,将交并比小于 0.3 的作为负样本,抛弃交并比在 0.3~0.7 之间的样本,并且保证正负样本的数量比例为 1:1。IOU 的定义如下:

$$IOU = \frac{\text{area}(B_p \cap B_g)}{\text{area}(B_p \cup B_g)} \quad (4)$$

其中, $\text{area}(B_p \cap B_g)$ 表示 B_p 与 B_g 的交集, $\text{area}(B_p \cup B_g)$ 表示 B_p 与 B_g 的并集。

将所有正样本和负样本都输入到损失函数中。

为了生成区域建议框,通过 3×3 的窗口在特征图上滑动,每个窗口都映射到 256 维的特征向量,然后对特征向量进行目标分类和回归。如图 4 所示,每个滑动窗口都预测 9 个不同长宽比例和尺度的建议框。

另外使用多任务损失函数来训练网络,其目的是使得分类和定位的误差最小。多任务损失函数定义如下:

$$L(p_i, \text{loc}_i) = L_{\text{cls}} + \lambda L_{\text{reg}} \quad (5)$$

其中, i 表示每个迭代中预测框的索引, L_{cls} 是分类的 softmax 损失函数, L_{reg} 是预测框的回归损失函数,使用的是 smoothL1 损失。 N_{cls} 和 N_{reg} 分别表示每个迭代批次的图片区域的个数和预测框的数量。在这里,设置 $\lambda = 2$,是为了使 L_{cls} 和 L_{reg} 的权重一样。损失函数定义如下:

$$\begin{cases} L_{\text{cls}} = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) \\ L_{\text{reg}} = \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(\text{loc}_i, \text{loc}_i^*) \\ L_{\text{reg}}(\text{loc}_i, \text{loc}_i^*) = f_{\text{L1}}(\text{loc}_i - \text{loc}_i^*) \end{cases} \quad (6)$$

其中, p_i 表示每个预测框分类的分数, p_i^* 表示真实标签, loc_i 表示每个预测框的预测矢量值, loc_i^* 表示真实边界框的矢量值, f_{L1} 是鲁棒的 smoothL1 损失函数,它对离群的值较为不敏感, $\text{smooth}_{\text{L1}}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & \text{其他} \end{cases}$ 。在训练的最后阶段,将获得的区域传递给 ROI 建议层和 RCNN 层,然后通过两个全连接层来预测目标的类别和边界框。

该网络模型通过随机梯度下降来训练。在训练阶段,使用 0.000 1 的权重衰减和 0.9 的动量。对于前 100k 迭代,学习率设置为 0.001,对于接下来的 200k 迭代,学习率设置为 0.000 1。RPN 批量大小设置为 256。为了抑制冗余框,基于置信度得分对建议框采用了非极大值抑制算法。

3 实验结果及分析

3.1 小目标

在该数据集中具有很多小目标,小目标大小占据整个图片的比例很小,难以检测。小目标难以检测的原因包括:分辨率低,图像模糊,携带的信息少。由此导致特征表达能力弱,也就是在提取特征的过程中,能提取到的特征非常少,这不利于对小目标的检测。在 MS COCO 数据集中,对小目标、中目标和大目标的定义如表 1 所示。

表 1 MS COCO 小、中、大目标的定义

类型	最小面积	最大面积
小目标	0×0	32×32
中目标	32×32	96×96
大目标	96×96	∞×∞

为了解决小目标检测精度不高的问题,在小目标数据集上做出了两点改进。第一点,通过对包含小目标的图像进行 oversampling 操作。第二点,通过在每个包含小目标的图像中多次复制粘贴小目标来处理,复制目标时,确保不会和已经存在的目标有任何交叠。这增加了小目标位置的多样性,同时确保这些目标出现在正确的上下文中。

3.2 数据集

该数据集是从 PCB 板生产线上通过高精度相机拍照而得到的,一般为 CCD 相机或者是 CMOS 相机。原图大小为 2 048×2 048 的分辨率,为了获取更多小目标的特征信息,将原图切割成 1 024×1 024 大小的图片作为训练集。但是,PCB 的数据集很难获取,能获取到的数据量很少,很难满足本章提出的网络训练达到收敛的需求,并且容易出现过拟合的状况。为了解决训练时所需的数据量,采用深度学习中数据增广的方式来增加训练数据集,让数据集尽可能多样化,使得训练的模型具有更强的泛化能力。

使用的数据增广的方法主要包括:水平或垂直翻转,旋转,缩放,裁剪,平移,对比度调整,色彩抖动和添加噪声等。经过数据增广过后的数据集,用作训练数据的有 20 664 张,用作测试数据的一共有 3 036 张。数据集一共包含元器件 11 类,总的分为电容、芯片、电阻、三极管和二极管五个大类,每个大类下有若干个小类,其中小目标类为第 7 类,它们的最大尺寸不超过 32×32。

3.3 结果及分析

这部分将在提供的数据集上测试结果。同时,对提出的模型性能进行分析,并与其他方法进行了比较。实验环境为基于 Caffe 深度学习框架,CPU 为 i7-8700k,显卡为 RTX 2080 Ti 11 GB 显存,物理内存为 16 GB,操作系统为 Ubuntu 16.04。

在该模型中,使用广泛应用的召回率、准确率和 mAP 标准来评估性能。召回率表示总样本中有多少个正例被分为正例,定义为:

$$P = \frac{TP}{TP + FP} \quad (7)$$

准确率表示被分为正例的目标中实际为正例的比率,定义为:

$$R = \frac{TP}{TP + FN} \quad (8)$$

其中,TP 表示将正样本预测为正的数目,FP 表示将负样本预测为正的数目,FN 表示将正样本预测为负的数目。

平均均值精度 mAP 是反映整体性能的检测指标,定义为:

$$mAP = \int_0^1 P(R) dR \quad (9)$$

如表 2 所示,通过消融实验表现了模型各个部分的重要性,统一通道数可以很大提升检测速度,其他各个组件对 mAP 的提高有不错的效果。

表 2 各个组件的表现

组件	是否应用					
1×1 conv	✓	✓	✓	✓	✓	✓
统一通道数		✓	✓	✓	✓	✓
CAROI Pooling			✓	✓	✓	✓
小目标增广				✓	✓	✓
建议框修改						✓
mAP	0.734	0.786	0.784	0.801	0.836	0.858
检测时间/s	0.040	0.042	0.032	0.034	0.034	0.034

实验结果如表 3 所示,在该数据集上运行了 VGG16^[17] 模型、ResNet50^[18] 模型以及文中利用

PeeleNet 改进后的模型。

表 3 实验结果对比

网络	参数量	mAP/%	检测时间/s
VGG16	138 M	86.0	0.056
ResNet50	23.48 M	86.8	0.050
文中网络	1.1 M	85.8	0.034

通过表中数据对比可以看到,文中模型在保证 mAP 没有多少降低的前提下,在速度上有很大的提升。同时,在小目标的检测精度上也有不错的结果。部分实验结果如图 5 所示。




图 5 检测结果

4 结束语

基于 PeleeNet 网络和 Faster RCNN 目标检测模型设计了一个轻量级卷积神经网络检测模型,该模型在 PCB 板元器件数据集上具有较好的精度和较高的速度。

该检测模型在 PeleeNet 的基础上改变 stem block 的结构,统一通道数量,并且结合 Faster RCNN 和 CAROI Pooling,同时通过先验知识设计了 anchor box 的大小来提高检测速度和保持检测精度。实验结果表明,该检测模型在 PCB 板元器件检测上有很好的效果。

在小目标的问题上,对小目标数据集进行了增广,提升了小目标的检测精度。但是,该检测模型仍然存在一些缺陷。例如,虽然模型速度有提高,但提高的幅度不够大,而且精度也有下降。在以后的工作中,将把工作重心放在提升模型速度和精度上。

参考文献:

[1] 黄卫平. 印刷电路板自动光学检测系统精确校准[J]. 电子设计工程,2012,20(13):117-120.

[2] 唐永鹤,陶华敏,卢焕章,等. 一种基于 Harris 算子的快速图像匹配算法[J]. 武汉大学学报:信息科学版,2012,37(4):406-409.

[3] 陈典典,程培培,马军山. 基于 Harris 角点检测和聚类算法的掌纹图像 ROI 提取方法[J]. 光学仪器,2018,40(5):27-34.

[4] REN S, HE K, GIRSHICK R, et al. Faster r-cnn: towards real-time object detection with region proposal networks [C]//Advances in neural information processing systems. San Francisco: Morgan Kaufmann, 2015: 91-99.

[5] 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. Las Vegas, NV, USA: IEEE, 2016: 779-788.

[6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot

- multibox detector [C]//European conference on computer vision. Amsterdam; Springer, 2016; 21–37.
- [7] ZHANG S, WEN L, BIAN X, et al. Single-shot refinement neural network for object detection [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City, UT, USA; IEEE, 2018; 4203–4212.
- [8] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Boston, MA, USA; IEEE, 2015; 1–9.
- [9] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City, UT, USA; IEEE, 2018; 4510–4520.
- [10] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: an extremely efficient convolutional neural network for mobile devices [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City, UT, USA; IEEE, 2018; 6848–6856.
- [11] MA N, ZHANG X, ZHENG H T, et al. Shufflenet v2: practical guidelines for efficient CNN architecture design [C]//Proceedings of the European conference on computer vision (ECCV). Munich, German; IEEE, 2018; 116–131.
- [12] WANG R J, LI X, LING C X. Pelee: a real-time object detection system on mobile devices [C]//Advances in neural information processing systems. San Francisco; Morgan Kaufmann, 2018; 1963–1972.
- [13] CHOLLET F. Xception: deep learning with depthwise separable convolutions [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu, HI, USA; IEEE, 2017; 1251–1258.
- [14] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu, HI, USA; IEEE, 2017; 4700–4708.
- [15] HU X, XU X, XIAO Y, et al. SINet: a scale-insensitive convolutional neural network for fast vehicle detection [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20 (3): 1010–1019.
- [16] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: surpassing human-level performance on imagenet classification [C]//Proceedings of the IEEE international conference on computer vision. Santiago, Chile; IEEE, 2015; 1026–1034.
- [17] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]//International conference on learning representations. San Diego, CA, USA; ICLR, 2015; 1150–1210.
- [18] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning [C]//Thirty-first AAAI conference on artificial intelligence. San Francisco, California, USA; AAAI, 2017.