DOI: 10. 13382/j. jemi. B2104821

# 轻量化 CenterNet 网络的二维条码定位算法\*

万伟形1 李长峰2 朱华波1 陶友瑞1

(1.河北工业大学机械工程学院 天津 300401;2.常州铭赛机器人科技股份有限公司 常州 213162)

摘 要:针对复杂工业、物流运输场景中传统的二维条码定位算法效率和稳定性较低的问题,提出了一种基于轻量化的 CenterNet 网络的二维条码定位算法。针对实际情况中二维条码尺寸变化问题,采用 CSPDarkNet53-tiny 作为主干网络并对其加 以修改。添加 SPP 模块以提高网络精度,对 CenterNet 的上采样以及输出模块部分进行轻量化改造,使用 5×5 深度可分离卷积 代替普通卷积,并在训练时采用余弦退火学习率策略防止过拟合。实验结果表明,在定位准确率仅比 YOLOv4-tiny 降低 0.64% 的情况下,不仅能够避免传统算法准确率受背景影响大、鲁棒性不强等问题,而且实时推理速度可以达到 124 fps,可以更好的 用于低硬件配置下各种二维条码定位。

## Two-dimensional barcode positioning algorithm of lightweight CenterNet network

Wan Weitong<sup>1</sup> Li Changfeng<sup>2</sup> Zhu Huabo<sup>1</sup> Tao Yourui<sup>1</sup>

(1. School of Mechanical Engineering, Hebei University of Technology, Tianjin 300401, China;2. Changzhou Mingseal Robot Technology Co., Ltd., Changzhou 213162, China)

Abstract: Aiming at the low efficiency and stability of the traditional two-dimensional bar code positioning algorithm in complex industrial and logistics transportation scenarios, a two-dimensional bar code positioning algorithm based on lightweight CenterNet network is proposed, a lightweight CenterNet detection algorithm is proposed. In view of the size change of two-dimensional bar code in the actual situation, CSPDarknet53-tiny is used as the backbone network and modified SPP module is added to improve the accuracy of the network. The upsampling and detection head of CenterNet are lightweight transformed.  $5 \times 5$  depth separable convolution is used to replace ordinary convolution. The change strategy of learning rate during training adopts cosine annealing learning rate to prevent over fitting. The experimental results show that the positioning accuracy is only 0.64% lower than YOLOv4 tiny. It not only avoids the problems that the accuracy of the traditional algorithm is greatly affected by the background and the robustness is not strong, the real-time reasoning speed also reaches 124 fps, which can be better used for all kinds of two-dimensional bar code location under low hardware configuration.

Keywords: object detection; two-dimensional barcode positioning; CenterNet network; lightweight network

## 0 引 言

条码技术是依靠计算机等技术的发展而产生的自动 识别技术,是实现信息准确且快速采集的重要手段。由 于条码技术具有快速、准确的特点,因此广泛被应用于工 业生产、产品流通等方面。在各种条码中,二维条码由于 信息容量大、纠错能力强而被广泛使用。二维条码通常 包括 QR(quick response)码、DM(data matrix)码两种类 别,每种类别的二维条码均有许多大小不同的规格。在 实际应用中,由于摄像头或产品的高速移动以及生产速 度的需要,对于二维条码的识别速度有很高的要求。二

收稿日期: 2021-10-19 Received Date: 2021-10-19

<sup>\*</sup>基金项目:国家重点研发计划项目(2020YFB2009400)资助

维条码的识别通常分为定位与解码两个部分,解码程序 的运行时间通常相对固定且较短。因此,为了满足二维 条码识别速度的高要求,需要设计高速的二维条码定位 算法。

传统的二维条码定位方法通常先对图片进行预处 理,然后利用角点检测等方法进行特征点检测,并根据检 测结果筛选可能存在二维条码的区域进行粗定位,最后 通过查找条码区域边缘的方法来对二维条码进行精确定 位。张万鹏等[1]通过对图像进行高斯滤波、二值化操作 后,利用开运算将条码变为矩形条,最后定位矩形条来确 定条码的位置。但是该方法没有考虑背景复杂可能会导 致的定位区域不准、定位错误等问题。针对二维条码识 别的背景复杂问题, 王伟等<sup>[2]</sup>提出一种基于 Hough 变换 的最佳边缘组合算法。该算法能够在有划痕的背景下准 确提取出 DM 码的边缘,提高了复杂背景下二维条码识 别精度,但该方法仍然只有86%的准确度,且速度平均在 739 ms,无法满足工业生产以及产品流通需要;由于 Hough 变换检测可能会因为干扰产生"虚假直线",导致 最终定位耗时较长,为了解决该问题,李东等[3]提出基于 角点分布的 DM 码候选区域快速定位方法。通过 Harris 角点检测预筛选结合改进的 Hough,使得检测精度与速 度大幅度提升,但该方法在背景有较多噪点时效果不佳; 为了提高角点检测的精确度,原渊<sup>[4]</sup>通过结合 ORB 描述 子与霍夫变换,获得了95%的条码定位准确率,但是依然 会受到背景噪声的影响。

传统方法定位方法在二维条码与背景颜色差异较大 且二维条码清晰时能够有较快的定位速度。但实际情况 中,二维条码背景通常比较复杂,可能存在干扰较多导致 在粗定位过程中候选区域太多、筛选困难等问题,导致定 位时间增加以及定位准确率的降低。尽管传统方法的生 产成本低,但对于实际环境下复杂背景的二维条码速度 与鲁棒性有一定的局限性,因此越来越难以满足生产、运 输等高速场景的需要。

近年来,卷积神经网络进入飞速发展时期,视觉图像 检测方面也有很大突破,检测准确度与速度得到进一步 提升<sup>[5]</sup>。Girshick等<sup>[6]</sup>提出的 R-CNN 算法是目标检测的 先例,利用 CNN 提取目标特征并用 SVM 分类器识别,但 该算法识别二维条码时速度太慢,对硬件配置要求过高; 针对 R-CNN 两阶段检测导致神经网络检测速度太慢的 问题,Redmon等<sup>[7]</sup>提出了单阶段目标检测网络 YOLO。 该算法完全抛弃了两阶段检测采用的"提案检测+验证" 的检测范式,直接在全连接层完成了物体分类与目标检 测,能够大大提高二维条码的定位速度,但是定位精度方 面仍有不足;Liu 等<sup>[8]</sup>提出 SSD 神经网络,引入了多参考 以及多分辨率检测技术,有效提高了单阶段目标检测器 的精度和二维条码的定位精度。将卷积神经网络用于二 维条码检测可以减少背景复杂程度对于时间以及准确率 的的影响,更加符合如今高速、高精度的要求。

在实际生产时,由于成本的限制,硬件配置无法很高 且无法及时、快速地进行硬件的迭代,对依赖于硬件配置 的各种目标检测算法提出了更高的要求。由于背景的复 杂多变,对定位程序的鲁棒性要求也更高。

因此,本文提出一种基于轻量化 CenterNet 网络的二 维条码快速定位算法。该算法不仅能够减少背景复杂度 对二维条码的定位带来的影响,同时在定位准确率基本 不变的情况下,能够在相对较低配置设备上保证运行速 度,更加适应各种生产、运输环境。

## 1 CenterNet 目标检测网络

目标检测算法按照有无预设锚框为基准可以分为 Anchor-free 方法与 Achor-based 方法。Anchor-free 算法 主要有 ConerNet<sup>[9]</sup>、CenterNet<sup>[10]</sup>、FOCS<sup>[11]</sup>等, Achorbased 主要有 YOLO 系列、SSD、RetinaNet<sup>[12]</sup>等。由于 Anchor-based 有部分缺陷存在,例如针对不同的数据集 需要设定不同的锚框,锚框的设定会对精度产生影 响<sup>[11]</sup>;需要进行非极大值抑制(non-maximum suppression)等后处理,导致算法运行速度降低<sup>[13]</sup>。为了 解决以上缺陷,Anchor-free 目标检测算法逐渐发展起来。

CenterNet 是从 CornerNet 改进而来的一个基于 Anchor-free 的目标检测算法。相对于 Anchor-based 算 法,该算法去除了复杂锚框设定,进一步提高了算法的运 行效率;由于没有锚框固定尺寸的限制,对于不同尺寸和 规格的二维条码适应能力更强,准确度更高;由于直接在 热力(heatmap)图上进行了过滤操作,不需要再次进行 NMS处理,提升了整个算法的运行速度。

CenterNet 的网络结构如图 1 所示,其主干网络提供 了 Hourglass、DLA、ResNet 几种不同的结构。输入图像经 过主干网络后会生成包含关键点的热力图,最后通过检 测模块对获取到的热力图进行卷积,得到关于物体中心 点位置、中心点偏移以及物体宽高信息。



Fig. 1 Network structure of CenterNet

CenterNet 的损失函数由3部分组成。热力图的损失 函数采用 Focal Loss 函数的思想,如式(1)所示。

$$L_{k} = \frac{1}{N} \sum_{xyc} \begin{cases} (1 - \hat{Y}_{xyc})^{\alpha} \log(\hat{Y}_{xyc}), \hat{Y}_{x,y,c} = 1\\ (1 - Y_{xyc})^{\beta} (\hat{Y}_{xyc})^{\alpha} \log(1 - \hat{Y}_{xyc}), \notin \mathbf{th} \end{cases}$$
(1)

其中,  $\alpha$ ,  $\beta$  是 Focal Loss 的超参数, 设置为 2 和 4, *N* 为图像中关键点的个数, 除以 *N* 的操作即为了将 Focal Loss 归一化。

在图像下采样时,由于数据的离散会导致 GT 关键 点产生偏移,故 CenterNet 添加了偏置损失用以预测局部 偏移,如式(2)所示。

$$L_{off} = \frac{1}{N} \sum_{p} |\hat{O}_{p} - \left(\frac{p}{R} - p\right)|$$
(2)

对于目标物体的大小, CenterNet 为每个目标种类都 使用单一的尺寸预测,并使用 L1 Loss 作为尺寸预测的损 失函数, 如式(3) 所示。

$$L_{size} = \frac{1}{N} \sum_{k=1}^{N} |\hat{S}_{pk} - s_k|$$
(3)

CenterNet 的总损失函数由上述 3 部分线性组合而成,即:

$$L_{det} = L_k + \lambda_{size} L_{size} + \lambda_{off} L_{off}$$
(4)

各个损失中的超参数为 CenterNet 中使用的超参数 $\lambda_{size} = 0.1, \lambda_{off} = 1_{o}$ 

## 2 轻量化 CenterNet 网络

#### 2.1 深度可分离卷积

本文为了对 CenterNet 进行轻量化改造,在网络中使 用深度可分离卷积替换部分通常卷积。深度可分离卷积 (depthwise separable convolution, DSC)实质是将普通卷积 分为两步:DepthwiseConv 与 PointwiseConv,其输入与输出 并未改变,但是运算量和参数量大大减少<sup>[14]</sup>。

深度可分离卷积结构如图 2 所示。假设输入特征图 大小为  $W \times W \times C_1$ ,其中 W 为输入特征图的宽/高, $C_1$  为 输入特征图通道数;输出特征图大小为  $W \times W \times C_2$ ,其中 W 为输出特征图的宽/高, $C_2$  为输出特征图通道数;卷积 核尺寸为  $D \times D$ ,其中 D 为卷积核的宽与高。

对于普通卷积,只计算乘法操作的情况下,其运算 量为:

$$W \times W \times C_1 \times C_2 \times D \times D \tag{5}$$

对于深度可分离卷积,只计算乘法操作的情况下,其 DepthwiseConv运算量为:

$$D \times D \times C_1 \times W \times W \tag{6}$$

$$1 \times 1 \times C_1 \times C_2 \times W \times W \tag{7}$$

总计算量为:

$$D \times D \times C_1 \times W \times W + C_1 \times C_2 \times W \times W \tag{8}$$







则深度可分离卷积与普通卷积计算量之比为:  

$$\frac{D \times D \times C_1 \times W \times W + C_1 \times C_2 \times W \times W}{W \times W \times C_1 \times C_2 \times D \times D} = \frac{1}{C_2} + \frac{1}{D^2}$$
(9)

根据式(9)可以看出深度可分离卷积相对于普通卷 积计算量大大减少,能够提高卷积网络运行速度,减少网 络参数量。

本文为了扩大感受野、提高网络精度,将所有深度可 分离卷积的卷积核由设置为5×5。由于深度可分离卷积 的存在,卷积核由3×3 变为5×5 仅增加了少量计算量, 但是感受野却大大增加,有效提高网络获取重要信息的 能力。

#### 2.2 改进的主干网络

CenterNet 的网络主干 ResNet50、Hourglass 等过于庞 大,不适合高速的生产、运输等环境,所以本文将其替换 为精度与速度都比较合适的 CSPDarkNet53-tiny 网络,并 对该主干网络进行修改。

CSPDarkNet53-tiny 作为 YOLOv4-tiny 的主干网络, 是在 YOLOv4<sup>[15]</sup>的主干网络 CSPDarkNet53 的基础上削 减而成。该网络仅对残差块进行删减,减少堆叠次数,保 留了 CSPDarkNet(cross stage partial DarkNet)结构以及残 差结构而成的,相比于 YOLOv4,参数量减少了 90%,速 度提高了 6~8 倍。CSPDarkNet53-tiny 使用了 CSPnet 结 构,并且使用了通道分割的方法,将经过 3×3 卷积后的特 征图划分为两部分,取第 2 部分。

CSPDarkNet 结构在降低网络的参数量、降低网络推 理速度同时提高了网络精度,因此相较于 YOLOv3-tiny, YOLOv4-tiny 速度和精度均得到提高。且由于本文所设 计的神经网络主要用于二维条码的定位,二维条码尽管 尺寸繁多,但其总体形状没有太大改变,不需要很复杂的 网络,所以 CSPDarkNet53-tiny 更加适合作为轻量化网络





图 3 CSPDarkNet53-tiny 网络结构 Fig. 3 Network structure of CSPDarkNet53-tiny

由于二维条码通常在整张图片中所占比例不大,为 了防止下采样次数过多导致提取的特征信息模糊,同时 提高改进后的 CenterNet 网络运行速度,本文对于 CSPDarkNet53-tiny 网络进行修改。删除 CSPDarkNet53tiny 最后一个 CSPBlock 模块,并将 CSPDarkNet53-tiny 前 两层用于压缩特征的通常卷积更换为深度可分离卷积, 减少处理输入特征图产生的庞大的运算量。同时, CSPDarkNet 为了压缩特征图尺寸,在每个 CSP 模块末端 使用了最大池化对特征图进行压缩。参考文献[16]提 出,用卷积层来代替池化层可以降低神经网络的错误率, 故本文将最大池化均用可分离卷积代替,用来提高网络 的准确率。

#### 2.3 SPP 模块

由于在实际生产生活中,二维条码的尺寸差异较大, 对于网络提取不同尺度的目标特征的能力提出了较大的 要求,本文在主干网络之后添加了参考 SPP 结构设计的 模块。

空间金字塔池化(spatial pyramid pooling, SPP)模块 由何恺明团队在 2015 年提出<sup>[17]</sup>。SPP 模块采用了多个 不同尺寸的池化核对输入特征图进行特征提取,能够获 取不同大小的局部特征信息以及全局信息,扩大网络的 感受野、丰富网络表达能力,有效提高网络精度。

本文参考 SPP 原理,使用了图 4 所示的空间金字塔 池化结构。在工业应用中,通常的二维条码检测系统机 器和二维条码的位置相对固定,无法像日常生活中通过 人为调整二维条码位置与面积保证识别率。工业二维条 码在整张检测图像中通常会出现面积占比较小的情况。 为了在工业环境更加通用,更好地获取面积占比较小的 二维条码的特征信息,本文将 SPP 模块中间 9×9 的池化 模块修改为 7×7。SPP 模块首先分别通过 5×5、7×7、13× 13 三种不同的池化模块获取不同的特征信息,然后将获 取到的 3 种特征信息与原特征图利用深度可分离卷积进 行通道、尺寸压缩与特征融合,这样输出的特征图既获得 了全局特征信息,又能够获得池化后不同的局部特征 信息。



#### 2.4 上采样模块与输出模块

CenterNet 的解码模块由 3 个转置卷积堆叠而成,每 次转置卷积将特征图尺寸放大一倍,并将通道数压缩为 原来的 1/2。随着特征图尺寸的增加,转置卷积的运算 量也急剧增加,显然不适合轻量化网络的需求,且转置卷 积在因此需要对上采样模块进行改造。本文采样模块采 用的是最邻近(nearest)插值法与 1×1 通常卷积组合代替 转置卷积。最邻近插值法即在增加图像尺寸时,不需要 计算新的图像中像素点的数值,而是直接通过对应关系 给新图像中的点赋值。在赋值时如果计算出的坐标为非 整数时,选取最邻近的坐标的像素进行赋值。其对应关 系如下式:

$$x = x_{new} \times \frac{w}{w_{new}}$$
(10)  
$$y = y_{new} \times \frac{h}{h}$$
(11)

其中, x、y 分别为原图像中像素点的 x、y 坐标, x<sub>new</sub>、 y<sub>new</sub> 分别为目标图像中像素点的 x、y 坐标, w、h 分别为原 图像的宽高, w<sub>new</sub>、h<sub>new</sub> 分别为目标图像的宽高, 当坐标为 小数时,四舍五入即可。经过最邻近插值法增加特征图 尺寸后再经过 1×1 通常卷积对特征进行压缩融合, 减少 通道数。

针对输出模块,Centernet 共有3个输出模块,分别用 来预测热力图、中心点的偏移以及物体的宽高。每个输 出模块均由一个3×3普通卷积与1×1的普通卷积堆叠 而成,为了将输出模块轻量化,本文将输出模块使用的 3×3普通卷积替换为5×5深度可分离卷积。

#### 2.5 改进后的网络总体结构

本文改进后的 CenterNet 网络总体结构如图 5 所示。

通过对 CenterNet 的主干网络的替换以及上采样、输出模块的轻量化改造,将模型参数量大幅度减少。添加 SPP

模块,实现局部特征与全局特征的融合,在提高精度的同时能够更好地适应实际工况中变化的二维条码尺寸。





Fig. 5 Structure of lightweight CenterNet network

## 3 实验验证

#### 3.1 数据集与实验平台

本文通过收集网络图片、公开二维条码数据集、以及 人工拍摄图片等方式获取共1104张图片,每张图片均 含有各种二维条码图像,其中长方形 Data Mtrix 码图案 1 609 个, 正方形 Data Mtrix 码 642 个, QR 码 1 050 个。 其中数据集图片尺寸为1920×1080.最小的二维条码尺 寸为150×150,训练集与测试集划分比例为8:2,数据集 示例如图 6 所示。本文实验操作系统为 Windows,软件 平台为 PyCharm,训练与测试框架为 Pytorch-1.9.0 版本, cuda10.2版本,硬件平台为 Intel(R) Core(TM) i5-10300H CPU @ 2.50 GHz 型号 CPU, RTX2060(6G) 型号 GPU。为了防止训练过程出现过拟合现象,导致神经网 络模型陷入局部最优解[18],采用余弦退火学习率 (T\_max=20, eta\_min=0.000005)。由于学习率越小,网 络可靠性越好,但训练速度越慢[19],所以权衡速度与效 果,学习率初始值设置为 0.000 5, Batchsize 设置为 16, 训 练至损失基本不再变化时停止训练。

#### 3.2 消融实验

为了能够保证轻量化网络的定位效果,本文主要做 了如下改进:

1)将下采样模块中的池化层用可分离卷积替换;

2)将所有的 3×3 深度可分离卷积替换为 5×5 深度 可分离卷积;



图 6 二维条码数据集示例 Fig. 6 Example of a two-dimensional barcode dataset

#### 3) 在改进的 CSPDarkNet53-tiny 后加入 SPP 模块。

为了验证上述 3 个模块对网络性能的改进,在本文数据集的基础上,以轻量化后未作上述 3 点处理的神经 网络为基线模型,依次施加上述 3 点改进措施进行消融 实验。实验输入图像分辨率为 416×416,以平均召回率 (mean recall)、平均准确率(mean precision)作为评价标 准<sup>[20]</sup>,实验结果如表 1 所示。

Table 1 Ablation experiment

方法	改进1)	改进2)	改进3)	Recall/%	Precision/%
1	×	×	×	96.57	96.32
2		×	×	96.89	97.06
3	$\checkmark$	$\checkmark$	×	97.66	97.82
4	$\checkmark$	$\checkmark$	$\checkmark$	97.92	98.67

消融实验表明,本文所做的各种改进方法能够有效 提高二维条码检测效果,保证轻量化后的网络的召回率 与准确率没有太大损失。

#### 3.3 模型性能对比

本文选取其他几种轻量化网络以及部分传统算法在 本文数据集中进行训练来对比模型检测效果,几种轻量 目标检测神经网络的检测效果如图 7 所示。每组图像从 左到右分别为 YOLOv5-s、YOLOv4-tiny、YOLO-FastestV2、 本文轻量化 CenterNet 的检测效果。通过对比可以看出, 本文改进的 CenterNet 在检测效果与其他优秀的轻量级 卷积神经网络相比上没有太大的差距。



图 7 检测效果对比

Fig. 7 Comparison of detection results

为了进一步验证改进的轻量化 CenterNet 网络的效果,需要对检测的准确度、鲁棒性以及模型运行效率进行 评估。

首先对比网络预测的准确度以及鲁棒性,本文选择 全部数据集以及从数据集中筛选的 300 张污损、遮挡、曝 光不均等问题的二维条码作为特殊数据集。通过对比定 位准确率,评价各种方法的准确度以及鲁棒性,几种模型 的指标对比结果如表 2 所示。实验数据表明,本文提出 的轻量化 CenterNet 网络的定位精度相比传统算法更高, 鲁棒性也更好。同时本文的 CenterNet 网络相比于 YOLOv5-s、YOLOv4-tiny 等轻量化神经网络的定位精度 仅有 1%左右的差距,证明了本文提出的 CenterNet 网络 的有效性。

Table 2	Comparison of	positioning ac	curacy
检测管注	检入公辨索	全部数据集定	特殊数据集准
11110000000000000000000000000000000000	<b></b> 制八刀 <del>加</del> 平	位准确率/%	定位确率/%
Harris 角点检测		93.35	86.43
Hough 直线检测	416×416	92.81	85.17
YOLOv5-s		97.87	97.19
YOLOv4-tiny	410/410	97.25	96.89
YOLO-FastestV2		91.90	89.17
CenterNet		98.62	98.32
Our-CenterNet		96.61	95.15

表 2 定位准确度对比 Fable 2 Comparison of positioning accurat

其次对比模型运行效率与复杂度,采用模型体积与 检测速度作为评价指标,检测速度取对 100 张图片检测 速度的平均值,对比结果如表 3 所示。其中由于 YOLO-FastestV2 为针对 CPU 优化版本,所以对比时该模型检测 速度为在 CPU 上的运行速度。数据表明本文轻量化的 神经网络在模型体积相上相比主流的目标检测算法模型 体积大大减少且检测速度有大幅度提升。

表 3 模型复杂度对比

#### Table 3 Model complexity comparison

检测算法	输入分辨率	模型体积/MB	检测速度/fps
YOLOv5-s		54.4	80
YOLOv4-tiny	416×416	22.4	86
YOLO-FastestV2		1.08	16(CPU)
CenterNet	CenterNet		46
Our-CenterNet		2.56	124

上述测试结果表明,本文提出的轻量化 CenterNet 网络在仅牺牲1%左右精度的情况下,运行速度相比提升40%左右,更加能够适应高速、高精度的工业生产、物流运输等环境。

#### 3.4 二维条码识别效果对比

为了验证本文提供的定位方法对于二维条码识别率 的贡献,本文使用部分数据集图片与开源解码程序 Zxing 进行实验验证。通过输入包含二维条码的原图片以及本 文神经网络定位后裁剪下的二维条码图片进行识别率测 试,结果如表4所示。实验证明,本文神经网络定位后能 够有效提高二维条码的识别率。

表 4 二维条码识别率

Table 4	Recognition	rate of	two-dimensional	bar	code
---------	-------------	---------	-----------------	-----	------

	-				
米刊	二维条码	定位成功	解码成功	识别率/%	
天型	数量	数量	数量		
原图片	1 500	1 253	1 167	77.8	
定位后条码	1 500	1 437	1 364	90.9	

#### 4 结 论

针对工业生产以及产品流通等情况中二维条码需要 高速、准确定位的问题,提出了一种轻量化的 Centernet 网络。采用修改后的 CSPDarkNet53-tiny 作为主干网络, 并且对主干网络的部分通常卷积模块替换为深度可分离 卷积;对上采样模块采用最邻近插值与 1×1 卷积结合的 方式进行轻量化,有效提升上采样速度;最后对输出模块 进行轻量化构建出一个轻量化 Centernet 网络。实验证 明,本文的 CenterNet 网络能够有效避免背景复杂程度对 检测成功率与速度的影响,在定位准确率仅比 YOLOv4tiny 低 0.4%同时,速度能够达到 124 fps,为原 CenterNet 目标检测网络的 2.95 倍,更能满足高速工业生产、产品 流通等场景的需要。

## 参考文献

- [1] 张万鹏,谢松云,姜官祥,等.复杂背景中模糊条形码的定位[J].国外电子测量技术,2013,32(3):75-79.
  ZHANG W P, XIE S Y, JIANG G X, et al. Blurry barcode locating in complex background [J]. Foreign Electronic Measurement Technology, 2013, 32 (3): 75-79.
- [2] 王伟,何卫平,雷蕾,等. 污染及多视角下 DataMatrix 码 精确定位[J]. 计算机辅助设计与图形学学报,2013, 5(9):1345-1353.

WANG W, HE W P, LEI L, et al. Accurate location of polluted datamatrix code from multiple views[J]. Journal of Computer-Aided Design and Computer Graphics, 2013, 25(9):1345-1353.

[3] 李东,郭浩铭,田劲东,等.改进的 DataMatrix 码 L 形边 精确定位方法[J]. 深圳大学学报(理工版),2018, 35(2):151-157.

> LI D, GUO H M, TIAN J D, et al. An improved method of locating L-edges DataMatrix codes [J]. Journal of Shenzhen University (Science & Engineering), 2018, 35(2):151-157.

[4] 原渊. 基于 ORB 特征描述子与随机森林的条码缺陷 识别算法[J]. 国外电子测量技术, 2019, 38(7): 61-64.

YUAN Y. Barcode defect recognition algorithm based on ORB feature descriptor and random forest [J]. Foreign Electronic Measurement Technology, 2019, 38 (7): 61-64.

[5] 蓝金辉,王迪,申小盼.卷积神经网络在视觉图像检测的研究进展[J].仪器仪表学报,2020(4):167-182.
 LAN J H, WANG D, SHEN X P. Research progress on visual image detection based on convolutional neural

network [J]. Chinese Journal of Scientific Instrument, 2020(4):167-182.

- [6] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [7] 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, 2016: 779-788.
- [8] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [9] LAW H, DENG J. Cornernet: Detecting objects as paired keypoints [C]. Proceedings of the European conference on Computer Vision (ECCV), 2018: 734-750.
- [10] ZHOU X, WANG D, KRÄHENBÜHL P. Objects as points[J]. arXiv preprint arXiv:1904.07850, 2019.
- [11] TIAN Z, SHEN C, CHEN H, et al. Fcos: Fully convolutional one-stage object detection [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 9627-9636.
- [12] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [13] GE Z, LIU S, WANG F, et al. Yolox: Exceeding YOLO series in 2021 [ J ]. arXiv preprint arXiv: 2107.08430, 2021.
- [14] 程换新,蒋泽芹,成凯. 基于改进 SegNet 模型的斑马线 图像语义分割[J]. 电子测量技术,2020,43(23): 104-108.
  CHENG H X, JIANG Z Q, CHENG K, Semantic segmentation of zebra crossing based on improved SegNet model[J]. Electronic Measurement Technology, 2020, 43(23):104-108.
- [15] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. arXiv preprint arXiv:2004.10934, 2020.
- [16] SPRINGENBERG J T, DOSOVITSKIY A, BROX T, et al. Striving for simplicity: The all convolutional net[J]. arXiv preprint arXiv:1412.6806, 2014.
- [17] 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.

 [18] 邵伟明,葛志强,李浩,等.基于循环神经网络的半监督动态软测量建模方法[J].电子测量与仪器学报, 2019,33(11):7-13.

SHAO W M, GE ZH Q, LI H, et al. Semisupervised dynamic soft sensing approaches based on recurrent neural network [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(11):7-13.

 [19] 曹泽卫,欧阳,林冬婷,等. 基于 CNNs 识别反馈的点阵 字符检测方法[J]. 电子测量与仪器学报, 2020, 34(8):159-166.

> CAO Z W, OU Y, LIN D T, et al. Dot matrix character detection method based on CNNs recognition feedback[J]. Journal of Electronic Measurement and Instrumentation, 2020,34(8):159-166.

[20] 石杰,周亚丽,张奇志. 基于改进 Mask RCNN 和 Kinect 的服务机器人物品识别系统[J]. 仪器仪表学报, 2019,40(4):216-228.

SHI J, ZHOU Y L, ZHANG Q ZH. Service robot item recognition system based on improved Mask RCNN and Kinect [J]. Chinese Journal of Scientific Instrument, 2019,40(4):216-228.

## 作者简介



**万伟彤**,2015年于西南石油大学获得 学士学位,现为河北工业大学硕士研究 生,主要研究方向为计算机视觉与图像 处理。

#### E-mail:1169085222@ qq. com

Wan Weitong received his B. Sc. degree from Southwest Petroleum University in 2015. Now he is a M. Sc. candidate in Hebei University of Technology. His main research interests include computer vision and image processing.



**陶友瑞**(通信作者),2010年于湖南大 学获得博士学位,现为河北工业大学教授, 主要研究方向为复杂系统可靠性分析与设 计理论和工业机器人技术。

E-mail: taoyourui@hebut.edu. cn

**Tao Yourui** (Corresponding author) received his Ph. D. degree from Hunan University in 2010. Now he is a professor in Hebei University of Technology. His main research interests include reliability analysis and design theory of complex system and industrial robot technology.