



基于反卷积和特征融合的SSD小目标检测算法

赵文清, 周震东, 翟永杰

引用本文:

赵文清, 周震东, 翟永杰. 基于反卷积和特征融合的SSD小目标检测算法[J]. 智能系统学报, 2020, 15(2): 310–316.

ZHAO Wenqing, ZHOU Zhendong, ZHAI Yongjie. SSD small target detection algorithm based on deconvolution and feature fusion[J]. *CAAI Transactions on Intelligent Systems*, 2020, 15(2): 310–316.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.201905035>

您可能感兴趣的其他文章

基于跳跃连接金字塔模型的小目标检测

Skip feature pyramid network with a global receptive field for small object detection
智能系统学报. 2019, 14(6): 1144–1151 <https://dx.doi.org/10.11992/tis.201905041>

基于改进的Faster R-CNN高压线缆目标检测方法

Object detection of high-voltage cable based on improved Faster R-CNN
智能系统学报. 2019, 14(4): 627–634 <https://dx.doi.org/10.11992/tis.201905026>

多层卷积特征的真实场景下行人检测研究

Research on pedestrian detection based on multi-layer convolution feature in real scene
智能系统学报. 2019, 14(2): 306–315 <https://dx.doi.org/10.11992/tis.201710019>

自动驾驶场景下小且密集的交通标志检测

Detection of small and dense traffic signs in self-driving scenarios
智能系统学报. 2018, 13(3): 366–372 <https://dx.doi.org/10.11992/tis.201706040>

高斯核函数卷积神经网络跟踪算法

Convolutional neural network tracking algorithm accelerated by Gaussian kernel function
智能系统学报. 2018, 13(3): 388–394 <https://dx.doi.org/10.11992/tis.201612040>

一种多层特征融合的人脸检测方法

Face detection method fusing multi-layer features
智能系统学报. 2018, 13(1): 138–146 <https://dx.doi.org/10.11992/tis.201707018>

微信公众平台



关注微信公众号, 获取更多资讯信息

DOI: 10.11992/tis.201905035

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20190828.1814.012.html>

基于反卷积和特征融合的 SSD 小目标检测算法

赵文清, 周震东, 翟永杰

(华北电力大学 控制与计算机工程学院, 河北 保定 071003)

摘要: 由于小目标的低分辨率和噪声等影响, 大多数目标检测算法不能有效利用特征图中小目标的边缘信息和语义信息, 导致其特征与背景难以区分, 检测效果差。为解决 SSD(single shot multibox detector) 模型中小目标特征信息不足的缺陷, 提出反卷积和特征融合的方法。先采用反卷积作用于浅层特征层, 增大特征图分辨率, 然后将 SSD 模型中卷积层 conv11_2 的特征图上采样, 拼接得到新的特征层, 最后将新的特征层与 SSD 模型中固有的 4 个尺度的特征层进行融合。通过将改进后的方法与 VOC2007 数据集和 KITTI 车辆检测数据集上的 SSD 和 DSSD 方法进行比较, 结果表明: 该方法降低了小目标的漏检率, 并提升整体目标的平均检测准确率。
关键词: 小目标检测; 反卷积; 特征映射; 多尺度; 特征融合; SSD 模型; PASCAL VOC 数据集; KITTI 数据集
中图分类号: TP18 **文献标志码:** A **文章编号:** 1673-4785(2020)02-0310-07

中文引用格式: 赵文清, 周震东, 翟永杰. 基于反卷积和特征融合的 SSD 小目标检测算法 [J]. 智能系统学报, 2020, 15(2): 310-316.

英文引用格式: ZHAO Wenqing, ZHOU Zhendong, ZHAI Yongjie. SSD small target detection algorithm based on deconvolution and feature fusion[J]. CAAI transactions on intelligent systems, 2020, 15(2): 310-316.

SSD small target detection algorithm based on deconvolution and feature fusion

ZHAO Wenqing, ZHOU Zhendong, ZHAI Yongjie

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: Given the low resolution and noise of small targets, most target detection algorithms cannot effectively utilize the edge and semantic information of small targets in feature maps, which makes it difficult to distinguish the features from the background. Thus, the detection effect is poor. To solve the problem of insufficient feature information of small and medium targets in the single shot MultiBox detector (SSD) model, we propose a method based on deconvolution and feature fusion. First, deconvolution is employed to process the shallow feature layer to increase the resolution of the feature graph. Then, the feature map of the convolution layer conv11_2 in the SSD model is sampled and spliced. Subsequently, a new layer of features is obtained. Finally, the new layer of features is combined with the feature layer of the four scales inherent in the SSD model. The improved method is compared with the SSD and DSSD methods on the VOC2007 dataset and KITTI vehicle detection dataset. The results show that the method reduced the missed detection rate of small targets and improved the average detection accuracy of all targets.

Keywords: small target detection; deconvolution; feature mapping; multi-scale; feature fusion; SSD model; PASCAL VOC dataset; KITTI dataset

标检测作为目标检测的一项关键技术,近年来已成为研究的热点。小目标因为尺度过小、特征不清晰、边框信息模糊、易被干扰等特点,容易造成误检漏检。因此,小目标检测技术仍需完善。

目标检测算法主要有2类,第1类是双阶段检测方法,例如 RCNN^[5]、Faster-RCNN^[6]、Mask-RCNN^[7]等,该类算法首先在特征图上对可能存在目标的位置提取候选区域框,然后对提取到的特征进行筛选和定位。对于小目标的检测,RCNN系列的算法未缩放原图尺寸,当目标本身像素过低,在一定深度的网络上,提取到的特征图中会丢失很多小目标的边缘信息,影响检测效果。第2类是单阶段检测方法,以 SSD^[8]和 YOLO^[9]为主,YOLO 算法的做法是将特征图等分为 $n \times n$ 的网格,但是一个网格中存在多个小目标的时候,会造成目标的漏检和误检,而 SSD 算法在一个网格中提取多个候选区域,兼顾检测的准确率和速度。但是,由于 SSD 的检测模型只有底层的 conv4_3 用于检测小目标,不具有足够的语义信息,因此 SSD 模型无法有效检测小目标,其效果有待提升。

为了提高 SSD 模型对小目标的检测准确率,2017年, Liu W 等^[10]在 SSD 的基础上做了进一步改进,充分利用特征层之间的上下文信息,使用残差网络提升特征网络的表征能力,提出 DSSD 模型,但是这种方法使检测速度大幅度降低。Bharat 等^[11]提出 SNIP 算法,主要对特征图进行不同倍数的上采样,实验出了相对最优的检测小目标的特征图尺寸,预测时建立多尺度预测模型,筛选出指定范围内的候选框,最后通过 soft-nms^[12]融合不同分辨率下的检测结果,效果显著。文献^[13]提出了 receptive field block(RFB),通过调整感受野大小,进一步增强网络的特征提取能力,将 RFB 与 SSD 结合,从而有效增大了感受野,提高了检测准确率。基于特征融合的思想,Seung-Wook Kim 等^[14]提出的 PFPNet 模型在 SSD 模型基础上引入 SPPNet^[15]方法构造特征金字塔,取得了显著的效果。Chenchen Zhu 等提出的 FSAF^[16]模型让目标自动选择最合适的特征,实现了模型自动化学习, FSAF 模块集成到 SSD 模型中可以有效提高小目标检测准确率。

DSSD 算法和文献^[17]提出的基于反卷积操作改进的 SSD 算法都只是用反卷积层和特征层进行点积融合,并未充分利用小目标的边缘信息,本文依据 SSD 模型中不同特征层与不同大小

目标的相关性,通过反卷积增大特征层 conv4_3 分辨率,映射特征信息,池化后与具有丰富语义信息的 conv11_2 特征图拼接,最后将 SSD 模型中固有的特征层与改进后的特征层融合,很大程度上丰富了特征图中小目标的特征信息。本文主要选取 SSD、DSSD 和 RFB 模型在 VOC2007 测试集和 KITTI 车辆检测数据集上作对比实验,比较检测的 mAP 值。实验结果表明,通过训练改进后的 SSD 模型,在 VOC2007 测试集上和 KITTI 中 2012 2D Object Detection left color images of object data 数据集的 mAP 分别为 82.6% 和 68.9%,对小目标检测的平均准确率有显著提升。

1 相关工作

1.1 SSD 网络结构

SSD 模型以 VGG16 网络为基础模型,并通过对 ILSVRC CLS-LOC 数据集上预训练,采用多尺度特征图检测方法,其中特征层 conv4_3 输出的特征图分辨率最高,为 38×38 ,负责检测小目标。其检测模型如图 1 所示。

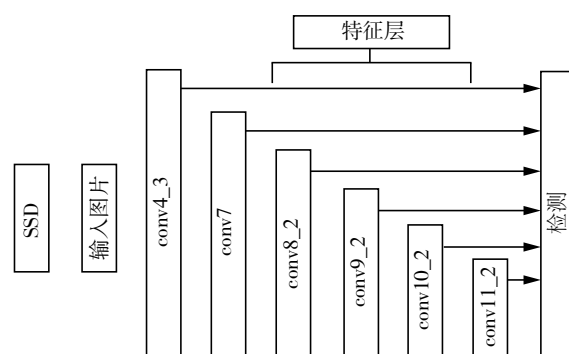


图 1 SSD 检测模型

Fig. 1 SSD detection model

1.2 反卷积

反卷积是卷积操作的逆运算,能够增大特征图分辨率,扩大感受野,卷积与反卷积的过程如图 2 所示。

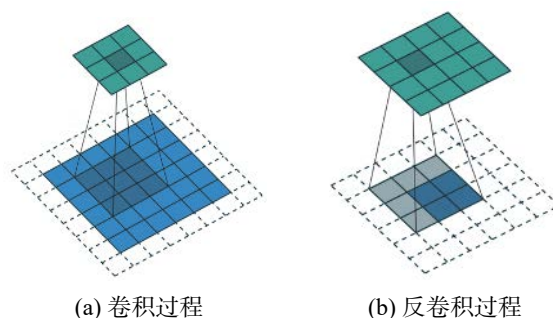


图 2 卷积和反卷积

Fig. 2 convolution and deconvolution

图2(a)为卷积过程,特征图尺寸为 5×5 ,卷积核大小为 3×3 ,步长为2,填充为1,经过卷积计算,得到的输出特征为 3×3 。图2(b)为反卷积过程,输入特征图尺寸为 2×2 ,卷积核大小 3×3 ,步长为1,填充为2,计算得到的特征输出为 4×4 。依次推算,得出反卷积过程中特征图的输入输出关系:

$$o' = s(i' - 1) + k - 2p \quad (1)$$

式中: o' 为输出; i' 为输入; s 为步长; k 为卷积核大小; p 为填充。

浅层特征图未经过大量的卷积池化,分辨率较高。与一般目标检测相比,小目标因为尺寸小,其特征在浅层特征图上更能体现出来。针对

这一特点,本文采用反卷积操作,增大特征图分辨率,以便更直观地反映小目标的特征。

2 反卷积与特征融合相结合的检测模型

针对 SSD 模型对小目标检测能力不足的问题,本文首先用反卷积增大负责检测小目标的特征层 conv4_3 的特征图,然后再对拥有丰富语义信息的特征层 conv11_2 得到的特征图进行上采样拼接到改进后的特征图 nconv4_3 上,最后与 SSD 模型固有的多尺度特征层进行像素直接加权和不同加权系数的特征融合。本文提出的反卷积和特征融合的 SSD 小目标检测模型如图3所示。

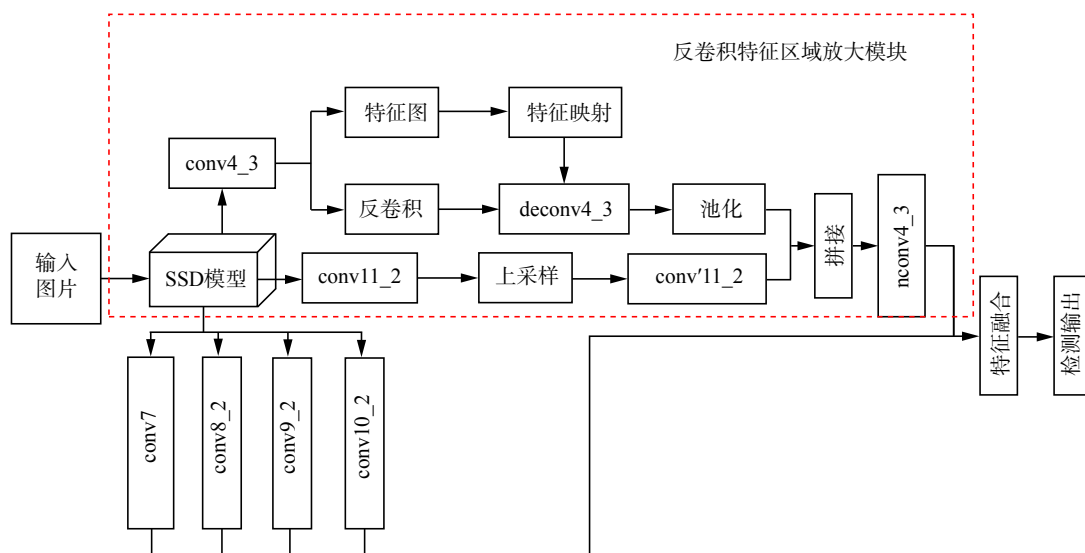


图3 基于反卷积和特征融合的 SSD 小目标检测模型

Fig.3 SSD small Target Detection Model based on deconvolution and feature Fusion

图3中虚框部分为反卷积特征区域放大模块,主要作用是通过反卷积放大 conv4_3 特征图分辨率,与上采样的 conv11_2 特征图拼接,得到新的特征层 nconv4_3。SSD 模型其他特征层为 conv7、conv8_2、conv9_2 和 conv10_2,与 nconv4_3 进行不同加权系数的特征融合,最后进行对目标的定位检测并输出。

2.1 反卷积特征区域放大

SSD 的结构与图像金字塔类似,低层特征图分辨率高,拥有更详细的边缘信息,利于检测小目标,但是缺乏高层特征图所包含的语义信息。因此,本文提出了一种通过反卷积增大特征区域分辨率,拼接深层特征图的方法,图3中的反卷积特征区域放大模块,具体做法分为以下5个步骤:

1) 提取 SSD 模型中第1个负责检测小目标的

特征层 conv4_3 的特征图,作为候选区域。

2) 反卷积操作作用与特征图 conv4_3,增大其分辨率至输入图像尺寸,使得目标特征更加显著,根据第2.2节中反卷积的输入输出关系公式,SSD300 模型将输入图像尺寸压缩至 300×300 ,conv4_3 得到的特征图尺寸为 38×38 ,则设置卷积步长 $s=8$,卷积核尺寸 $k=4$,填充 $p=1$ 。SSD512 模型将输入图像尺寸设置为 512×512 ,经过卷积层 conv4_3 后,特征图尺寸为 64×64 ,则设置卷积步长 $s=8$,卷积核尺寸 $k=8$,填充 $p=0$ 。经过反卷积作用特征图后,得到新的特征图 deconv4_3。

3) 提取卷积层 conv4_3 的特征图的特征信息,特征映射到 deconv4_3 上,此处的特征映射包含特征图像素点的映射和感受野坐标的映射,首先将特征图 conv4_3 每个位置的像素映射到 de-

conv4_3 上, 坐标映射公式如下:

$$g(x, y) = f(h(x, y)) \quad (2)$$

式中: (x, y) 表示像素的横纵坐标; g 函数为目标特征图, f 函数是待映射特征图, h 函数表示映射方法。然后引用文献 [4] 中 ROI 映射到特征图的方法, 实现感受野的坐标映射, 如图 4 所示。




图 4 感受野坐标映射

Fig. 4 Receptive field coordinate mapping

图 4 表示特征图 conv4_3 与特征图 deconv4_3 之间的感受野坐标映射关系, p 为中心点。将点 p 映射到 deconv4_3 中, 坐标变化所采用的公式如下:

$$p_i = u_i \times p_{i+1} + ((t_i - 1)/2 - \text{padding}) \quad (3)$$

式中: p_i 为第 i 层特征图上的中心点; u_i 和 t_i 分别表示从第 $i+1$ 层反卷积到第 i 层的卷积步长和卷积核尺寸, padding 为填充。

4) 将特征映射后的 deconv4_3 池化为固定尺寸。

5) 将卷积层 conv11_2 的特征图上采样, 得到 conv'11_2, 其尺寸与池化后的 deconv4_3 相同。

6) 拼接池化后的 deconv4_3 与 conv'11_2 的特征图, 形成新的检测特征层 nconv4_3。

2.2 特征融合

根据高分辨的浅层特征图细节特征丰富, 低分辨率的深层特征图上下文信息和语义信息丰富的特点, 本文采用加权特征融合的方式, 将 SSD 固有的多尺度特征图与第 2.1 节得到的新的特征图进行融合, 增强图像特征信息, 提高小目标检测的准确率。

加权融合是直接的图像融合方法, 该方法实现简单, 运算效率高, 冗余信息少。目前的特征融合的方式多为直接相加, 本文旨在提升小目标的检测效果, 因此未直接采用相同权值加权, 低层特征图拥有更多小目标的细节特征信息, 因此本文在相同权值直接相加的基础之上, 额外为 5 个不同尺度的特征图分配加权系数, 经过多次调参实验, 得到一组相对最优权值, 分别为 30%、20%、15%、15%、20%。特征向量的输出如式 (4)

所示:

$$F = V + a_1 v(\text{nconv4_3}) + a_2 v(\text{conv7}) + a_3 v(\text{conv8_2}) + a_4 v(\text{conv9_2}) + a_5 v(\text{conv10_2}) \quad (4)$$

式中: F 为特征输出; V 为本文采用的 5 个尺度的特征图通过上采样直接加权融合得到特征信息; v 为表示特征层的特征信息的函数, a_1 、 a_2 、 a_3 、 a_4 和 a_5 为权重系数, 值分别为 0.3、0.2、0.15、0.15 和 0.2。为避免特征信息冗余, 各个权重系数之和为 1。

2.3 先验框尺度调整

SSD 模型从卷积层中提取 conv7、conv8_2、conv9_2、conv10_2, 作为检测所用的特征图, 融合第 3.1 节中改进后的 nconv4_3 层, 共 5 个特征图, 其大小分别是 (38×38) 、 (19×19) 、 (10×10) 、 (5×5) 、 (3×3) , 不同特征图设置的先验框数目为 9、6、6、6、6。先验框的尺度大小变化为线性变化, 公式如下:

$$s_k = s_{\min} + \frac{s_{\max} - s_{\min}}{m - 1} (k - 1), k \in [1, m] \quad (5)$$

式中: m 指的特征图个数; s_k 表示先验框尺寸相对原图片的比例; s_{\min} 和 s_{\max} 表示比例的最小值与最大值。为了更好地检测小目标, 本文将 s_{\min} 和 s_{\max} 的值调整为 0.1 和 0.9, 这样有效避免了由于目标过小导致在训练阶段真实标签无法找到相应的先验框与之匹配的问题。

3 实验结果及分析

3.1 实验环境

本文实验所用的配置为: Linux 操作系统 Ubuntu16.04LT, 选用 intel(R)Core(TM)i7-8700 的 CPU, NVIDIA GeForce TX1080Ti 的 GPU, 深度学习框架为 Tensor flow。

3.2 实验数据集

为避免训练数据量不足造成的过拟合问题, 本文选用 PASCAL VOC 和 KITTI 两个数据集上面做对比实验, 首先在 PASCAL VOC 数据集中选 voc2007+voc2012 中的训练数据部分为训练集, 在 voc2007 测试数据集上做测试。为验证本文模型的检测效果, 与 SSD、DSSD 和文献 [11] 提出的 RFB 3 种算法作比较, 分别在输入图像尺寸为 300×300 和 512×512 下进行对比实验。

其次, 本文选取 2012 2D Object Detection left color images of object data 作为训练集和测试集。该数据集来自于 KITTI 车辆检测数据, 包括各种道路场景中的车辆, 而且也包括大量较小的目标车辆, 为验证本文提出模型的检测效果, 分别与 SSD、DSSD 和文献 [12] 提出的算法进行对比试验。

3.3 实验结果及对比

通过改进 SSD 模型,对加权特征融合权重参数调优,本文模型在 VOC2007 和 VOC2012 训练

集上训练,在 VOC 2007 测试集上的平均 mAP 为 82.6%,与 SSD、DSSD 和 RFB Net 分别对比,实验结果如表 1 所示。

表 1 VOC2007 测试集检测结果对比
Table 1 Comparison of Test results of VOC2007 test set

方法	输入尺寸	网络	mAP/%
Faster R-CNN ^[5]	~1 000×600	VGG16	73.2
Faster R-CNN ^[5]	~1 000×600	Residual-101	76.4
YOLOv2 544 ^[15]	544×544	Darknet	78.6
SSD300 ^[7]	300×300	VGG16	77.2
DSSD321 ^[8]	321×321	Residual-101	78.6
RFB300 ^[11]	300×300	VGG16	80.5
本文模型	300×300	VGG16	80.9
SSD512 ^[7]	512×512	VGG16	79.8
DSSD513 ^[8]	513×513	Residual-101	81.5
RFB512 ^[11]	512×512	VGG16	82.2
本文模型	512×512	VGG16	82.6

由表 1 数据可知,在 VOC2007 数据集上测试,输入图像尺寸为 300×300 时,本文提出模型的 mAP 为 81.4%,较 SSD、DSSD 和 RFB Net 分别提高 3.7%、2.3% 和 0.4%。输入图像为 512×512 时,本文提出模型的 mAP 为 82.6%,较 SSD、DSSD

和 RFB Net 分别提高 2.8%、1.1% 和 0.4%。

本文提出的模型旨在提升小目标的检测准确率,VOC2007 测试集中有 21 类不同大小的目标,本文选取其中 6 类具有代表性的小目标,检测准确率与 SSD 和 DSSD 对比,实验结果如表 2 所示。

表 2 VOC2007 数据集中小目标检测的准确率
Table 2 Mean average precision of small targets detection in VOC2007 test set

方法	输入尺寸	mAP/%						
		平均值	船	瓶子	椅子	盆栽	电视	鸟
SSD300	300×300	64.2	69.6	50.5	60.3	52.3	76.8	76.0
DSSD321	321×321	65.8	68.4	53.9	61.1	51.7	79.4	80.5
本文模型	300×300	68.0	71.8	58.5	62.7	54.8	79.2	80.8
SSD512	512×512	68.6	73.0	57.8	63.5	55.6	80.0	81.5
DSSD513	513×513	70.0	74.9	62.5	65.2	51.1	83.7	82.6
本文模型	512×512	71.7	75.8	65.5	67.0	56.7	82.7	82.8

由表 2 可知,输入图像尺寸为 300×300 时,本文提出的模型在 6 类小目标的平均检测准确率为 68.0%,较 SSD300 和 DSSD321 模型分别提升 2.2% 和 3.8%,其中 bottle 和 bird 的检测准确率提升较为显著。当输入图像尺寸为 512×512 时,在 6 类小目标的平均检测准确率为 68.0%,较 SSD512 和 DSSD513 模型分别提升 3.1% 和 1.7%。可见本

文方法能有效检测小目标,对小目标检测的平均准确率有明显的提升。

为进一步验证本文提出的模型对小目标识别的准确率,选取 2012 2D Object Detection left color images of object data 数据集作为训练集和测试集。将数据集集中的 8 类目标整合为 3 类,分别为行人、机动车辆、其他目标。实验结果如表 3 所示。

表3 KITTI数据集测试结果对比
Table 3 Comparison of test results of KITTI test set

方法	mAP/%
SSD512	62.1
DSSD513	67.3
文献[18]模型	68.1
本文模型	68.9

文献[18]为吴天舒等提出的基于改进SSD的轻量化小目标检测模型。由表2对比可知,本文提出的模型在KITTI数据集上的mAP较SSD-512、DSSD513、文献[18]模型分别提升了6.8%、1.6%和0.8%,效果显著,可见本文提出的模型对于小目标的识别效果较好。

4 结论

针对小目标的检测,本文提出了利用反卷积与特征融合的方法改进原有的SSD模型,对低层特征层进行反卷积增大分辨率,融合深层特征层提高小目标特征信息,然后进行多尺度特征融合,实验结果表明本文提出模型在整体的检测准确率较SSD、DSSD模型有明显提升,对小目标检测的准确率提升尤为显著。但是,由于反卷积操作增大了模型的计算量,使得检测速度大幅降低。优化网络结构,降低特征信息冗余将是之后的主要研究方向。

参考文献:

- [1] 杨会成, 朱文博, 童英. 基于车内外视觉信息的行人碰撞预警方法[J]. 智能系统学报, 2019, 14(4): 752–760.
YANG Huicheng, ZHU Wenbo, TONG Ying. Pedestrian collision warning system based on looking-in and looking-out visual information analysis[J]. CAAI transactions on intelligent systems, 2019, 14(4): 752–760.
- [2] 姚群力, 胡显, 雷宏. 深度卷积神经网络在目标检测中的研究进展[J]. 计算机工程与应用, 2018, 54(17): 1–9.
YAO Qunli, HU Xian, LEI Hong. Application of deep convolutional neural network in object detection[J]. Computer engineering and applications, 2018, 54(17): 1–9.
- [3] 龙敏, 佟越洋. 应用卷积神经网络的人脸活体检测算法研究[J]. 计算机科学与探索, 2018, 12(10): 1658–1670.
LONG Min, TONG Yueyang. Research on face liveness detection algorithm using convolutional neural network[J]. Journal of frontiers of computer science and technology, 2018, 12(10): 1658–1670.
- [4] 张慧, 王坤峰, 王飞跃. 深度学习在目标视觉检测中的应用进展与展望[J]. 自动化学报, 2017, 43(8): 1289–1305.
ZHANG Hui, WANG Kunfeng, WANG Feiyue. Progress and prospect of application of deep learning in target vision detection[J]. Acta automatica sinica, 2017, 43(8): 1289–1305.
- [5] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA, 2014: 580–587.
- [6] REN Shaoqing, HE Kaiming, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1137–1149.
- [7] HE Kaiming, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//Proceedings of 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy, 2017: 2980–2988.
- [8] LIU Wei, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, The Netherlands, 2016: 21–37.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA, 2016: 779–788.
- [10] FU Chengyang, LIU Wei, RANGA A, et al. DSSD: deconvolutional single shot detector[C]//Computer Vision and Pattern Recognition, 2017.
- [11] SINGH B, DAVIS L S. An analysis of scale invariance in object detection-SNIP[C]//Proceedings of 2018 IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA, 2018.
- [12] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS-improving object detection with one line of code[C]//Proceedings of 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy, 2017: 5562–5570.
- [13] LIU Songtao, HUANG Di, WANG Yunhong. Receptive field block net for accurate and fast object detection[C]//Proceedings of ECCV2018, 2018.
- [14] KIM S W, KOOK H K, SUN J Y, et al. Parallel feature pyramid network for object detection[C]//Proceedings of the 15th European Conference on Computer Vision-ECCV 2018. Munich, Germany, 2018: 239–256.
- [15] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, 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.

- [16] ZHU Chenchen, HE Yihui, SAVVIDES M. Feature selective anchor-free module for single-shot object detection[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, 2019.


- [17] 郭川磊, 何嘉. 基于转置卷积操作改进的单阶段多边框目标检测方法 [J]. *计算机应用*, 2018, 38(10): 2833–2838.

GUO Chuanlei, HE Jia. Improved single shot multibox detector based on the transposed convolution[J]. *Journal of computer applications*, 2018, 38(10): 2833–2838.

- [18] 吴天舒, 张志佳, 刘云鹏, 等. 基于改进 SSD 的轻量化小目标检测算法 [J]. *红外与激光工程*, 2018, 47(7): 0703005.

WU Tianshu, ZHANG Zhijia, LIU Yunpeng, et al. A lightweight small object detection algorithm based on improved SSD[J]. *Infrared and laser engineering*, 2018, 47(7): 0703005.

作者简介:



赵文清, 教授, 博士, 主要研究方向为人工智能与数据挖掘。发表学术论文 50 余篇。



周震东, 硕士研究生, 主要研究方向为机器学习和基于深度学习的小目标检测。



翟永杰, 教授, 博士, 主要研究方向为模式识别与计算机视觉、机器学习与人工智能等。参与省级以上科研项目 50 余项。发表学术论文 100 余篇。

2020 全球人工智能技术大会

The Global Artificial Intelligence Technology Conference(2020)

2020 年 7 月 25—26 日, 由中国人工智能学会主办的“2020 全球人工智能技术大会”即将登陆杭州未来科技城。“全球人工智能技术大会”创办于 2016 年, 历经四载, 已成为中国人工智能技术和产业领域规模最大、影响力最强的专业会议之一。一年一届的大会立足当下、放眼全球, 以国际化、尖端化、前瞻化的理念及视角, 不断勾勒人工智能发展蓝图与路径。

人工智能作为科技变革浪潮的新引擎, 为中国经济向创新型经济转变提供了重要驱动力。百舸争流千帆竞, 短短数年, 人工智能已融入全球各国的基本国家战略之中, 成为产、学、研的热点。七月江南秀雅如画, 让我们相约杭州, 共话人工智能的新格局。

会务咨询:

贾老师(微信同手机: 13240274156)、邹老师(微信同手机: 13121123883)