

轻量级红外弱小目标检测算法

章琦, 朱鸿泰*, 程虎, 张俊, 张晔

中国电子科技集团公司第五十八研究所, 江苏 无锡 214072

摘要 针对现有方法难以在复杂背景下对缺乏内在特征的红外弱小目标进行检测并且存在检测耗时较高等问题, 提出了一种适用于嵌入式边缘计算设备的红外弱小目标检测算法。将小目标检测问题转化为语义分割问题, 模型使用轻量级主干网络提取特征, 设计基于上下文调制的跨层间的特征融合方式, 用于交换高层语义和低层细节, 引入基于通道和位置的双注意力机制突出特征图中的弱小目标。通过实验验证了提出算法模型相较于现有先进的算法在复杂场景下具有更好的检测效果、更低的虚警以及更少的耗时等优势, 且该模型大小只有 100 KB, 可以达到 20 frame/s 视频流实时检测, 方便嵌入式部署及实际应用。

关键词 成像系统; 红外弱小目标检测; 语义分割; 注意力机制; 上下文调制; MobileNet-V3

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP202259.1611007

Lightweight Infrared Small-Target Detection Algorithm

Zhang Qi, Zhu Hongtai*, Cheng Hu, Zhang Jun, Zhang Ye

China Electronics Technology Group Corporation No. 58 Research Institute, Wuxi 214072, Jiangsu, China

Abstract The lack of inherent characteristics of infrared small targets, with issues such as high time consumption, prevents applying existing detection methods in complex environments. Herein, we propose an infrared small-target detection algorithm suitable for embedded edge-computing devices which transforms the problem of small-target detection into the problem of semantic segmentation. A lightweight backbone network is used to extract the features, a cross-layer feature fusion method based on context modulation is designed to exchange high-level semantics and low-level details, and dual attention mechanism based on channels and locations is introduced to highlight the small targets in the feature map. Experiments prove that this algorithm outperforms existing state-of-the-art methods in terms of detection effects, false alarms, and time consumption in complex backgrounds. The model is only 100 KB in size and can detect video streams at 20 frame/s in real-time, making it ideal for embedded deployment and practical applications.

Key words imaging system; infrared small-target detection; semantic segmentation; attention mechanism; contextual modulation; MobileNet-V3

1 引言

红外弱小目标检测技术一直是红外图像处理中的研究重点^[1], 其广泛应用于远程预警系统、导弹跟踪系统、海上监视系统等众多军事领域中。遗憾的是, 红外弱小目标检测仍然充满挑战, 首先, 由于成像距离长, 小目标往往呈点状, 缺乏纹理和结构信息; 其次, 红外成像还受到复杂背景、杂波和大气辐射的影响, 导致红外图像的信噪比低, 有时目标甚至被背景淹没; 第三, 人工建筑物、海中船舶、空中飞鸟等干扰对探测能力也有不良影响。如何有效抑制背景, 提高目标的检测能

力, 减少误报一直是难以解决的问题。

现有基于单帧方法的弱小目标检测方法主要依靠一些先验信息, 比如背景的一致性、目标的显著性、目标的稀疏性和背景的低秩性^[2]是检测红外弱小目标最常用的假设。主要分为两类: 使用局部先验的滤波方法和使用非局部先验的优化方法。第一种滤波方法根据背景一致性的先验信息来估计背景。通过从原始图像中减去预测背景来增强目标。传统的典型滤波器包括顶帽(Tophat)滤波器^[3]、二维最小均方(TDLMS)滤波器^[2]和最大均值滤波器^[4], 可以在简单的均匀场景下轻松捕获目标。但是这些方法难以适应干扰场景下的

收稿日期: 2021-11-24; 修回日期: 2021-12-27; 录用日期: 2022-02-17

通信作者: *627242573@qq.com

复杂边缘。另一种滤波方法通过计算基于人类视觉系统(HVS)的显著图来突出弱小目标,例如高斯差分(DoG)滤波器^[5]、局部对比度测量(LCM)^[6]等等。还可以通过分析傅里叶域中的视觉显著性^[7]。

深度学习由于其强大的特征提取能力以及相对于传统检测算法更强的泛化性能,在近些年来的物体识别、目标检测和分割领域取得了巨大的进步,在检测速度和准确度方面都达到了较好的水平。但是这些经典的网络主要是为通用图像数据集设计的^[8]。由于数据分布以及目标特征的巨大差异,如果直接将它们用于红外弱小目标检测可能会导致不太理想的结果。因此本文提出一种基于注意力机制的轻量级卷积神经网络,通过从多个方面重新定制网络并将检测问题转化为逐像素分割问题,以适用于弱小目标检测。包括:

1) 借用移动端卷积神经网络(MobileNet-V3)^[9]的设计思路,重新设计主干特征提取网络,引入深度可分离卷积和线性瓶颈的逆残差结构,轻量化网络模型,减少模型参数和计算复杂度以适用于嵌入式边缘端计算平台;

2) 添加自顶向下的基于通道注意力压缩和激发(SE)模块以及自底向上的基于像素空间位置注意力的双注意力机制,以保留和突出红外高层特征中的弱小目标;

3) 提出新的高低层融合方式-非对称上下文调制,不同于以往特征图简单相加,利用低层空间特征细节来丰富高层的语义特征,利用高层的语义信息来丰富低层空间特征^[10]。

2 基本原理

首先与通用数据集中的物体检测不同,红外弱小目标检测是一个离群点检测问题,属于一个二元决策问题^[11]。由于红外弱小目标最小可检测大小通常为 $3 \text{ pixel} \times 3 \text{ pixel}$ 且缺乏轮廓和纹理等内在特征,因此将它们全部归为一类,而没有进一步区分其具体类别。若直接使用经典的经典目标检测网络,例如:FasterRcnn、Yolo^[12]等网络进行检测,会存在针对弱小目标

检测效果不好以及常规网络模型太大、计算复杂度高等问题。因此在设计卷积神经网络(CNN)时,首要任务应该是保留和突出深层红外弱小目标的特征。在这里将红外弱小目标的检测问题转化为一个语义分割^[13]问题,通过对每个像素进行密集的预测来实现细粒度的推理,并引入注意力机制更好地学习到前景和背景的差异。

当前主流的语义分割网络主要由编码器(encoder)和解码器(decoder)组成^[13]:编码器主要由主干分类网络组成,主要负责特征提取,将图像分辨率逐渐降低并提升通道特征;而解码器则是将编码器先前丢失的空间信息逐渐恢复,包括上采样和跨层间的特征融合等操作。

2.1 主干网络结构

经典的主干特征提取网络主要包括 VGG、ResNet^[14]、DenseNet^[15]等系列,虽然具有良好的特征提取效果,但由于其网络深度和参数量都在成倍增加,导致模型无法直接应用于移动和嵌入式设备。而 MobileNet 系列是谷歌为移动端和嵌入式设备提出的轻量化高效模型,通过深度可分离卷积极大地减少模型的参数,使用 1×1 的卷积调整特征图通道数减少计算量。MobileNet-V3^[9]作为该系列最新的模型,在保留之前模型轻量化优势的前提下,引入了新的线性瓶颈逆残差结构 bneck,并添加了轻量级的注意力模型 SE 模块,并通过神经网络结构搜索(NAS)自动搜索出合适的模型参数和结构,可以达到与 ResNet-50 相似的准确度。因此在这里,参考 MobileNet-V3 的结构进行主要特征提取网络的设计,如表 1 所示。

将红外图像缩放到 416×416 输入到网络中,经过卷积层和多个 bneck 结构进行特征提取,输出 $26 \times 26 \times 40$ 的特征图。表中第 1 列输入表示网络每个特征层的 shape 变化;第 2 列代表特征层需要经过的 block 结构,包括卷积层和 bneck 结构;第 3、4 列分别表示 bneck 内逆残差结构上升后的通道数、输入到 bneck 时特征层的通道数;第 5 列 SE 表示是否引入注意力机制;第 6 列 NL 表示激活函数的选择,HS 代表 h-swish 函数,RE 代表 ReLU 函

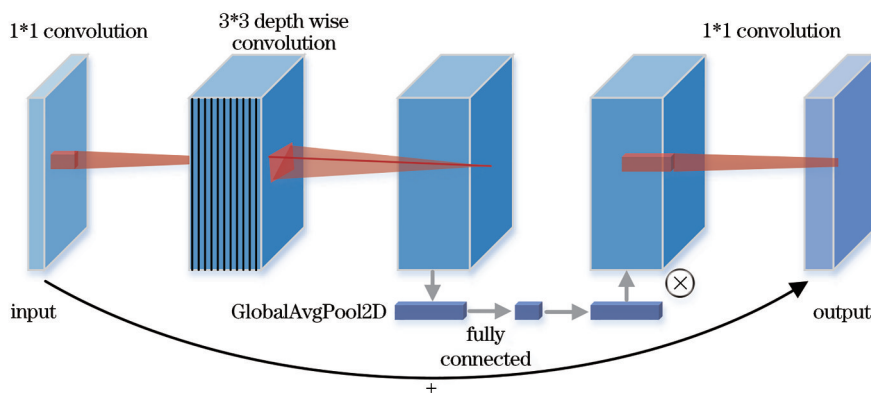


图1 bneck 结构示意图

Fig. 1 Structure diagram of bneck

表 1 模型主干网络结构

Table 1 Backbone structure of network

Input	Operator	Expand size	Out size	SE	NL	Step
416 ² *1	con2d, 3*3		8	—	HS	2
208 ² *8	bneck1, 3*3	32	16	✓	RE	2
104 ² *16	bneck2, 3*3	72	24	—	RE	2
52 ² *24	bneck3, 3*3	88	24	—	RE	1
52 ² *24	bneck4, 3*3	96	40	✓	HS	2
26 ² *40	bneck5, 3*3	120	40	✓	HS	1

数;第 7 列 Step 代表每一次 block 结构所用的步长。

bneck 模块的主要计算过程包括首先经过 1*1 卷积进行特征通道的升维,并保留原始通道数的残差边;之后通过 3*3 的深度可分离卷积进行特征提取,可以极大地降低模型参数量;接着经过 SE 模块,该模块的

核心思想是通过显式建模卷积特征通道之间的相互依赖关系,来自动获取每个特征通道的重要程度,调整每个通道的权重。

2.2 解码结构

decoder 部分的任务是将编码器学习到的识别特征(低分辨率)语义投影到像素空间(高分辨率)上,得到密集的分类^[13]。主要分割的头部网络包括上采样和跨层间的特征融合,针对经过前述特征提取网络最后一层 bneck5 的特征图,首先一条分支经过 1*1 卷积调整通道数;另一条分支经过平均池化层得到一个较小的特征图,再通过 sigmoid 激活函数提取通道注意力机制^[8],上采样到输入大小后与第一条分支的特征图进行点乘。接着将输出特征图继续上采样一倍,与浅层 bneck2 的特征图进行不同层级间的跨层融合。编码和解码整体结构如图 2 所示。

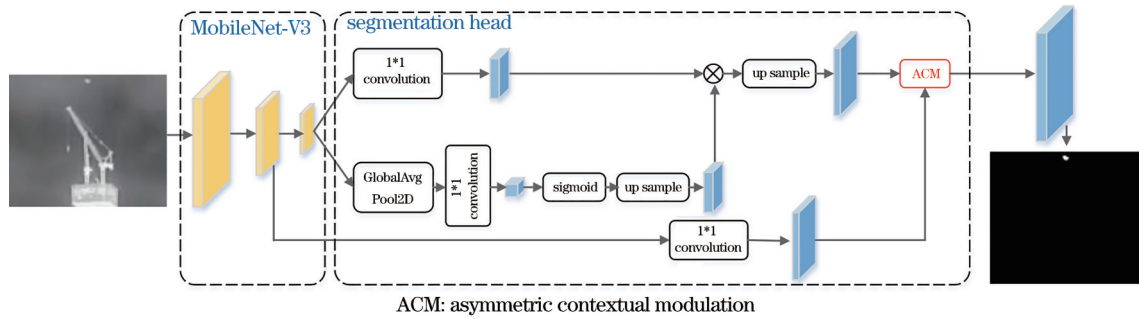


图 2 算法模型整体结构图

Fig. 2 Overall structure of model

2.3 非对称上下文调制特征融合结构

常规对不同深度层之间特征图进行融合的方法,往往只是使用 1*1 卷积调整通道数并上采样特征图到相同大小然后进行简单的相加,称为简单融合。这种方式没有考虑到不同层级特征图之间语义特点,较低层的特征图具有丰富的位置细节特征,而高层的特征图具有丰富的语义信息,如何有效地利用两者之间的特点进行更有效的融合,并且提高模型检测效果是急需解决的问题。

因此本文提出新的高低层融合方式非对称上下文调制(ACM)^[10],给出一个低层的具有丰富位置细节特征的特征图 X 和一个高层的具有丰富语义信息的特征图 Y ,将它们上采样到相同长宽大小,结合两者之间的优势和特点进行更好的跨层融合。在这里引入 2 条主分支,对低层特征图 X 使用 1*1 卷积调整通道数,并对每个空间位置的通道特征进行单独聚合,之后使用 sigmoid 激活函数求出特征图每个位置的重要程度,提取位置注意力特征 $L(X)$;对高层特征图 Y 使用全局平均池化层将特征图转换为只有通道数的特征向量,然后使用全连接层提取通道注意力特征 $G(Y)$ 。接着对低层特征 X 和提取通道注意力特征的 $G(Y)$ 使用逐元素点乘进行融合,使得低层特征的通道也具有高层语

义信息;对高层特征 Y 和提取位置注意力特征的 $L(X)$ 使用逐元素点乘进行特征图融合,使得高层特征也能具有低层位置信息;最后再将 2 条分支的结果进行相加融合得到最后的特征图 Z ,使得 Z 能同时对空间位置以及目标形状和结构特征敏感,如图 3 和下式所示:

$$Z = G(Y) \otimes X + L(X) \otimes Y, \quad (1)$$

$$G(Y) = \sigma \{ \beta \{ \omega_2 \{ \gamma \beta \{ \omega_1 \rho(Y) \} \} \} \}, \quad (2)$$

$$L(X) = \sigma \{ \beta \{ \varphi_2 \{ \gamma \beta \{ \varphi_1(X) \} \} \}, \quad (3)$$

式中: G 函数代表对高层特征 Y 经过全局平均池化以及全连接层提取通道注意力特征; σ 代表 sigmoid 激活函数; β 代表批量标准化(BN); ω 代表全连接层 FC; γ 代表 ReLU 激活函数; ρ 代表全局平均池化函数(GlobalAvgPooling); L 函数代表对低层 X 使用 1*1 卷积和 sigmoid 函数提取位置注意力特征; φ 代表 1*1 的卷积; \otimes 代表对两个输入进行逐元素的点乘。通过让高层特征 Y 融合低层位置信息特征 $L(X)$ 以及让低层特征 X 融合高层语义特征 $G(X)$,使得最后的输出特征图能同时对空间位置以及目标形状和结构特征敏感,提高网络检测能力。如此设计的整体轻量级模型只有 100 KB 大小,计算复杂度也不高,适用于嵌入式设备的推理计算要求。

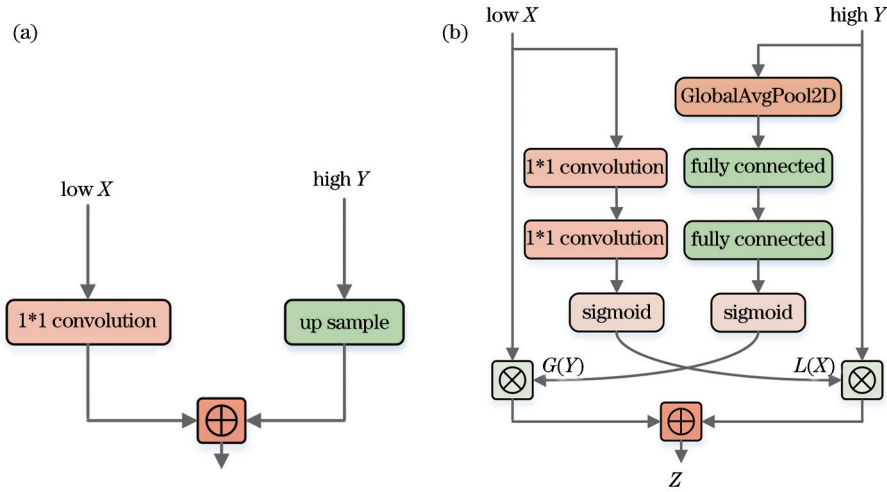


图 3 不同特征融合方式对比。(a)简单融合结构;(b) ACM原理结构

Fig. 3 Comparison of different feature fusion methods. (a) Simple fusion structure; (b) structure of ACM

2.4 数据集

深度学习更多的是一种基于数据驱动的方法。通过不同典型场景的数据,学习到前景和背景分布的语义信息,因此训练数据集的质量直接影响着网络最终泛化能力的强弱。数据集需要考虑红外目标检测问题中的多样性和复杂性,本文根据典型应用场景,将目标背景大概分为地面背景、天空背景、海上背景以及城市建筑背景 4 大类。选择利用开源的 SIRST^[10]数据集加

上本文实际应用所采集的图像,每幅图像包括 1 到数个目标,大小尺寸从 3 pixel×3 pixel 到 30 pixel×30 pixel,目标根据尺度大小、环境复杂程度以及是否邻近相似对比度背景可以将数据分为难易样本。数据集包含 500 张图片以及经过标注后对应的 mask 图,包括 562 个目标,将数据集随机划分为 50% 的训练集、20% 的验证集以及 30% 的测试集。一些典型场景图像和目标如图 4 所示。




图 4 不同场景下数据集图像。(a) 天空场景;(b) 建筑场景;(c) 地面场景;(d) 海上场景

Fig.4 Data set images of different background examples. (a) Sky background; (b) architectural background; (c) ground background; (d) sea background

2.5 网络训练

在网络的训练中,准备好原始红外图像和标注的二值图 mask,进行随机缩放、裁剪、随机镜像翻转以及调添加高斯噪声来扩增数据集。选择平滑交并比 (Soft IoU)^[16]作为损失函数,使用 0.05 的初始学习率,批大小 (batch size) 为 8,训练 300 个批次 (epoch),每 10 个批次将学习率衰减 1/10,根据模型训练过程中的验证结果,选出表现最好的模型。

3 实验与分析

本文实验的硬件环境分为训练环境和测试部署环境。训练环境下使用深度学习 Pytorch 框架进行模型的设计和训练过程。而测试部署环境的硬件配置主要为海思 Hi3559 的嵌入式板卡双核 ARM Cortex A73. 1.8 GHz 进行实际的前向推理测试,ARMv8-A 构架,是 ARM 公司的首款支持 64 位指令集的处理架构,包括 ARM TrustZone 技术、NEON、虚拟化和加密

技术。Cortex-A73 都可以提供适应性最强的移动应用生态开发环境^[17]。使用混沌神经网络(NCNN)框架转换训练的模型并部署在嵌入式板卡上测试推理耗时和检测的精度损失。

本文选用几个经典的检测算法进行比较,分别为传统的改进 Tophat 算法,主要依靠边缘形状进行检测、基于迭代优化和基于张量核规范(PSTNN)的^[18]算法,通过一种新的非凸低秩约束张量核范数的部分和

联合加权 l1 范数来有效抑制背景并保护目标、目标检测工业最常用的 Yolo-V4^[19]算法以及本文提出的基于语义分割的红外弱小目标检测算法。由于包含基于传统图像处理算法、目标检测算法以及语义分割算法多种类型和不同参考指标,主要从目标检测率、虚警率、平均交并比(mIoU)、时延(latency)几个指标进行对比。将所提出的网络与其他先进的模型驱动方法以及数据驱动网络的性能进行比较,结果如表 2 所示。

表 2 不同算法检测指标对比

Table 2 Comparison of detection indicators of different algorithms

Algorithm	Detection rate / %	False alarm rate / %	mIoU	Board latency / ms
Improved Tophat	93.5	47.2	0.35	100
PSTNN	94.4	19.4	0.51	500
Yolo-V4	91.6	9.3	/	150
Proposed+simple fusion	92.6	5.5	0.65	45
Proposed + ACM	93.5	4.7	0.68	50

各算法一些典型检测效果如图 5 所示:从左至右分别为改进 Tophat、PSTNN、Yolo-V4 以及提出方法。

从表 2 以及图 5 中可以看到,相较于传统小目标检测算法改进的 Tophat 以及深度学习工业界最经典的

Yolo-V4 算法,本文提出的红外弱小目标检测算法,在检测率、虚警率以及嵌入式耗时等性能方面具有明显的优势。传统改进的 Tophat 算法具有原理简单、计算量小等特点,但由于其检测原理只与目标的边缘特性




图 5 各算法检测效果图对比。(a) 改进 Tophat; (b) PSTNN; (c) Yolo-V4; (d) 提出方法

Fig. 5 Comparison of detection results of different algorithms. (a) Improved Tophat; (b) PSTNN; (c) Yolo-v4; (d) proposed algorithm

有关导致其容易受到背景噪声干扰,因此虚警率相较于提出方法高出数倍;并且随着图像输入尺寸的增加,基于迭代优化的 PSTNN 算法,在传统算法中具有一定的检测性能,但虚警率还是偏高,并且由于基于优化的算法需要多次迭代过程,导致算法复杂度较高,难以满足实时性要求。而基于深度学习的 Yolo-V4 算法,由于包含深度特征信息,可以做到较低的虚警率,但 Yolo 系列算法由于多次下采样和 Anchor 原理的限制导致其针对小目标的检测并不理想,因此目标的检测率并不高;并且 Yolo-V4 原始网络主干网络结构较复杂,包含多个 Yolo 层和多个 Anchor^[20-21]提取不同尺度的目标导致模型后处理耗时较长,在嵌入式设备中难以满足实时性要求。本文提出的红外弱小目标检测算法,相较于前述算法在保证较高检测准确率的情况下,虚警率也低于 6%,检测面积平均交并比达到 0.68,具有良好的检测效果和对虚警的抑制,针对不同检测场景也能具有比较好的鲁棒性;使用基于 ACM 模块相较于简单相加融合可以提高一定的检测效果和准确性;该算法模型移植方便,可以做到嵌入式 ARM 板端 20 frame/s 的实时视频流检测效果。

4 结 论

主要针对当前红外成像系统中弱小目标与复杂背景之间的特点和难点,提出了一种适用于嵌入式边缘计算设备以及多种实际场景的红外弱小目标检测算法。该算法首先使用轻量级主干网络进行特征提取,再通过多次上采样层和基于 ACM 跨层间的特征融合得到最后的分割二值图。通过实验与其他最经典和先进的方法进行全方位对比,本文设计的网络可以用更少的参数和更快的速度实现更好的检测性能。该领域在未来的发展趋势是研究计算量小、性能优、鲁棒性强、实时性好和便于硬件实现的红外弱小目标检测算法^[22-24]。

参 考 文 献

- [1] Chen C L P, Li H, Wei Y T, et al. A local contrast method for small infrared target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1): 574-581.
- [2] Gu Y F, Wang C, Liu B X, et al. A kernel-based nonparametric regression method for clutter removal in infrared small-target detection applications[J]. IEEE Geoscience and Remote Sensing Letters, 2010, 7(3): 469-473.
- [3] Gao C Q, Meng D Y, Yang Y, et al. Infrared patch-image model for small target detection in a single image [J]. IEEE Transactions on Image Processing, 2013, 22(12): 4996-5009.
- [4] Wang X Y, Peng Z M, Kong D H, et al. Infrared dim target detection based on total variation regularization and principal component pursuit[J]. Image and Vision

Computing, 2017, 63: 1-9.

- [5] Wang X, Lü G F, Xu L Z. Infrared dim target detection based on visual attention[J]. Infrared Physics & Technology, 2012, 55(6): 513-521.
- [6] 李潇凡, 王胜强, 翁轩, 等. 基于 UNet 深度学习算法的东海大型漂浮藻类遥感监测[J]. 光学学报, 2021, 41(2): 0201002.
Li X F, Wang S Q, Weng X, et al. Remote sensing of floating macroalgae blooms in the East China Sea based on UNet deep learning model[J]. Acta Optica Sinica, 2021, 41(2): 0201002.
- [7] Dong X B, Huang X S, Zheng Y B, et al. Infrared dim and small target detecting and tracking method inspired by human visual system[J]. Infrared Physics & Technology, 2014, 62: 100-109.
- [8] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [9] Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 1314-1324.
- [10] Dai Y M, Wu Y Q, Zhou F, et al. Asymmetric contextual modulation for infrared small target detection [C]//2021 IEEE Winter Conference on Applications of Computer Vision, January 3-8, 2021, Waikoloa, HI, USA. New York: IEEE Press, 2021: 949-958.
- [11] 林两魁, 王少游, 唐忠兴. 基于深度卷积神经网络的红外过采样扫描图像点目标检测方法[J]. 红外与毫米波学报, 2018, 37(2): 219-226.
Lin L K, Wang S Y, Tang Z X. Point target detection in infrared over-sampling scanning images using deep convolutional neural networks[J]. Journal of Infrared and Millimeter Waves, 2018, 37(2): 219-226.
- [12] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [13] Noh H, Hong S, Han B. Learning deconvolution network for semantic segmentation[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1520-1528.
- [14] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [15] Liu Z, Li J G, Shen Z Q, et al. Learning efficient convolutional networks through network slimming[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2755-2763.

- [16] Huang Y F, Tang Z R, Chen D, et al. Batching soft IoU for training semantic segmentation networks[J]. IEEE Signal Processing Letters, 2020, 27: 66-70.
- [17] Wang B, Ma F Q, Ge L J, et al. Icing-EdgeNet: a pruning lightweight edge intelligent method of discriminative driving channel for ice thickness of transmission lines[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 20151878.
- [18] Jiang T X, Huang T Z, Zhao X L, et al. Multi-dimensional imaging data recovery via minimizing the partial sum of tubal nuclear norm[J]. Journal of Computational and Applied Mathematics, 2020, 372: 112680.
- [19] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2021-06-08]. <https://arxiv.org/abs/2004.10934>.
- [20] Wei X C, Liang Y, Li X H, et al. TGPA: tile-grained pipeline architecture for low latency CNN inference[C]// 2018 IEEE/ACM International Conference on Computer-Aided Design (ICCAD), November 5-8, 2018, San Diego, CA, USA. New York: IEEE Press, 2018: 18356926.
- [21] Zhang S F, Chi C, Yao Y Q, et al. Bridging the gap between anchor-based and anchor-free detection via adaptive training sample selection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 9756-9765.
- [22] 李俊宏, 张萍, 王晓玮, 等. 红外弱小目标检测算法综述[J]. 中国图象图形学报, 2020, 25(9): 1739-1753.
Li J H, Zhang P, Wang X W, et al. Infrared small-target detection algorithms: a survey[J]. Journal of Image and Graphics, 2020, 25(9): 1739-1753.
- [23] 魏敬和, 林军. 深度学习算法、硬件技术及其在未来军事上的应用[J]. 电子与封装, 2019, 19(12): 1-6, 22.
Wei J H, Lin J. Deep learning algorithms, hardware and their military applications[J]. Electronics & Packaging, 2019, 19(12): 1-6, 22.
- [24] 梅亚军, 王唯佳, 彭析竹. 基于FPGA的U-Net网络硬件加速系统的实现[J]. 电子与封装, 2020, 20(6): 40-45.
Mei Y J, Wang W J, Peng X Z. Implementation of FPGA-based U-net network hardware acceleration system[J]. Electronics & Packaging, 2020, 20(6): 40-45.