

基于U形特征融合的遥感图像目标检测方法

尹雪乔¹ 宋叔尼^{2*}

¹(东北大学理学院 辽宁 沈阳 110819)

²(广东培正学院 广东 广州 510830)

摘要 由于遥感图像具有视野大、目标小等特殊性质,如何准确地检测遥感图像的目标仍然是具有挑战性的问题。基于YOLOv3进行改进,提出新方法U-YOLO。改进YOLOv3的预选框的选取方法,解决预选框选取不平衡的问题。提出U形特征提取模块来提取更深层次的特征,提高检测的效果。提出应用于损失函数的面积因子,改善小目标检测难的问题。分别在NWPU VHR-10数据集和RSOD数据集进行实验,实验结果表明,该方法分别比原始的YOLOv3提高了0.079和0.065。

关键词 目标检测 遥感图像 深度学习

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.08.021

U-SHAPE FUSION FEATURE BASED OBJECT DETECTION METHOD FOR REMOTE SENSING IMAGES

Yin Xueqiao¹ Song Shuni^{2*}

¹(College of Science, Northeastern University, Shenyang 110819, Liaoning, China)

²(Guangdong Peizheng College, Guangzhou 510830, Guangdong, China)

Abstract Due to the particularity of remote sensing image, such as wide field of vision, small target, how to quickly and accurately detect targets in remote sensing images is still a challenging problem. A new method based on improved YOLOv3, U-YOLO, is presented. The selection method of anchor box was improved, and the problem of unbalanced selection of pre-selection box was solved. A U-shaped feature extraction module was proposed to extract deeper features and improve the detection effect. The area factor applied to the loss function was put forward, which improved the difficulty of small target detection. The experiments were conducted on the NWPU VHR-10 dataset and RSOD dataset. Experimental results show that this method is 0.079 and 0.065 higher than the original YOLOv3 in the two groups of experiments, respectively.

Keywords Object detection Remote sensing image Deep learning

0 引言

随着遥感技术的飞速发展,遥感图像在气象、农业、水利、资源开发、环境保护等诸多领域发挥了重要作用。目标检测是计算机视觉的经典任务,在遥感方向上有很多应用,如船舶检测、飞机检测等。传统的目标检测方法是手工提取的特征放入分类器中去训练。特征提取方法包括局部二值模式(LBP)^[1]、尺度不变特征变换(SIFT)^[2]、方向梯度直方图(HOG)^[3]和Haar^[4]等。传统方法提取出来的特征比较明了且易于理解。但是,特征提取过程复杂,手工设计的特征的鲁

棒性不强。并且大多数只是针对于单一类别进行检测,如文献[5]针对机场跑道进行检测,文献[6]专门研究油罐检测。

近年来,神经网络在各个领域的应用表现较为优异,基于深度学习的目标检测方法逐渐受到学者的关注和研究,整体上分为两种,两阶段目标检测方法和一阶段目标检测方法。两阶段目标检测方法也被称为基于区域的目标检测方法,该类算法首先生成候选区域,然后对候选区域进行分类与回归。R-CNN^[7]使用选择性搜索算法生成区域建议,这样R-CNN避免了遍历所有区域,只关注可能存在目标的区域,然后使用AlexNet^[8]提取区域建议中的特征,最后将提取出来的

特征送入各个 SVM 分类器中判断是否属于这个类别。FastRCNN^[9] 进一步改进了 R-CNN 的特征提取的部分,只需进行一次特征提取即可得到特征图。采用卷积网络来生成区域建议,不但减少了区域建议的数量,而且提高了区域建议的质量。FPN^[10] 为了解决多尺度检测的问题,使用多层特征图进行预测,增加了对尺度变化的鲁棒性。

两阶段目标检测方法具有较高的准确率。但是由于两阶段方法模型结构较为复杂,参数较多,对于实时性要求较高的检测任务无法胜任,且在工业落地时,由于模型较大,对于设备的要求也较高。YOLO^[11] 提出了一个单阶段的思路,不需要生成候选区域,直接预测目标的类别概率和位置,YOLO 检测速度相比于两阶段方法更快。SSD^[12] 借鉴了 YOLO 的 RPN 理念并引入 prior box,相比于 YOLO 的准确度更高,同时兼顾了检测速度。YOLOv2^[13] 引入了 Faster RCNN 的 anchor box 思想,并使用了 K-means 生成预选框。YOLOv3^[14] 在 YOLOv2 的基础上借鉴了残差网络的结构,建立了特征提取网络中不同网络层之间的快速连接。

尽管卷积神经网络可以通过图像数据学习到目标的高级特征,有很强大的功能。然而遥感图像的一些特性导致目标检测仍然是一个具有挑战性的任务。

1) 遥感图像不同于 Imagenet 为代表的常规目标检测数据集,遥感图像从空中俯视拍摄,目标具有角度多变的特点。

2) 遥感图像的背景杂乱且复杂。很多目标处在复杂的周边环境,检测困难。

3) 遥感图像通常涵盖范围较广,小目标居多,而遥感图像尺度一般较大,导致检测任务困难。

深度学习的目标检测算法大多数针对日常场景下的数据集,使得算法应用于遥感图像时效果并不理想。针对这个问题,基于 YOLOv3 进行改进,提出一种应用于多尺度多类别的遥感图像上的 U 形特征融合目标检测方法,主要工作如下:

1) 设计 UFE 模块并将其改进至 YOLOv3 模型中,可以进一步提取更深层次的特征,提高检测效果。

2) 在训练集的长度和宽度数据进行了均衡,解决了先验框聚类结果偏小的问题。

3) 提出应用于损失函数的面积因子,以此加大小目标的损失,大大提高小目标的检测效果,解决小目标检测难的问题。

1 相关工作

YOLOv3 的骨干网络为 Darknet-53,主要负责基本的特征提取工作。并且它的设计借鉴了残差网络的思

想,在层之间设计了快捷链路。这样做的好处是防止在多次卷积的过程中丢失有效信息,也降低了训练时出现梯度消失的可能性。YOLOv3 算法借鉴了 FPN 的思想,采用金字塔特征采样的方法,从不同感受野提取特征并形成不同大小的特征图。通过上采样将不同大小的特征图进行通道方向上的合并,提高了图像中目标检测的准确性。

YOLOv3 结构如图 1 所示,通过特征提取,得到三幅不同大小的特征图。小尺寸特征图足以负责提取大面积的物体特征,如操场、篮球场;大尺寸特征图相对于小尺寸特征图对于小尺寸物体的特征细节更清晰,如飞机、船舶。该算法将三个不同尺寸的网格映射到原始图像上,并将原始图像划分成不同大小的网格。YOLOv3 在每个网络中设置 3 个不同大小的 anchor box,并在每个网格中输出预测框向量。向量值包括预测框中所包含的置信值,预测框相对 anchor box 的长、宽偏差,中心坐标偏差和存在目标的概率。




图 1 YOLOv3 结构

2 U 形特征融合目标检测方法

本节分别介绍了针对 YOLOv3 进行的三个改进点,改进后的方法命名为 U-YOLO。

2.1 UFE 模块

为了进一步提取到多层次的特征,从医学图像分割模型 U-NET^[15] 中得到启发,构建 UFE 模块,并改进至 YOLOv3 模型中。U-NET 模型通过三层编码结构和三层解码结构提取特征,并通过 U 形结构将浅层信息和高层信息结合起来。经过多次下采样后的高层信息可以提供目标在整幅图像中的上下文语义信息,这个特性对于对象分类很有帮助。编码器输入的特征图通过 connection 直接传递到相同高度的解码器,将浅层信息融合进去,可以提供更精细的特征细节。因此 U-NET 在图像大目标小的医学图像中应用比较好。而遥感图像具有相似的特点。

U-NET 为一个完整的语义分割模型,参数总量约为 7.76 MB。如果完整地将其融合到 YOLOv3,网络层数将会变多,可能会导致网络过深的问题,且参数增加太多,在训练过程中容易出现过拟合或者梯度弥散的情况。因此基于 U-Net 的思路设计了 UFE 模块如图 2 所示。




图 2 UFE 模块结构

编码过程中,先通过卷积层继续学习特征,卷积核大小均为 3×3 ,激活函数使用 LeakyReLU。为了防止特征图缩减得太小而丢失位置信息,采用 samepadding 的方式将其填充恢复为原图大小。解码过程使用 1×1 卷积,激活函数仍旧使用 LeakyReLU。使用 LeakyReLU 而不是 ReLU,是因为 LeakyReLU 解决了 ReLU 神经元死亡的问题。U 型结构可以在保持特征图尺度不变的前提下大幅增加非线性特性。解码同时将编码过程中对应的高度的特征图进行通道拼接,以补充特征细节。通过这样的方法,既能得到更多层次的特征,又不会因为网络过深引起梯度弥散。改进后的整体模型结构如图 3 所示。

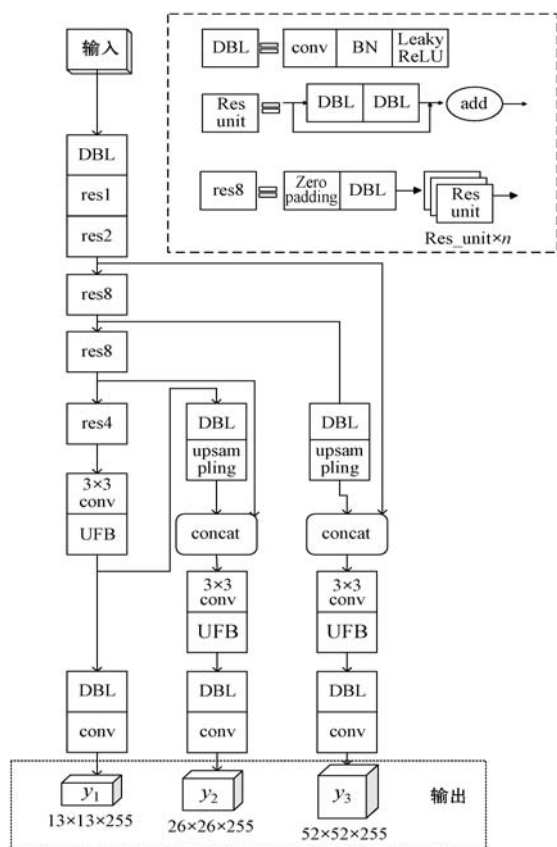


图 3 改进后的结构

通过表 1 可知,原始 YOLOv3 模型大小约为 235 MB,改进后的模型仅仅比原始的 YOLOv3 大 4 KB,模型大小的增加几乎可以忽略不计。

表 1 原始模型和改进结构后的大小

模型	YOLOv3	U-YOLO
模型大小/KB	241 140	241 144

2.2 Anchor box

本文延续了 YOLOv3 的三个预测模块,分别负责预测大目标、中目标、小目标,每个模块有三个先验框 (anchor box)。先验框是从训练集中真实框 (ground truth) 中聚类得到的几个不同尺寸的框,这样就可以得到具有代表性形状的长和宽。先验框可以对预测的对象范围进行约束,并加入了尺寸先验经验。这样做的目的是避免模型训练时盲目地寻找长宽值,可以加快模型的收敛。YOLOv3 采用 K-means 方法对目标的长和宽的集合进行聚类。步骤如下:随机选取 9 个样本作为簇中心;计算所有样本与这 9 个“簇中心”的距离;对于每一个样本,将其划分到与其距离最近的“簇中心”所在的簇中;对于新的簇计算各个簇的新的“簇中心”。如果 K-means 聚类方法使用欧氏距离函数,较大的定位框会比较小的定位框产生更多的误差,聚类结果可能会偏离。为此,采用的评判标准是 IOU 得分。

但是遥感图像中小目标较多,例如车辆、船只和飞机,直接聚类会导致聚类出的先验框偏小,使得负责拟合中目标和大目标的先验框偏离实际,影响整体模型的检测效果。不同于传统目标检测,例如 PASCAL VOC 数据集,图片的视角和拍摄角度、高度相关,因此同一类别的目标可能大小相差很大。但是遥感图像采集高度稳定,相同类别的目标大小相近。可以对少类别的大、中目标进行扩增,而后再用 K-means 方法聚类,可以聚类出更合理的先验框。具体方法如下:

- 1) 分别统计数据集中大、中、小三种目标的数量。
- 2) 算出大、中目标相比于小目标的数量缺失量。
- 3) 在大、中目标的 ground truth 的值进行相应数值的过采样。
- 4) 将过采样后的数据重新利用 Kmeans 方法进行聚类。

如图 4 所示,图 4(a)是原始 K-means 算法聚类出的先验框,图 4(b)是改进后聚类出的先验框的结果,相比于 YOLOv3 使用 K-means 聚类的更均衡。




图4 先验框聚类

2.3 面积因子

遥感图像为航拍或卫星拍摄的图像,相比于其他图像数据集,场景更加复杂、多样,并且小目标占有的像素点少,包含的信息少,因此更难识别出小目标。在现实生活中,人眼识别时也是如此情况,小目标往往需要人更细心地寻找和分辨,相比于大目标要给予更多的注意力。YOLOv3 的损失函数包括三个部分,分别是 bbox 损失、置信度损失和类别损失。bbox 损失用于计算 bbox 与 groundtruth 之间的中心点位置和大小差异。式(1)为原始 YOLOv3 的 bbox 损失部分。

$$\begin{aligned} loss(o_{\text{bjeect}}) = & \lambda_{\text{coord}} \sum_{i=0}^{K \times K} \sum_{j=0}^M I_{ij}^{\text{obj}} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \\ & \lambda_{\text{coord}} \sum_{i=0}^{K \times K} \sum_{j=0}^M I_{ij}^{\text{obj}} [(w_i - \hat{w}_i)^2 + (h_i - \hat{h}_i)^2] \end{aligned} \quad (1)$$

式中: λ_{coord} 是用来协调不同大小矩形框对误差函数贡献的系数; x_i 和 y_i 是中心点的坐标; w_i 和 h_i 是目标的宽和高。当网格中存在目标时, I_{ij}^{obj} 的值为1,否则为0。由式(1)可知,bbox 损失采用 L2 损失函数,当模型预测出的结果相对于目标尺寸偏移同样比例时,小目标对于损失函数的影响远远小于大目标,这更加剧了小目标在神经网络中难预测、预测不准的问题。为解决这个问题,提出一项面积因子,并将其应用于 bbox 损失上。给予小目标更大的惩罚权重,这样可以更有利于小目标的学习。

训练中,样本的长和宽在训练时经过归一化,因此长和宽的乘积小于1。需要给更小的目标更大的惩罚,面积因子应是单调递减函数。本文设计的面积因子计算方式如式(2)所示。

$$\gamma = 1 + e^{-w \times h} \quad (2)$$

如图5所示为面积因子的函数图像,并且举例数据集中某船只和某操场对应的面积因子的数值。横坐标为 $w \times h$ 的值,纵坐标为面积因子值 γ 。通过图像可知,船只对应的面积因子的值比操场所对应的更大。改进后的 bbox 损失函数如式(3)所示,其中 γ 为面积因子。




图5 面积因子图像

$$\begin{aligned} loss(o_{\text{bjeect}}) = & \lambda_{\text{coord}} \sum_{i=0}^{K \times K} \sum_{j=0}^M I_{ij}^{\text{obj}} \times \gamma \times [(x_i - \hat{x}_i)^2 + \\ & (y_i - \hat{y}_i)^2] + \lambda_{\text{coord}} \sum_{i=0}^{K \times K} \sum_{j=0}^M I_{ij}^{\text{obj}} \times \\ & \gamma \times [(w_i - \hat{w}_i)^2 + (h_i - \hat{h}_i)^2] \end{aligned} \quad (3)$$

3 实验

本文使用了两个数据集做实验,分别是 NWPU VHR-10 dataset^[16]和 RSOD-dataset^[17]。我们将数据按70%和30%分为训练集和测试集。实验在32 GB 显存的 Tesla P100 GPU 上运行。为了验证算法的有效性,将改进后的算法 U-YOLO 与四种最先进的方法进行比较:YOLOv3、SSD、Faster R-CNN、FPN。这四种算法在当前的目标检测领域都是最优的。

3.1 数据集

NWPU VHR-10 数据集是用于检测10种地理空间目标的公共遥感数据集。这十类物体分别是飞机、轮船、储油罐、棒球场、网球场、篮球场、田径场、港口、桥梁和车辆。

RSOD-dataset 也是遥感图像方面经典的数据集。它包括四种类型的对象:飞机、操场、立交桥和油桶。其中:446 幅图像共含有4 993 架飞机;189 幅图像共含有191 个游乐场;176 幅图像共含有180 个立交桥;165 幅图像共含有1 586 个油桶。

3.2 评价指标

在实验中,使用 AP (Average Precision) 和 mAP (mean Average Precision) 指标来评估这五种算法的性能。AP 是 Precision-Recall 曲线中曲线下的面积,代表测试结果的平均准确率,也是最常用的性能指标。mAP 是对每个类型的 AP 取平均值。其中, $p_{\text{recision}} = T_p / (T_p + F_p)$, $R_{\text{ecall}} = T_p / (T_p + F_N)$, T_p 、 F_p 和 F_N 分别表示真阳性、假阳性和假阴性的数目。

3.3 实验效果对比

第一个实验中,在 NWPU VHR-10 数据集下进行训练和测试。分别计算了包括 U-YOLO 在内的五种模型的每类目标的 AP 和整体的 mAP,实验结果如表 2 所示。U-YOLO 在船舶、车辆、飞机检测效果相比于 YOLOv3 分别提高了 0.06、0.02、0.06。由此可以看出改进后的损失函数在小目标的检测中表现得更好。且 U-YOLO 在 MAP 的表现中也是最好的,超过了原始的 YOLOv3 0.07。U-YOLO 比两阶段的 Faster RCNN 和 FPN 表现结果也更加优异,mAP 指标分别高出 0.081 和 0.038,且 U-YOLO 模型大小优于两阶段的模型,速度快于两阶段的模型。

表 2 NWPU VHR-10 数据集下不同方法的检测结果对比

准确性	类别	FPN	Faster RCNN	SSD	YOLOv3	U-YOLO
AP	飞机	0.94	0.91	0.90	0.93	0.99
	轮船	0.81	0.84	0.72	0.77	0.83
	棒球场	0.94	0.91	0.93	0.93	0.99
	网球场	0.87	0.80	0.78	0.83	0.95
	篮球场	0.90	0.80	0.75	0.84	0.99
	田径场	0.99	0.91	0.90	0.84	1.00
	港口	0.70	0.81	0.69	0.83	0.80
	桥梁	0.79	0.60	0.65	0.73	0.91
	车辆	0.89	0.81	0.67	0.82	0.84
	储油罐	0.96	0.97	0.93	0.88	0.88
mAP		0.879	0.836	0.792	0.838	0.917

第二个实验中使用了 RSOD 数据集,实验结果如表 3 所示。U-YOLO 的性能最好,主要是因为 UFE 模块能够提取更深层次的特征。mAP 从 YOLOv3 的 87.3% 提升到 93.8%,提高了 0.065。U-YOLO 模型的飞机对应的 AP 值为 94%,操场的 AP 值为 78.42%,油桶的 AP 值为 83%,立交桥的 AP 值为 81%。

表 3 RSOD 数据集下不同方法的检测结果对比

准确性	类别	FPN	FASTER RCNN	SSD	YOLOv3	U-YOLO
AP	飞机	0.94	0.91	0.92	0.93	0.94
	操场	0.95	0.92	0.93	0.92	1.00
	油桶	0.85	0.84	0.79	0.83	0.94
	立交桥	0.88	0.80	0.69	0.81	0.87
mAP		0.905	0.868	0.832	0.873	0.938

第三个实验,使用 NWPU VHR-10 数据集对比原

始 YOLOv3 单独加入单个改进点的效果。通过表 4 可知,加入 UFE 模块的 YOLOv3 比原始的 YOLOv3 提高了 0.038,使用改进先验框的 YOLOv3 比原始使用 K-means 聚类的 YOLOv3 提高了 0.025,使用了面积因子的 YOLOv3 比没有使用面积因子的 YOLOv3 提高了 0.045。通过实验结果能够看出,所提出的三个改进点都具有效果。

表 4 NWPU VHR-10 数据集上改进效果对比

方法	YOLOv3	YOLOv3 + UFE 模块	YOLOv3 + 改进 anchor box	YOLOv3 + 面积因子
mAP	0.838	0.876	0.863	0.894

为证明本文提出的面积因子的泛化性,将面积因子分别应用于其他模型的损失函数上,并在 NWPU VHR-10 数据集上做了实验,结果如表 5 所示。结合表 4 和表 5 可知,面积因子的改进点对于 FPN、Faster RCNN、SSD 这三个模型都有不同程度的提升,分别为 0.016、0.025、0.031。由此可以证明面积因子在除 YOLOv3 以外的模型也有较好的表现,可见本文所提出的面积因子的泛化性能较好。

表 5 不同模型使用面积因子对比

指标	FPN + 面积因子	Faster RCNN + 面积因子	SSD + 面积因子
mAP	0.895	0.861	0.823
提升	0.016	0.025	0.031

4 结 语

随着遥感技术的发展,遥感图像对于资源调查、环境监测等领域越来越重要。遥感图像具有背景复杂、尺寸大、目标小的特点,针对遥感图像的目标检测方法具有研究的意义。本文在 YOLOv3 的基础上进行改进,设计 U 形特征提取模块,通过过采样使得先验框聚类更加合理,且设计了应用于损失函数的面积因子,改善了小目标的检测效果。两个数据集上进行实验,证明本文方法是一个有效的遥感图像目标检测模型。在接下来的工作中,我们将不断调整和优化网络结构,进行模型加速和模型压缩,以此为更好地工业落地而做出努力。

参 考 文 献

[1] Ojala T, Pietikainen M, Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification wit-h local

- binary patterns[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(7): 971–987.
- [2] Lowe D. Distinctive image features from scale-invariant keypoints[J]. *International Journal of Computer Vision*, 2004, 60: 91–110.
- [3] Dalal N, Triggs B. Histograms of oriented gradients for human detection [C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005: 886–893.
- [4] Lienhart R, Maydt J. An extended set of Haar-like features for rapid object detection [C]//International Conference on Image Processing, 2002.
- [5] 王敏, 张艳宁, 孙瑾秋. 一种遥感图像机场跑道的多尺度提取方法[J]. *中国体视学与图像分析*, 2009, 14(3): 256–260.
- [6] 张维胜, 王超, 张红, 等. 基于遥感影像的油罐自动检测算法[J]. *宇航学报*, 2006(6): 1298–1301.
- [7] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580–587.
- [8] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2012, 60(6): 84–90.
- [9] Ren S, He K, 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.
- [10] Lin T, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936–944.
- [11] 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, 2016: 779–788.
- [12] Liu W, Anguelov D, Erhan D, et al. SSD: Single shot multibox detector [C]//European Conference on Computer Vision, 2016: 21–37.
- [13] Redmon J, Farhadi A. YOLO9000: Better, faster, stronger [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6517–6525.
- [14] Redmon J, Farhadi A. YOLOv3: An Incremental improvement [EB]. arXiv:1804.02767, 2018.
- [15] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation [C]//Medical Image Computing and Computer-assisted Intervention, 2015: 234–241.
- [16] Cheng G, Han J, Zhou P, et al. Multi-class geospatial object detection and geographic image classification based on collection of part detectors[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 98: 119–132.
- [17] Long Y, Gong Y, Xiao Z, et al. Accurate object localization in remote sensing images based on convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(5): 2486–2498.
- ~~~~~
- (上接第 120 页)
- [3] Preeth S K S L, Dhanalakshmi R, Kumar R, et al. An adaptive fuzzy rule based energy efficient clustering and immune-inspired routing protocol for WSN-assisted IoT system [J]. *Journal of Ambient Intelligence and Humanized Computing*, 2018(12): 1–13.
- [4] Hawbani A, Wang X, Al-Sharabi Y, et al. LORA: Load-balanced opportunistic routing for asynchronous duty-cycled WSN [J]. *IEEE Transactions on Mobile Computing*, 2018, 18(7): 1601–1615.
- [5] Rajoua A. Opportunistic routing protocols in wireless sensor networks [J]. *Wireless Personal Communications*, 2019, 104(3): 921–933.
- [6] Zhang X, Tao L, Yan F, et al. Shortest-latency opportunistic routing in asynchronous wireless sensor networks with independent duty-cycling [J]. *IEEE Transactions on Mobile Computing*, 2020, 19(3): 711–723.
- [7] Aljebori S, Finjan A. A Suggested angles-based sensors deployment algorithm to develop the coverage in WSN [C]//2nd International Conference on Inventive Systems and Control (ICISC 2018), 2018.
- [8] Wei Z, Li B, Hu W, et al. Hamming-luby rateless codes for molecular erasure channels [J]. *Nano Communication Networks*, 2019, 23: 100280.
- [9] Jain S, Bose R. Rateless-code-based secure cooperative transmission scheme for industrial IoT [J]. *IEEE Internet of Things Journal*, 2020, 7(7): 6550–6565.
- [10] Du W, Li Z, Liando J C, et al. From rateless to distanceless: Enabling sparse sensor network deployment in large areas [J]. *IEEE/ACM Transactions on Networking*, 2015, 24(4): 2498–2511.
- [11] Rossi M, Zanca G, Stabellini L, et al. SYNAPSE: A network reprogramming protocol for wireless sensor networks using fountain codes [C]//IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications & Networks. IEEE, 2010.
- [12] Zuniga M, Krishnamachari B. Analyzing the transitional region in low power wireless links [C]//2004 1st Annual IEEE Communications Society Conference on Sensor and Ad Hoc Communications and Networks. IEEE, 2004.