

基于改进 YOLOv8 的遥感图像目标检测算法

郑杰, 宁佳绪, 刘子怡

(沈阳理工大学 信息科学与工程学院, 沈阳 110159)

摘要: 针对遥感图像背景复杂、小目标数量多、目标尺度各异的特点, 提出一种基于改进 YOLOv8 的遥感图像目标检测算法。首先, 在主干网络引入深度可分离卷积(DSConv), 减少模型的计算量和参数量, 提升计算效率; 其次, 为提升对遥感图像的目标检测能力, 在颈部(Neck)添加一种高效通道空间注意力模块(ECSA), 通过对通道和空间特征的融合提高模型的识别能力; 最后, 增加检测尺度为 160×160 的小目标检测层, 提升图像中小目标检测能力, 并将边界框损失函数替换为 SIOU, 关注预测边界框与真实边界框的角度信息, 提升检测精度。在遥感图像数据集 SIMD 上的实验结果表明: 改进 YOLOv8 算法具备更强的特征提取能力, 与 YOLOv8 算法相比, 平均精度均值提升了 2.63%, 模型参数量减少了 19.43%, 模型计算量减少了 28.31%, 证明了改进 YOLOv8 算法的有效性。

关键词: 目标检测; YOLOv8; 遥感图像; 损失函数; 注意力机制

中图分类号: TP391.41 **文献标志码:** A **DOI:** 10.3969/j.issn.1003-1251.2025.05.008

Remote Sensing Image Target Detection Algorithm Based on Improved YOLOv8

ZHENG Jie, NING Jiaxu, LIU Ziyi

(Shenyang Ligong University, Shenyang 110159, China)

Abstract: Aiming at the characteristics of remote sensing image with complex background, large number of small targets and different target scales, a remote sensing image target detection algorithm based on improved YOLOv8 is proposed. Firstly, the depth separable convolution (DSConv) is introduced to construct the backbone network, which reduces the computational volume and number of parameters of the model and improves the computational efficiency. Secondly, in order to improve the detectability for remote sensing images of the target, an efficient channel spatial attention module (ECSA) proposed is added in the Neck section to improve the recognition ability of the model by fusing the channel and spatial features. Finally, a small target detection layer with a detection scale of 160×160 is added to improve the detectability of small targets in the image; the bounding box loss function is replaced with SIOU, which focuses on the angle information between the predicted bounding box and the real bounding box to improve the detection accuracy. The experimental results on the remote sensing image dataset SIMD show that the optimized YOLOv8 algorithm demonstrates significantly improved feature extraction capacity. Compared with the YOLOv8 algorithm, the average accuracy is improved by 2.63%, the model parameter quantity is reduced by 19.43%, and the model computation is reduced by 28.31%, which proves the effectiveness of the improved YOLOv8 algorithm.

Key words: target detection; YOLOv8; remote sensing images; loss function; attention mechanism

遥感图像目标检测是利用遥感技术获取图像数据,通过计算机视觉和机器学习等方法,对图像中的特定目标进行识别和定位的技术。遥感图像目标检测在军事、城市规划、环境检测等领域具有广泛的应用^[1]。随着遥感传感器的不断发展,遥感图像的光谱范围和分辨率尺度不断增加,图像所包含的信息日益复杂。遥感图像通常存在小目标数量多、背景复杂度高、尺度差异大等特点,增加了遥感图像的目标检测难度。

传统的目标检测方法^[2]主要依赖于手工提取和特定的图像处理技术,对复杂场景和多变目标的检测能力有限。近年来,基于深度学习的目标检测算法逐渐取代传统的目标检测方法。基于深度学习的目标检测算法主要分为两阶段目标检测和单阶段目标检测。两阶段目标检测主要分为候选区域生成、特征提取、特征分类、目标识别等步骤。典型的两阶段目标检测算法有 R-CNN^[3]、Fast R-CNN^[4]、Faster R-CNN^[5]等。单阶段目标检测算法直接在图像上应用卷积神经网络(CNN)进行特征提取和目标检测,输出包含目标的类别和边界框位置。典型的单阶段目标检测算法有 YOLO 系列^[6-7]、SSD^[8]等。由于单阶段目标检测算法不需要预先生成候选区域,免去了繁琐的数据转换和计算,减少了计算成本,具有更快的处理速度,相较于两阶段目标检测应用更广泛^[9-10]。

目前,以 YOLO 系列为代表的单阶段目标检测算法性能优于很多其它目标检测算法,但对于遥感图像的检测精度不如两阶段目标检测算法。为了增强 YOLO 系列对遥感图像的检测精度,不少研究者对 YOLO 系列进行了改进。文献[11]针对 YOLOv8 设计了一种空间和通道注意力机制的自校准随机注意(SC_sA)模块,实现对上下文信息的自适应编码,增强了小目标的检测能力。文献[12]基于 YOLOv8 提出了名为 LAR-YOLOv8 的改进方法,该方法设计一种注意力引导的双向特征金字塔网络,有效避免了漏检和误检问题,但改进方案会增加网络层数,导致模型检测速度下降。文献[13]引入门控特征金字塔网络中的双层路由注意(BGFPN),利用高效的特征聚合网络和重参数化技术来优化不同尺度特征图之间的信息交互

以捕捉小目标的关键特征信息。文献[14]在 YOLOv8 的基础上提出一种针对滑坡的检测模型,将 CBAM 注意力机制融合到模型中以提高检测准确率,但由于滑坡特征形态不明显,模型仍存在一定的漏检现象。

尽管对遥感图像目标检测的研究取得了一定的进展,但仍存在参数量大、推理时间长、复杂背景下小目标检测精度不高等问题。为此,本文提出一种基于改进 YOLOv8 的遥感图像目标检测算法,具体内容如下:

1) 在主干网络(Backbone)引入深度可分离卷积(DSConv),减少模型的参数量和计算量,提升检测效率;

2) 增加 160×160 大小的小目标输出层,提高网络对小目标的检测能力;

3) 在颈部(Neck)添加一种高效通道空间注意力(ECSA)模块,提高检测准确率;

4) 对损失函数进行改进,采用 SIoU 损失函数,同时关注预测边界框和真实边界框的角度、形状、距离的关系,提高模型的鲁棒性。

1 YOLOv8 模型

YOLOv8 根据模型大小和准确性划分为五种模型,包括 YOLOv8n、YOLOv8l、YOLOv8m、YOLOv8s、YOLOv8x。本文基于速度和准确性的考虑,选取 YOLOv8s 作为基线模型。其主要结构如图 1 所示^[7],分为输入端、Backbone、Neck、头部(Head)四部分。在输入端,数据首先经过 mosaic 数据增强和 mixup 数据增强帮助模型学习到更鲁棒的特征。在 Backbone 部分,使用一系列的卷积(Conv)、C2f、快速空间金字塔池化层(SPPF)模块。C2f 模块在实现进一步轻量化的同时,通过并行更多的梯度流分支,增强模型的收敛速度和效果。SPPF 模块通过增大感受野,使模型可获得更多上下文信息,从而提升目标检测的准确性。Neck 部分经过一系列的下采样(Upsample)和特征融合(Concat),负责融合不同尺度的特征图,帮助模型捕捉到不同层次的结构信息,提升检测的准确性和鲁棒性。Head 部分主要包括 Detect 模块,负责从网络的特征图中提取目标的位置和类别信息。

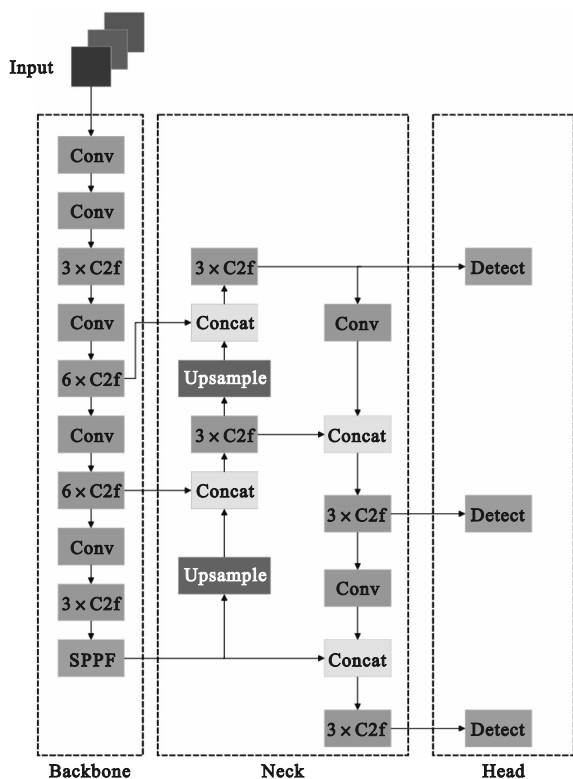


图1 YOLOv8 结构

Fig.1 YOLOv8 structure

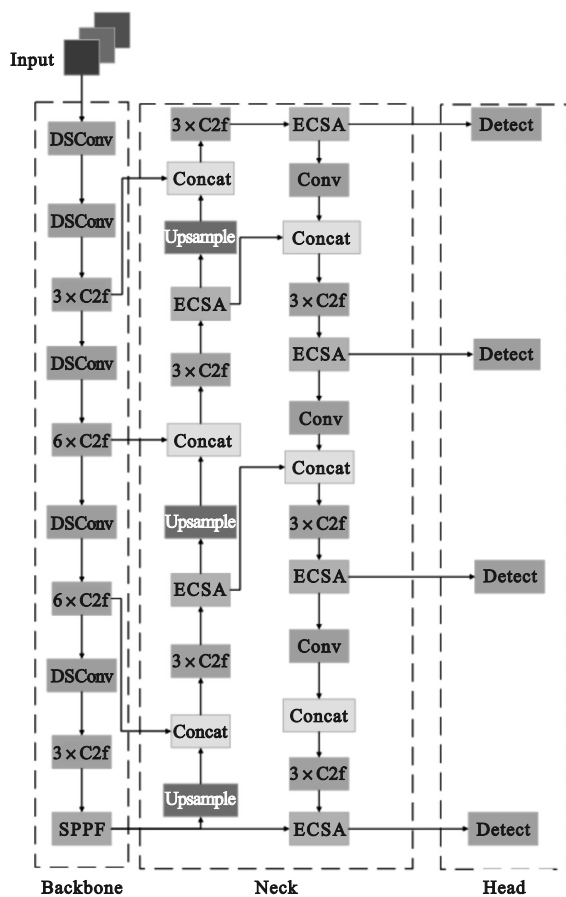


图2 改进的 YOLOv8 结构

Fig.2 Structure of improved YOLOv8

2 改进的 YOLOv8 模型

改进后的 YOLOv8 模型结构如图 2 所示。

2.1 引入轻量化 DSConv 模块

传统卷积将卷积核应用于输入特征图的每个通道,并将每个通道的卷积结果相加以创建单个输出特征图。上述过程在输入特征图的所有通道上重复,以创建多个输出特征图,导致参数数量呈平方级增长,增加了模型的存储需求。本文引入 DSConv 模块,将卷积操作分解为深度卷积和逐点卷积,以减少参数数量,提升模型计算效率^[15]。

DSConv 包含两个步骤。首先,执行深度卷积,使用相应的卷积核对输入特征图的每个通道进行独立卷积,从而产生与输入特征图具有相同通道数的中间特征图。然后执行逐点卷积,将 1×1 卷积核应用于中间特征图的每个通道,从而产生最终的输出特征图。DSConv 模块结构如图 3 所示,其中 N 表示输入特征图的数量, n 表示卷积核大小。

2.2 引入注意力机制 ECSA

计算机视觉中,注意力机制通常分为通道注意力机制和空间注意力机制。通道注意力能够对

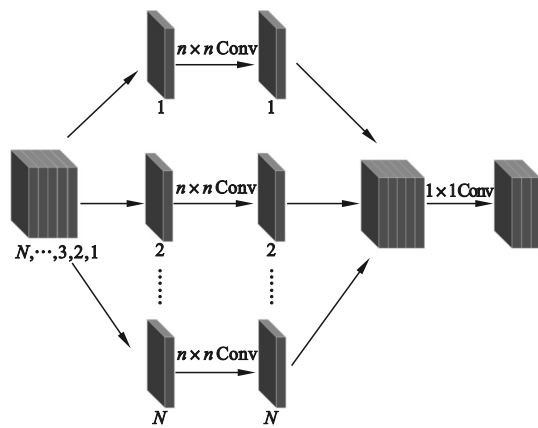


图3 DSConv 结构模块图

Fig.3 Structure of DSConv module

特征通道的重要性加权,强调有用的特征并抑制不重要的特征;空间注意力关注特征图上的每个位置,可以捕捉到局部之间的关系,对于细节信息更加敏感。高效的通道注意力模块(ECA)^[16]解决了注意力机制中性能与复杂性的矛盾,避免了使用复杂的全连接层和通道降维操作,通过局部跨通道交互捕获通道描述符上的局部跨通道依赖关系,ECA 注意力模块如图 4 上半部分所示。然而,

ECA 模块仅关注图像的通道信息,忽略了空间信息。为进一步提升注意力模块对特征提取的能力,提出一种高效的通道空间注意力模块 ECSA,如图4所示。该模块在原始 ECA 模块的基础上加入了空间注意力模块,提高了遥感图像中检测目标的识别能力。空间注意力模块考虑图像的空间特征,核心是获取图像像素空间的特征系数,再将其作用于原始特征,进而关注图像重要区域的特征,忽略不重要的背景区域特征,更准确地定位目标位置。本文设计了一种空间注意力模块,其结构如图4下半部分所示。对于输入形状为 $C \times H \times W$ 的特征图 F (其中 C 表示图像的通道数、 H 表示图像的高度、 W 表示图像的宽度),首先分别使用两种全局池化层对其通道进行压缩,获得两个 $1 \times H \times W$ 的特征图,并在通道维度上进行拼接,得到形状为 $2 \times H \times W$ 的特征图;然后利用感受野较大的 7×7 卷积(通道数为1),对特征进一步融合;最后使用 Sigmoid 激活函数获得最终形状为 $1 \times H \times W$ 的注意力权重。将输入特征图和注意力权重在空间维度相乘,获得形状为 $C \times H \times W$ 的输出特征图,其计算表达式为

$$\begin{aligned} M_s(F) &= F \times \sigma(f^{(7 \times 7)}(\text{AvgPool}(F); \text{MaxPool}(F))) \\ &= \sigma(f^{(7 \times 7)}([\mathbf{F}_{\text{Avg}}^S; \mathbf{F}_{\text{Max}}^S])) \end{aligned} \quad (1)$$

式中: $M_s(F)$ 表示空间注意力输出结果; F 表示输入特征图; AvgPool 表示全局平均池化; MaxPool 表示全局最大池化; $f^{(7 \times 7)}$ 表示卷积核尺寸为 7×7 的卷积; σ 表示 Sigmoid 激活函数; $\mathbf{F}_{\text{Avg}}^S$ 和 $\mathbf{F}_{\text{Max}}^S$ 表示经过全局平均池化和全局最大池化后的特征图。

ECSA 注意力机制使用 ECA 作为通道注意力模块,突出遥感图像通道信息的同时可以有效降低参数量和计算量,同时加入空间注意力模块,可以进一步关注遥感图像检测目标的空间信息。ECAS 将通道注意力和空间注意力相结合的方式有利于提升目标检测的精度。

2.3 添加小目标输出层

由于遥感图像中小目标尺寸较小,YOLOv8 网络中需要3次下采样才能得到最大特征图,由此导致大量目标特征信息丢失,难以完整保留小目标特征信息。因此,本文在YOLOv8的基础上,添加一个适用于小目标检测的输出层。

在 Neck 部分经过上采样生成 80×80 的特征图后,再额外进行一次上采样操作,得到尺寸更大的 160×160 特征图,与 Backbone 部分经过 C2f 后得到的第一个 160×160 的特征图进行特征融

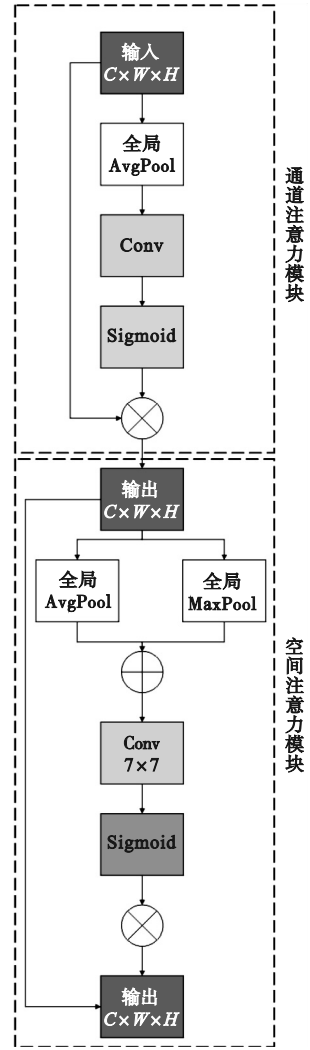


图4 ECSA 注意力机制

Fig. 4 ECSA attention mechanism

合后输入到 Head 结构中进行检测,实现较浅层特征图上小目标特征的提取。

2.4 优化损失函数

在目标检测任务中,检测性能取决于损失函数的设计。YOLOv8 中边界损失框函数使用的是 CIoU,而 CIoU 仅关注预测边界框与真实边界框的形状和位置信息,缺乏对预测边界框和真实边界框的角度关注。在遥感图像中小目标在整体图像中占比较大,角度信息对精确检测至关重要。而 SIoU^[17] 引入了预测边界框和真实边界框的角度差异,可以加快定位损失的收敛速度,提高检测精确度。

3 实验与结果分析

3.1 训练环境

模型训练前需要搭建所需训练环境,本文所

用的训练环境如下:CPU为Intel(R) Core(TM) i5-8300H;GPU为NVIDIA RTX A6000 64 GB;深度学习环境为Pytorch 2.2.1、Python 3.9、cuda 11.8;使用SGD优化器,学习率为0.01;批次大小为64,训练轮次为300。

3.2 数据集与数据增强

本文采用遥感目标检测数据集SIMD^[18]训练和评估改进模型。SIMD数据集中图像尺寸为1 027 × 768,共包含5 000幅遥感图像和45 096个实例。数据集中的实例共15类,分别为汽车、卡车、厢车、长车、公共汽车、客机、螺旋桨飞机、教练机、包机、战斗机、楼梯车、拖车、直升机、船、其他。将数据按照9:1的比例划分为训练集和验证集,测试集不单独划分。

数据增强部分首先利用mosaic将四幅图像进行翻转、缩放、色域变换等操作,然后再拼接成一幅图像;再利用mixup将两幅图像按比例进行混合,使原本两幅图像的真实框位于一幅图像上,进一步增强了输入数据的场景复杂度。

本文实验选取的评价指标包括准确率、召回率、平均精度均值(mAP@0.5)、参数量以及计算量。

3.3 注意力机制实验

为证明本文提出的ECSA注意力机制的优越性,选取目前通用的三种注意力机制ECA、

CBAM^[19]和GAM^[20]与YOLOv8结合,在SIMD遥感数据集上的检测效果进行对比,实验结果如表1所示。由表1可以看出,对比其它注意力机制,ECSA在遥感图像目标检测中具有更好的适用性,对遥感图像目标的特征学习能力更强。此外,该实验数据再一次证明,对比其它优异的注意力机制,ECSA注意力机制在应对遥感图像复杂背景下的抗干扰能力更强。

表1 注意力机制对比

模型	mAP@0.5	召回率	准确率
YOLOv8	93.21	91.19	87.61
YOLOv8 + ECA	94.44	92.16	88.68
YOLOv8 + CBAM	93.73	91.43	88.76
YOLOv8 + GAM	93.44	92.16	88.62
YOLOv8 + ECSA	95.97	93.42	90.13

3.4 对比实验

为进一步验证改进YOLOv8算法的创新型和优越性,本文选取主流目标检测算法Faster R-CNN、YOLOv5、YOLOv7、YOLOx、YOLOv8在遥感图像SIMD数据集上进行对比,结果如表2所示。可以看出,本文改进YOLOv8算法的性能均最优,参数量和计算量均为最低,其综合性能具有明显的优越性。

表2 对比实验结果

Table 2 Comparison of experimental results

模型	mAP@0.5/%	召回率/%	准确率/%	参数量/ 10^6	计算量/ 10^9
Faster R-CNN	74.99	79.45	57.50	137.099	370.210
YOLOv5	67.60	57.14	70.69	47.057	115.918
YOLOv7	91.72	85.74	88.89	37.620	106.472
YOLOx	87.02	82.64	79.89	54.209	156.011
YOLOv8	93.21	91.19	87.61	11.167	28.817

3.5 消融实验

为进一步研究各个模块对YOLOv8模型的影响,本文采用消融实验验证,实验结果如表3所示。YOLOv8算法的mAP@0.5为93.21%,参数量为 28.817×10^6 ,计算量为 11.167×10^9 ,单独在Backbone中将原卷积替换为DSCConv后,mAP@0.5降低至90.33%,参数量和计算量分别降低30.38%和29.93%;单独添加ECSA注意力机制后,mAP@0.5达到95.97%,较原模型提升2.76%;单独替换边界框损失函数为SIoU则不会

对参数量和计算量有所影响,mAP@0.5提升1.52%;单独添加小目标检测层后,参数量和计算量略微增加,mAP@0.5提升1.61%;同时添加DSCConv和ECSA注意力机制后,mAP@0.5提升1.75%,达到92.08%;再将损失函数替换为SIoU后,mAP@0.5提升2.46%,达到94.58%;最后添加小目标检测层后,mAP@0.5提升1.3%。由此可见,改进后的YOLOv8算法较原算法在保持轻量化的同时,平均精度mAP@0.5提升2.63%,达到95.84%。

表 3 消融实验结果

Table 3 Results of ablation experiments

模型	DSConv	ECSA	SiOU	小目标层	mAP@0.5/%	参数量/ 10^6	计算量/ 10^9
1					93.21	11.167	28.817
2	✓				90.33	7.775	20.192
3		✓			95.97	11.357	28.947
4			✓		94.73	11.167	28.817
5				✓	94.82	12.199	29.155
6	✓	✓			92.08	7.965	20.322
7	✓	✓	✓		94.54	7.965	20.322
8	✓	✓	✓	✓	95.84	8.997	20.660

3.6 检测效果比较

图 5 为 YOLOv8 和本文改进 YOLOv8 在 SIMD 遥感图像数据集上检测效果对比图。由图 5 可以看出:YOLOv8 算法明显存在漏检的情况,特别是当小目标数量多、目标较为密集时,本文改进 YOLOv8 算法的目标框拥有更高的置信度且明显改善了漏检率,表明改进 YOLOv8 算法在遥感图像数据集上有着较好的检测性能。




图 5 改进前后检测效果对比

Fig.5 Detection results before and after improvement

4 结论

本文针对遥感图像目标检测模型轻量化不足、识别精度低等问题,提出一种基于 YOLOv8 的改进算法。改进过程中,将 Backbone 部分引入轻量化卷积 DSConv 后,参数量和计算量分别减少 30.38% 和 29.93%;在 Neck 部分引入本文提出的 ECSA 注意力机制并添加小目标检测层后,解决

了背景复杂下遥感图像的识别精度;将边界框损失函数替换为 SiOU 后,能够更加关注预测边界框和真实边界框的角度信息,提升了检测精度。在遥感图像数据集 SIMD 上的相关实验验证了所提方法的有效性。

尽管本文在 SIMD 数据集上取得了较好的结果,但模型的泛化能力可能受限于特定类型的数据集。未来需要进一步验证模型在其他遥感图像数据集上的表现,以确保其鲁棒性和通用性,并将聚焦于无标签数据的检测,将本文算法拓展到更多场景中,提升模型的泛化能力。

参考文献 (References):

- [1] LI K, WAN G, CHENG G, et al. Object detection in optical remote sensing images: a survey and a new benchmark [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 159: 296 – 307.
- [2] ZHAO Z Q, ZHENG P, XU S T, et al. Object detection with deep learning: a review [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3212 – 3232.
- [3] GAO S, LIU H L. RetinaNet-based compact polarization SAR ship detection [J]. IEEE Journal on Miniaturization for Air and Space Systems, 2022, 3(3): 146 – 152.
- [4] MIAO T, ZENG H C, YANG W, et al. An improved lightweight RetinaNet for ship detection in SAR images [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 4667 – 4679.
- [5] REN S Q, HE K M, 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.
- [6] WANG Z P, JIN L Y, WANG S, et al. Apple stem/calyx real-time recognition using YOLO-v5 algorithm for fruit automatic loading system [J]. Postharvest Biology and Technology, 2022, 185: 111808.
- [7] YANG T T, ZHOU S Y, XU A J, et al. YOLO-SegNet: a method for individual street tree segmentation based on the improved YOLOv8 and the SegFormer network [J]. Agriculture, 2024, 14(9): 1620.
- [8] ZHAI S P, SHANG D R, WANG S H, et al. DF-SSD: an im-

- proved SSD object detection algorithm based on DenseNet and feature fusion[J]. IEEE Access, 2020, 8: 24344 – 24357.
- [9] 王梅, 胡晓杰. 基于改进 FCOS 的细长物体检测算法[J]. 沈阳理工大学学报, 2022, 41(4): 8 – 13, 19.
- WANG M, HU X J. Algorithm for slender object detection based on improved FCOS[J]. Journal of Shenyang Ligong University, 2022, 41(4): 8 – 13, 19. (in Chinese)
- [10] KHALILI B, SMYTH A W. SOD-YOLOv8-enhancing YOLOv8 for small object detection in aerial imagery and traffic scenes[J]. Sensors, 2024, 24(19): 6209.
- [11] SHEN L Y, LANG B H, SONG Z X. DS-YOLOv8-based object detection method for remote sensing images[J]. IEEE Access, 2023, 11: 125122 – 125137.
- [12] YI H, LIU B, ZHAO B, et al. Small object detection algorithm based on improved YOLOv8 for remote sensing[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 17: 1734 – 1747.
- [13] YAO G Z, ZHU S D, ZHANG L, et al. HP-YOLOv8: high-precision small object detection algorithm for remote sensing images[J]. Sensors, 2024, 24(15): 4858.
- [14] LI Y L, DING M T, ZHANG Q, et al. Old landslide detection using optical remote sensing images based on improved YOLOv8[J]. Applied Sciences, 2024, 14(3): 1100.
- [15] HUANG M K, LI G Y, LIU Z, et al. Lightweight distortion-aware network for salient object detection in omnidirectional images[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(10): 6191 – 6197.
- [16] GUO Z H, MA D M, LUO X Y. A lightweight semantic segmentation algorithm integrating CA and ECA-Net modules[J]. Optoelectronics Letters, 2024, 20(9): 568 – 576.
- [17] ZHANG S Q, LI C L, JIA Z, et al. Diag-IoU loss for object detection[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(12): 7671 – 7683.
- [18] HAROON M, SHAHZAD M, FRAZ M M. Multisized object detection using spaceborne optical imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 3032 – 3046.
- [19] YU H, WANG J G, HAN Y X, et al. Research on an intelligent identification method for wind turbine blade damage based on CBAM-BiFPN-YOLOV8[J]. Processes, 2024, 12(1): 205.
- [20] ZHAO Y L, JU Z J, SUN T A, et al. TGC-YOLOv5: an enhanced YOLOv5 drone detection model based on transformer, GAM & CA attention mechanism[J]. Drones, 2023, 7(7): 446.

(责任编辑:和晓军)

(上接第43页)

- [13] 隋涛, 孙凡, 冯永新, 等. 一种时间反转的参考信号调制 DCSK 通信方案[J]. 火力与指挥控制, 2024, 49(9): 11 – 17, 24.
- SUI T, SUN F, FENG Y X, et al. A reference signal modulation DCSK communication scheme for time reversal[J]. Fire Control and Command Control, 2024, 49(9): 11 – 17, 24. (in Chinese)
- [14] ZHANG G, HE P, HE L F. Multi-carrier multi-level DCSK communication system based on time-reversal[J]. Annals of

Telecommunications, 2023, 78(3): 235 – 247.

- [15] TAO Y W, FANG Y, MA H, et al. Multi-carrier DCSK with hybrid index modulation: a new perspective on frequency-index-aided chaotic communication[J]. IEEE Transactions on Communications, 2022, 70(6): 3760 – 3773.
- [16] DAI W H, YANG H, SONG Y R, et al. Two-layer carrier index modulation scheme based on differential chaos shift keying[J]. IEEE Access, 2018, 6: 56433 – 56444.

(责任编辑:和晓军)

(上接第51页)

- [16] 刘再兴, 王海刚. 同心圆环区域电容层析成像传感器数目优化[J]. 仪器仪表学报, 2021, 42(10): 94 – 104.
- LIU Z X, WANG H G. Optimization of the number of electrical capacitance tomography sensors with concentric annulus structure[J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 94 – 104. (in Chinese)
- [17] HOR X F, ALI M S M, GOOI W P. Electrode configuration study for three-dimensional imaging of on-chip ECT[J]. Engineering Research Express, 2023, 5(2): 025003.
- [18] 姚佳烽, 车权齐, 李志伟, 等. 电容层析成像技术研究进展[J]. 机械制造与自动化, 2022, 51(5): 1 – 7, 25.
- YAO J F, CHE Q Q, LI Z W, et al. Research progress of electrical capacitance tomography[J]. Machine Building & Automation, 2022, 51(5): 1 – 7, 25. (in Chinese)
- [19] 张立峰, 戴力. 基于鲁棒正则化极限学习机的电容层析成像图像重建[J]. 计量学报, 2022, 43(8): 1044 – 1049.
- ZHANG L F, DAI L. Image reconstruction based on robust regularized extreme learning machine for electrical capacitance tomography[J]. Acta Metrologica Sinica, 2022, 43(8): 1044 – 1049. (in Chinese)
- [20] 张晋荣, 王莉莉, 杨博韬, 等. 电容层析成像系统传感器场

域剖分及参数优化[J]. 哈尔滨理工大学学报, 2021, 26(2): 59 – 67.

- ZHANG J R, WANG L L, YANG B T, et al. Sensor field segmentation and parameter optimization for electrical capacitance tomography system[J]. Journal of Harbin University of Science and Technology, 2021, 26(2): 59 – 67. (in Chinese)
- [21] 李照威, 孙启国. 油气润滑 ECT 系统灵敏度矩阵的秩亏问题及其影响因素[J]. 内蒙古科技与经济, 2021(8): 97 – 99.
- LI Z W, SUN Q G. Rank deficiency of sensitivity matrix of oil-gas lubrication ECT system and its influencing factors[J]. Inner Mongolia Science Technology & Economy, 2021(8): 97 – 99. (in Chinese)
- [22] HUANG G X, LI C, WANG J W, et al. ECT image reconstruction based on sensitive field expansion and optimization[J]. Measurement Science and Technology, 2024, 35(6): 065402.
- [23] RASEL R K, ZUCCARELLI C E, MARASHDEH Q M, et al. Toward multiphase flow decomposition based on electrical capacitance tomography sensors[J]. IEEE Sensors Journal, 2017, 17(24): 8027 – 8036.

(责任编辑:和晓军)