光电技术及应用

DOI：10.16818/j.issn1001－5868.2022110201

基于 YOLACT 与 Transformer 相结合的实例分割算法研究

赵敬伟[1,2]，林珊玲[2,3]，梅　婷[1,2]，林志贤[1,2,3*]，郭太良[1,2]

（1. 福州大学 物理与信息工程学院，福州 350116；2. 中国福建光电信息科学与技术创新实验室，福州 350116；3. 福州大学 先进制造学院，福建 泉州 362200）

摘　要： 为提高单阶段实例分割的检测精度和改善小目标漏检、错检情况，提出一种基于 YOLACT 改进的 YOLACTR 算法。该算法首先利用 CNN 与 Transformer 相结合，设计一种新的头部预测网络，对特征进一步提取，并使用双向注意力来关联同一实例的掩码信息并区分不同实例之间的掩码特征，注重特征点周围的关联信息，使得检测框的预测更加准确；然后利用多级上采样和设计的 CS 注意力模块结合形成掩码分支，使其融入多种不同尺度信息，并利用 CS 注意力来关注不同的尺度信息。在 MS COCO 数据上，YOLACTR 算法与 YOLACT 算法相比，其边框和掩码检测精度分别提升了 7.4％和 2.9％，在小目标检测上分别提升了 18.9％和 13.5％。实验表明，YOLACTR 算法可以在多目标复杂场景下，提升检测和分割精度以及分类的准确度，改善小目标和重叠目标漏检、错检的问题。

关键词： YOLACT；实例分割；Transformer；注意力机制；小目标检测

中图分类号： TP391.4　**文章编号：** 1001－5868(2023)01－0134－07

Research on Instance Segmentation Algorithm Based on YOLACT and Transformer

ZHAO Jingwei[1,2], LIN Shanling[2,3], MEI Ting[1,2], LIN Zhixian[1,2,3], GUO Tailiang[1,2]

(1. College of Physics and Information Engineering, Fuzhou University, Fuzhou 350116, CHN;
2. Fujian Science & Technology Innovation Laboratory for Optoelectronic Information of China, Fuzhou 350116, CHN;
3. School of Advanced Manufacturing, Fuzhou University, Quanzhou 362200, CHN)

Abstract: In order to improve the segmentation accuracy of single stage instance segmentation and improve the situation of missed and wrong detection of small targets, an improved YOLACTR algorithm is proposed based on YOLACT algorithm. The algorithm first used the combination of CNN and Transformer to design a new head prediction network to further extract features, and used two-way attention to correlate the mask information of the same instance and distinguish the mask features between different instances. It paid attention to the correlation information around the feature points, making the prediction of the detection box more accurate. Then the mask branch was formed by the combination of multi-level up sampling module and the designed CS attention module, which integrated a variety of different scale information. Then the CS attention module was used to pay attention to different scale information. On the MS COCO data, compared with YOLACT algorithm, YOLACTR algorithm improves the detection accuracy of box and mask by 7.4％ and 2.9％ respectively, and improves the detection accuracy of small targets by 18.9％ and 13.5％ respectively. Experiments

收稿日期：2022－11－02.

基金项目：国家重点研发计划项目(2021YFB3600603)；福建省自然科学基金项目(2020J01468).

* **通信作者：**林志贤　**E-mail：**lzx2005000@163.com

results show that YOLACTR algorithm can improve the accuracy of detection, segmentation and classification in multi-target complex scenes, which improves the problem of missed and wrong detection of small targets and overlapping targets.

Key words: YOLACT; instance segmentation; Transformer; attention mechanism; small target detection

0 引言

近年来，随着深度学习的快速发展、计算机算力显著增强、存储扩大以及高质量图像数据集的出现，计算机视觉和图像处理领域进入了新的技术时代。实例分割是一项在计算机领域中具有挑战性的任务，它需要正确检测图像中所有的实例，并在像素级对每个实例进行标记。即不仅需要对不同类别的目标进行像素级别的分割，还需要对同一类别的不同实例进行区分[1-3]。因此实例分割可以看做是语义分割[4-5]和目标检测[6-7]相互结合的产物，其技术在自动驾驶、医疗影像、智慧农业等方面得到广泛应用[8]。

实例分割算法从处理过程可以归纳为两阶段检测算法和单阶段检测算法两大类。

两阶段检测实例分割是按照处理阶段划分，其方案主要是基于候选区域网络进行，先检测出图像中的实例所在区域，再对候选区域进行像素级实例分割。Mask R-CNN[9]是经典的两阶段检测算法，该算法是在 Faster R-CNN[10]的基础上，在目标分类和边界框回归分支上添加了一个并行的掩码分支来预测分割结果。通常多尺度特征通过在区域候选网络(Region Proposal Network，RPN)[10]获得感兴趣区域(Region of Interest，ROI)，然后对 ROI 进行池化和对齐操作(ROI Align[9])，最后送入后续网络获得类别和实例掩码。继 Mask R-CNN 之后，PANet[11]在 Mask R-CNN 的基础上，对 FPN 进行改进，引入了一条自下而上的融合路径，采用自适应融合的 ROI 区域特征池化，融合不同层次的特征信息。Mask Scroing R-CNN[12]在 Mask R-CNN 的基础上添加一个掩码评价标准，通过计算预测掩码和真实掩码的交并比 IoU 来提高实例分割性能。BMask R-CNN[13]则在 Mask R-CNN 中添加目标的边缘信息来增强掩码预测，RefineMask[14]是利用语义信息和边缘信息来改进掩码的边缘线条。

两阶段检测的方案避免了图像其他区域的干扰，提高了算法的准确性，但是严重依赖目标检测的精确性，由于其经过了两个阶段的处理，对于多实例的复杂场景，前期需要生成大量的建议区域，很大程度增加了算法的复杂度，制约了模型计算速度，因此往往无法达到实时性的要求。

单阶段检测算法不再采用候选区域的操作，而是直接利用全卷积网络进行一次目标检测来区分不同的实例。YOLACT[15]算法以单阶段检测为基础，结合原型掩码(Prototype Masks)和掩码系数首次实现了实时实例分割。因其取消了 RPN 网络结构，利用全卷积网络对共享特征进行卷积操作，降低了模型复杂度，提高了实例分割的效率。但是由于直接使用全卷积网络对全图进行卷积而生成分割结果，目标检测过程中失去了较多的细节，导致分割精度相较两阶段检测网络有所下降。CondInst[16]实现了更快的速度，同时也保证了一定的精度，它去掉了检测器的辅助，通过动态卷积的思想生成实例敏感的滤波器来编码实例信息，不依赖检测框和 ROI Pooling 等特征对齐操作，用 FCOS[17]检测实例类别，然后用参数动态生成的 mask head 在原型掩码和相对坐标图结合图上卷积生成实例掩码。SOLO[18]将输入图像划分为不同层次的网格，并赋予位置信息，根据实例的位置和大小为实例中的每个网格分配类别，从而将实例分割转化为一个单次分类问题。Point INS[19]，CenterMask[20]从点特征出发来进行实例分割获得全局掩码。BlendMask[21]通过设计合理的 blender 模块融合高低层语义信息来获得更准确的实例分割结果。目前，单阶段实例分割算法依然存在着不足，在结构形式、检测精度和检测速度等方面还需要进一步提升。

近几年，因 Transformer[22]框架在自然语言处理(NLP)领域取得了突破性进展，研究者们尝试将 Transformer 应用到计算机视觉领域且取得了较好的效果。Image Transformer[23]模型是首次将 Transformer 应用于图像生成。DETR[24]将 CNN 与 Transformer 进行结合，提出一个完备的端到端目标检测框架，这是首次将 Transformer 应用到目标检测中。ISTR[25]通过预测低维掩码嵌入，并与

真实掩码嵌入进行匹配来获得损失，同时使用循环细化策略进行检测和分割。与 CNN 相比，Transformer 框架具有较强的语义特征提取和长距离特征捕获能力，其并行计算能力和 CNN 相当，因此视觉 Transformer 在实例分割这个领域具有很强的竞争力[26]。

为了提高单阶段实例分割的检测精度和小目标检测精度，本文设计一种改进的 YOLACT 算法，本文称为 YOLACTR 算法，主要包括：(1)利用 CNN 与 Transformer 相结合，设计一种新的头部预测网络，对特征进行提取，并使用双向注意力关联实例周围信息以作区分，能够有效提取低层特征信息并捕获更长范围的上下文依赖，得到更准确的掩码系数、边框位置和类别信息；(2)利用 CS 注意力模块来聚合不同尺度特征信息形成掩码分支，通过关注不同尺度不同位置的实例信息，增强小目标物体的细节特征，区分复杂背景信息，得到更准确的高质量原型掩码。

1 YOLACT 检测算法

YOLACT 网络结构如图 1 所示，主要包含两个分支：原型掩码分支(Protonet)和预测分支。YOLACT 为每张图片生成 k 个原型掩码和 k 个掩码系数，每个掩码系数和原型掩码一一对应，通过将掩码系数和原型掩码进行线性组合，然后通过 sigmoid 非线性函数来生成最终的 masks。YOLACT 算法在检测速度上具有很好的表现，但是在复杂场景下检测和小目标检测的效果不理想。

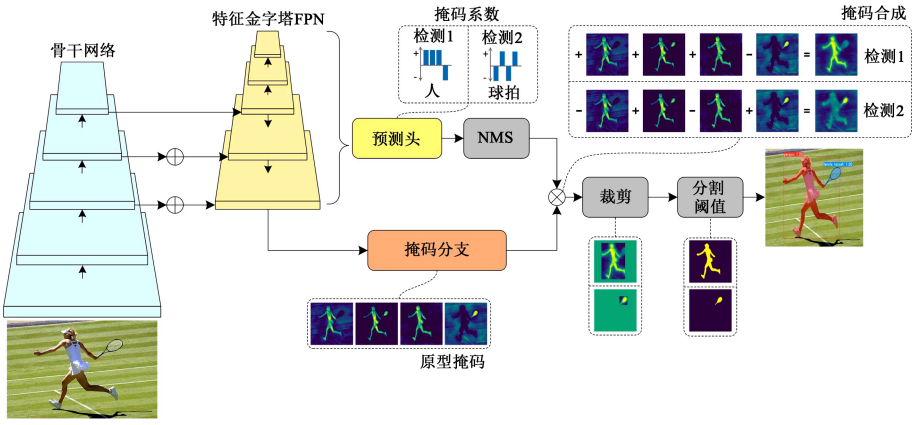


图 1 YOLACT 网络结构

2 本文提出的改进算法

YOLACTR 是一种基于 YOLACT 算法的 CNN 和 Transformer 融合的实例分割模型。YOLACTR 模型框架如图 2 所示。输入图像经过骨干网络 Resnet[27]和特征金字塔 FPN 获得多尺度特征，接着将实例分割的复杂任务分解成两个并行任务，这些并行分支最终通过极大值抑制、线性组合来获得最终的分割结果。

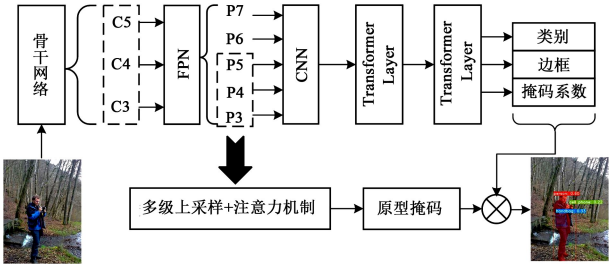


图 2 YOLACTR 模型框架

2.1 预测分支网络结构

预测头网络结构如图 3 所示，由三部分结构组成，分别为 CNN、Transformer 和 3 个并行功能头。来自 FPN 模块的特征图，经过三次重复的 3×3 Conv，Group Norm[28]和 Relu 激活处理后，特征图依次经过两次 Transformer layer 处理。处理后得到的特征图被输入到 3 个不同功能的功能头以进行

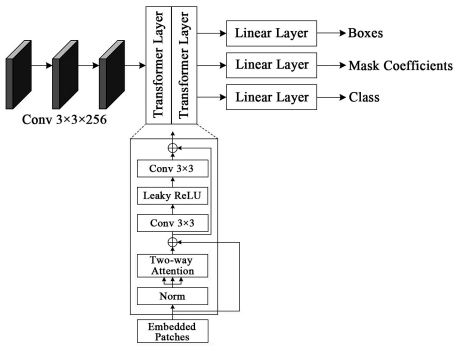


图 3 预测分支网络结构

后续预测，每个功能头均由线性层组成，分别对应类别预测、anchor 预测和掩码系数预测。

其中 Transformer Layer，为了在计算成本和特征提取效果之间进行最佳权衡，在遵循原始 NLP 基本结构设计的情况下，使用双向注意力方式来代替多头注意力，并使用 3×3 卷积替代后续操作，以更好的捕捉局部信息并增强特征表示。其中，双向注意力方式是将感受野限制为固定步幅的方块形式。它首先计算每列中的注意力，同时保持不同列中的元素独立。该策略可以在水平尺度上聚合元素之间的上下文信息。然后，在每一行中进行类似的关注，以在垂直尺度上充分利用其特性进行交互。两个方向上的注意力依次连接成一个具有全局感受野并覆盖两个维度信息的多尺度注意力特征图。

与 YOLACT 相比，该结构增加了网络的深度，更加注重特征点周围的关联信息，这使得 anchor 的预测更加准确，提高了检测的质量，同时利用 CNN 来平衡模型推理速度，使得模型在一定程度上兼顾效率和精度。

2.2　掩码分支网络结构

掩码头网络结构如图 4 所示，由多级上采样和 CS 注意力模块（Channel and Spatial Attention Module）组成。将 FPN 得到的 P3～P6 相结合为统一尺寸的特征图，对于每个尺度的特征图而言，经过 3×3 Conv，Group norm 和 Relu 几个阶段，然后对 P4～P6 进行双线性上采样 $2x$，$4x$，$6x$，分别达到 $(H/8,W/8)$ 的分辨率。将处理的 P3～P6 相加到一起，进行逐点卷积和上采样，以得到最终统一的 $H/4\times W/4$ 特征图，最后通过具有 k 个通道的卷积层，对该特征图获取和掩码数量相应的原型掩码。其中，对 P4～P6 第一次进行上采样后的特征图以及最后一次进行上采样得到的特征图，分别接入 CS 注意力模块，以对各个尺度的不同实例进行关注，根据所需丰富特征图中不同实例的差异信息，从而获得高质量的原型掩码。

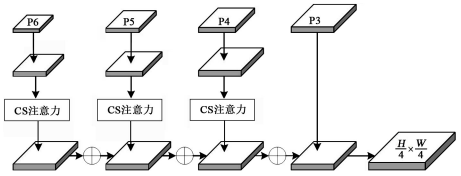


图 4　掩码分支网络结构

其中 CS 注意力模块如图 5 所示，由关注通道和关注空间两个分支组成。图像右半部分为通道注意力，首先对不同尺度的特征层分别进行全局平均池化和全局最大池化，之后对两种池化结果，利用共享的 1×1Conv，Relu，1×1Conv 进行处理。然后对两个处理的结果进行加和，利用 sigmoid 函数，将每个特征层的每个通道的权值设置在 0～1。图像的左半部分为空间注意力，首先对不同尺度的特征层的每一个特征点的所有通道上获得其平均值和最大值，之后将两个结果进行堆叠，利用通道数为 1 的 3×3 Conv 进行处理，然后使用 sigmoid 函数将每个特征层的每一个特征点的权值设置在 0～1。之后将两个权值进行加和，并与相对应的输入特征层相乘和相加即可。

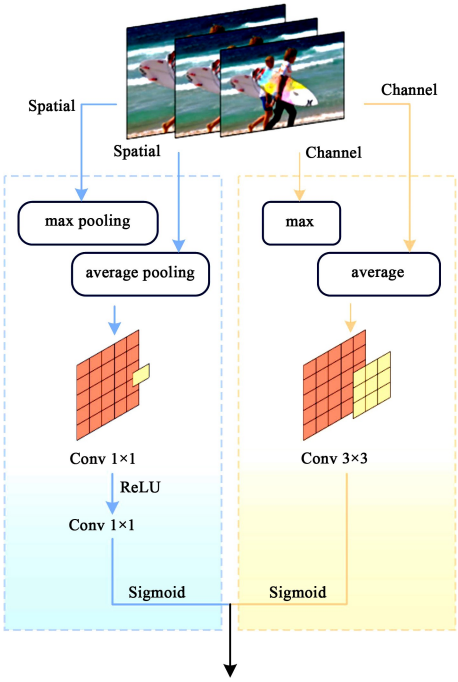


图 5　CS 注意力模块

与 YOLACT 相比，相对于只采用 P3 特征层作为原型掩码的输入，该结构融入了多尺度的特征信息，丰富了不同实例大小的差异化信息，同时利用 CS 注意力机制更好的关注不同尺度信息，获得更高效精确地原型掩码。

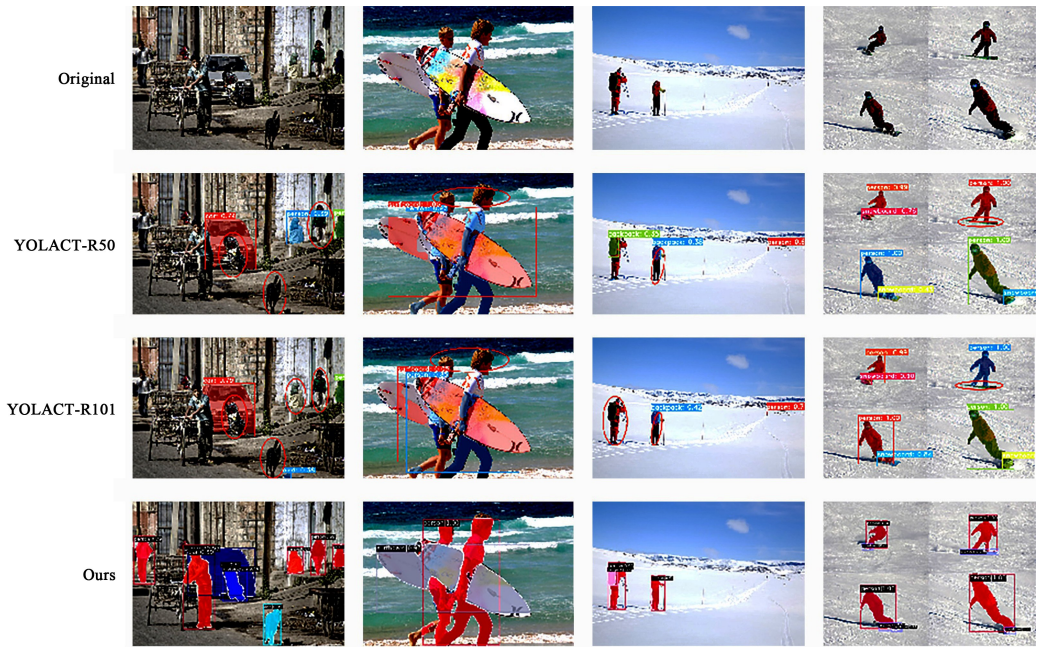
3　实验结果和分析

3.1　实验平台和检测结果

本实验在 Pytorch 平台进行，操作系统为 Linux（Ubuntu 20.04.3 LTS），内存为 128 G，显卡使用 NVIDIA GeForce RTX 3090 24G x2。数据集使用微软发布的公开数据集 COCO，该数据集以场景理解为目标，是一个大规模的目标检测、实例分割

和字幕数据集。数据集、验证数据集分别达到了118和5 k，拥有80个对象类别标注，涵盖了日常生活中的大部分场景。采用SGD优化器训练模型，将初始学习率设置为0.002，恒定预热500次迭代，使用的权重衰减和0.9的动量。分别在20，42，49，52 epoch处降低10倍学习率，共训练55 epochs，批量大小为16。

检测结果如图6所示，其中第一行为随机抽取的不同场景下的测试图像，图6(a)为自然场景下的多目标检测和分割结果，在多目标的复杂场景中，受背景和色调影响，YOLACT模型存在较大程度的漏检情况，相较而言YOLACTR模型可以很好区分和分割出主要实例；图6(b)为重叠遮挡情况下的目标检测和分割结果，可以看出，在大面积遮挡时，YOLACT模型没有很好地区分和分割实例，造成部分实例分割错误，而YOLACTR模型对遮挡情况有很好的表现，分割区域和类别相对准确，区分人和冲浪板较好；图6(c)为小目标检测和分割结果，可以看出，对于较小目标检测场景，YOLACT模型没有识别出来部分实例和内容(如图像中背着包的人)，而YOLACTR模型能够比较准确地分割和区分不同实例；图6(d)为不同尺寸的目标检测和分割结果，可以看出，在不同尺寸实例的检测和分割下，YOLACT模型对于一些细节内容没有识别出来(如人物脚下的滑板等)，而YOLACTR模型相对来说可以更好识别出更小的目标和更多的信息。总的来说，本文算法在各个场景下的检测效果都能很好地检测和分割出目标区域。



(a) 自然场景 (b) 重叠遮挡 (c) 小目标检测 (d) 不同尺寸目标检测

图6 不同场景下的检测结果

3.2 数据对比

为了验证本文算法的有效性，此部分将本文算法与采用不同深度的YOLACT算法进行比较。表1给出了不同算法的检测时间和检测精度，表2给出了对于不同尺度目标的检测精度。

表中的检测时间是在同一设备条件下进行测量，选取2 000张图片进行测试，取最后的平均检测时间作为检测结果(由于设备和平台有所差异，YOLACT模型的检测时间与官方数据有所出入)；表中的检测精度是在COCO数据中的5 000张验证集上进行测试得到的结果。

表1 网络模型参数量、时间和精度检测

网络模型	特征提取网络	参数量/M	Box mAP/%	Mask mAP/%
YOLACT	R50-FPN	31.16	30.2	28.0
YOLACT	R101-FPN	50.15	32.5	29.8
YOLACTR	R50-FPN	37.25	32.6	28.8

由表1数据可知，YOLACTR的Box检测精度为32.6%，Mask检测精度为28.8%，YOLACT-R50的Box检测精度为30.2%，Mask检测精度为28%(取用官方模型进行测试)，YOLACTR模型的检测精度相比YOLACT-R50模型分别提升了7.4%和2.9%，其中YOLACT-R101模型的Box检测精度为32.5%，YOLACTR模型的Box检测

精度甚至与采用更深网络结构的 YOLACT-R101 模型的检测精度相持平。可见，CNN 与 Transformer 相融合的检测头，以及多尺度的掩码方式提供了更为丰富的差异化信息，增强了不同像素之间关联，扩大了不同实例间的差异化，进而生成更准确的边界框和掩码。

YOLACT 算法在处理小目标物体以及重叠物体上，其结果相对较差，由表 2 可知，相较于 YOLACT-R50 算法，YOLACTR 算法在小物体检测上，其 Box 检测精度提高了 18.9%，Mask 检测精度提高了 13.5%，在中等物体检测上，Box 检测精度提高了 9.7%，其他检测精度与 YOLACT-R50 相近。其中对小物体的检测提升最为明显，不过到目前为止，小目标检测依然是实例分割领域中一项具有挑战性的任务。

表 2　不同大小的实例分割精度检测

网络模型	Box mAP/%			Mask mAP/%		
	Small	Medium	Big	Small	Medium	Big
YOLACT-R50	14.3	32.0	44.8	8.9	30.2	47
YOLACT-R101	15.3	35.0	47.9	10.1	32.3	50.2
YOLACTR	17.0	35.1	45.6	10.1	30.4	46.8

实验结果表明，YOLACTR 模型对于 YOLACT 模型，在多目标复杂场景、重叠场景、小目标场景等多个场景下，能够很好的完成多场景下的目标检测和分割，改善了小目标错检、漏检的问题，并提高检测精度和检测细节。

4　结论

本文提出一种基于 YOLACT 与 Transformer 相结合的实例分割算法。该算法利用 CNN 与 Transformer 相结合，设计一种新的头部预测网络，通过双向注意力关联同一实例的掩码信息并区分不同实例之间的掩码特征，使得检测范围和小目标检测更加准确；同时利用 CS 注意力模块关注不同尺度的可用信息，聚合关键信息来增加特征细节，获得更高质量的原型掩码。从实验对比表明，本文算法可以在多目标复杂场景下实现更好的检测，能够有效地检测并分割出小目标。

参考文献：

[1] 苏　丽，孙雨鑫，苑守正. 基于深度学习的实例分割研究综述[J]. 智能系统学报，2021，17(1)：16-31.
Su Li，Sun Yuxin，Yuan Shouzheng. A survey of case segmentation based on deep learning[J]. J. of Intelligent Systems，2021，17(1)：16-31.

[2] 张继凯，赵　君，张　然. 深度学习的图像实例分割方法综述[J]. 小型微型计算机系统，2021，42(1)：161-171.
Zhang Jikai，Zhao Jun，Zhang Ran. A survey of image instance segmentation methods based on depth learning[J]. Small Microcomputer System，2021，42(1)：161-171.

[3] Minaee S，Boykov Y Y，Porikli F，et al. Image segmentation using deep learning：A survey[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence，2022，44(7)：3523-3542.

[4] 梁新宇，罗　晨，权冀川，等. 基于深度学习的图像语义分割技术研究进展[J]. 计算机工程与应用，2020，56(2)：18-28.
Liang Xinyu，Luo Chen，Quan Jichuan，et al. Research progress of image semantic segmentation based on depth learning[J]. Computer Engineering and Applications，2020，56(2)：18-28.

[5] 田　萱，王　亮，丁　琪. 基于深度学习的图像语义分割方法综述[J]. 软件学报，2019，30(2)：440-468.
Tian Xuan，Wang Liang，Ding Qi. A survey of image semantic segmentation methods based on depth learning[J]. J. of Software，2019，30(2)：440-468.

[6] 陆　峰，刘华海，黄长缨，等. 基于深度学习的目标检测技术综述[J]. 计算机系统应用，2021，30(3)：1-13.
Lu Feng，Liu Huahai，Huang Changying，et al. A survey of target detection techniques based on deep learning[J]. Computer Systems Applications，2021，30(3)：1-13.

[7] 姚　铭，邓红卫，付文丽，等. 一种改进的 Mask R-CNN 的图像实例分割算法[J]. 软件，2021，42(9)：78-82.
Yao Ming，Deng Hongwei，Fu Wenli，et al. An improved Mask R-CNN image instance segmentation algorithm[J]. Software，2021，42(9)：78-82.

[8] 陈　加，陈亚松，李伟浩，等. 深度学习在视频对象分割中的应用与展望[J]. 计算机学报，2021，44(3)：609-631.
Chen Jia，Chen Yasong，Li Weihao，et al. Application and prospect of deep learning in video object segmentation[J]. J. of Computer Science，2021，44(3)：609-631.

[9] He K，Gkioxari G，Dollár P，et al. Mask R-CNN[C]// Proc. of the IEEE Inter. Conf. on Computer Vision，2017：2961-2969.

[10] Ren S，He K，Girshick R，et al. Faster R-CNN：Towards real-time object detection with region proposal networks[J]. IEEE Trans. on Pattern Analysis & Machine Intelligence，2017，39(6)：1137-1149.

[11] Liu S，Qi L，Qin H，et al. Path aggregation network for instance segmentation[C]// Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition，2018：8759-8768.

[12] Huang Z，Huang L，Gong Y，et al. Mask scoring R-CNN[C]// Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition，2019：6409-6418.

[13] Cheng T，Wang X，Huang L，et al. Boundary-preserving mask R-CNN[C]// European Conf. on Computer Vision. Springer，Cham，2020：660-676.

[14] Zhang G，Lu X，Tan J，et al. Refinemask：Towards high-

quality instance segmentation with fine-grained features[C]// Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition, 2021: 6861-6869.

[15] Bolya D, Zhou C, Xiao F, et al. Yolact: Real-time instance segmentation[C]// Proc. of the IEEE/CVF Inter. Conf. on Computer Vision, 2019: 9157-9166.

[16] Tian Z, Shen C, Chen H. Conditional convolutions for instance segmentation[C]// European Conf. on Computer Vision. Springer, Cham, 2020: 282-298.

[17] Tian Z, Shen C, Chen H, et al. Fcos: Fully convolutional one-stage object detection[C]// Proc. of the IEEE/CVF Inter. Conf. on Computer Vision, 2019: 9627-9636.

[18] Wang X, Kong T, Shen C, et al. Solo: Segmenting objects by locations[C]// European Conf. on Computer Vision. Springer, Cham, 2020: 649-665.

[19] Qi L, Wang Y, Chen Y, et al. Pointins: Point-based instance segmentation[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2021, 44(10): 6377-6392.

[20] Wang Y, Xu Z, Shen H, et al. Centermask: single shot instance segmentation with point representation[C]// Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition, 2020: 9313-9321.

[21] Chen H, Sun K, Tian Z, et al. Blendmask: Top-down meets bottom-up for instance segmentation[C]// Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition, 2020: 8573-8581.

[22] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J]. Adv. in Neural Information Processing Systems, 2017, 30: 6000-6010.

[23] Parmar N, Vaswani A, Uszkoreit J, et al. Image transformer[C]// Inter. Conf. on Machine Learning, PMLR, 2018: 4055-4064.

[24] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers[C]// European Conf. on Computer Vision. Springer, Cham, 2020: 213-229.

[25] Hu J, Cao L, Lu Y, et al. ISTR: End-to-end instance segmentation with transformers[DB/OL]. 2021-5-6.

[26] 尹 航, 范文婷. 基于 Transformer 目标检测研究综述[J]. 现代信息科技, 2021, 5(7): 14-17.
Yin Hang, Fan Wenting. Review of Transformer-based target detection[J]. Modern Information Technology, 2021, 5(7): 14-17.

[27] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]// Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition, 2016: 770-778. http://www.xueshufan.com/publication/3159833358.

[28] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]// Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition, 2017: 2117-2125.

作者简介:

赵敬伟(1996—),男,硕士研究生,研究方向为图像处理、计算机视觉和光电显示技术;

林志贤(1975—),男,博士,教授,博士生导师,从事新型显示技术、印刷电子显示、平板显示器驱动系统、三维立体显示技术,以及图像处理技术等方面的研究。