doi:10.6041/j.issn.1000-1298.2025.09.055

基于 CEG－YOLO 的轻量化设施环境樱桃花检测方法

任龙龙[1,2]　杜永辉[1]　李玉强[1]　高　昂[1]　宋月鹏[1,2]

（1.山东农业大学机械与电子工程学院，泰安 271018；2.山东省设施园艺智慧生产技术装备重点实验室，泰安 271018）

摘要：为实现设施环境中樱桃花目标的准确检测，本文在 YOLO v8 的基础上，提出一种适用于设施环境樱桃花目标检测模型 CEG－YOLO。引入跨阶段部分网络与部分卷积结合（Integration of cross-stage partial networks and partial convolution，CSPPC）结构，替换 Backbone 和 Neck 网络中的 C2f 模块，以增强网络的特征提取能力，同时显著降低了模型的浮点运算量和参数量；在 SPPF 模块前添加轻量化的高效通道注意力（Efficient channel attention，ECA），进一步增强网络的特征提取能力，提高模型的检测精度；将 Neck 中的 Conv 模块替换为 GSConv（Grouped spatial convolution）模块，进一步降低模型的参数量和浮点运算量。结果显示，CEG－YOLO 模型的精确率为 89.8%、召回率为 91.3%、mAP 为 94.8%、参数量为 2.03×10^6、浮点运算量为 5.8×10^9。与原始 YOLO v8 模型相比，该模型的精确率、召回率和 mAP 分别提高 1.6、1.9、1.8 个百分点，参数量和浮点运算量分别减少 32.56% 和 28.40%。与 YOLO v3、YOLO v5、YOLO v7、YOLO v9、YOLO v10 和 YOLO 11 模型相比，CEG－YOLO 模型 mAP 分别提高 7.7、0.7、1.8、2.1、3.1、1.7 个百分点，参数量分别减少 76.59%、71.53%、32.56%、55.09%、24.81% 和 21.31%，浮点运算量分别减少 55.04%、45.28%、28.40%、32.56%、29.27% 和 7.9%。因此，本文提出的 CEG－YOLO 模型不仅能够准确地检测设施环境中的樱桃花，还具有较低的计算成本，适合部署在樱桃授粉机器人的嵌入式设备上，为设施樱桃的智能授粉提供可行的视觉支持。

关键词：设施樱桃授粉；樱桃花；深度学习；目标检测；高效通道注意力机制；YOLO v8

中图分类号：TP391　　**文献标识码**：A　　**文章编号**：1000-1298(2025)09-0648-09　　**OSID**：

Lightweight Cherry Blossom Detection Method in Facility Environments Based on CEG－YOLO

REN Longlong[1,2]　DU Yonghui[1]　LI Yuqiang[1]　GAO Ang[1]　SONG Yuepeng[1,2]

（1. *College of Mechanical and Electronic Engineering*, *Shandong Agricultural University*, *Taian* 271018, *China*

2. *Shandong Key Laboratory of Intelligent Production Technology and Equipment for Facility Horticulture*, *Taian* 271018, *China*）

Abstract: In order to achieve accurate detection of cherry blossom targets in the facility environment, a model CEG－YOLO for cherry blossom target detection in the facility environment based on YOLO v8 was proposed. Firstly, the structure of integration of cross-stage partial networks and partial convolution (CSPPC) structure was introduced to replace the C2f module in the Backbone and Neck networks to enhance the feature extraction capability of the network, and at the same time, the computational and parametric quantities of the model were reduced significantly. Secondly, a lightweight efficient channel attention (ECA) was added before the SPPF module, which enabled the network to further enhance the characteristics extraction and improve the detection accuracy of the model. Finally, the Conv module in Neck was replaced with the grouped spatial convolution (GSConv) module, which made the number of parameters and computation of the model further reduce. The experimental results showed that the accuracy of the CEG－YOLO model was 89.8%, the recall was 91.3%, the mAP was 94.8%, the number of parameters was 2.03×10^6, and the computational cost was 5.8×10^9. Compared with the original YOLO v8 model, the accuracy, recall, and mAP of the model was improved by 1.6, 1.9, and 1.8 percentage points, respectively, and the number of parameters and computational were decreased by 32.56% and 28.40%. Compared with the YOLO v3, YOLO v5, YOLO v7, YOLO v9, YOLO v10, and YOLO 11 models, the mAP of the CEG－YOLO model was increased by 7.7, 0.7, 1.8, 2.1, 3.1, and

收稿日期：2025－03－17　修回日期：2025－05－26

基金项目：山东省重点研发计划项目（2024TZXD045）和山东省现代果品产业技术体系项目（SDAIT－06－12）

作者简介：任龙龙（1987—），男，讲师，博士后，主要从事图像处理与深度学习算法研究，E-mail：renlonglong@sdau.edu.cn

通信作者：宋月鹏（1971—），男，教授，博士生导师，主要从事果园管理及产后处理生产技术与装备研究，E-mail：uptonsong@sdau.edu.cn

1.7 percentage points, and the number of parameters and computation was reduced significantly. The CEG－YOLO model proposed was not only able to accurately detect cherry blossoms in facility environments, but also possessed low computational overheads, which was suitable for deployment on the embedded devices of cherry pollination robots, which provided feasible visual support for realizing intelligent pollination of facility cherries.

Key words: facility cheery pollination; cherry blossom; deep learning; target detection; efficient channel attention mechanism; YOLO v8

0　引言

樱桃是一种温带落叶果树，隶属于蔷薇科李属[1]。大多数樱桃品种具有自交不亲和性，依赖异花授粉[2]，因此其产量易受自然条件和授粉效率影响。特别是在设施樱桃种植中，授粉问题尤为突出。尽管蜜蜂授粉可行，但由于设施环境的限制，蜜蜂活动受限，授粉效率较低，同时维持蜜蜂种群的成本较高。人工授粉虽不受环境影响，但其劳动强度大、效率低，且难以满足大规模种植的需求。为解决上述问题，智能农业技术的应用为设施樱桃种植提供了创新性解决方案——智能化机械授粉。机械授粉通过精确控制授粉过程，不仅能够实现高效、均匀授粉，大幅提升授粉效率和质量，还减少了对外部环境和蜜蜂活动的依赖。在恶劣环境下，机械授粉仍能稳定运行，确保授粉任务的顺利完成，为设施樱桃的高产和优质提供了可靠的技术支持。而樱桃花的精准检测是智能化机械授粉的关键技术之一，能够进一步提升授粉作业的效率和效果，从而推动设施樱桃种植的智能化和现代化发展。

近年来，随着机器视觉技术的飞速发展，国内外学者在花卉检测领域利用机器学习和图像处理技术，实现了对多种花卉的准确检测，例如草莓花[3]、黄瓜花[4]、黄菊花[5]、猕猴桃花[6]、梨花[7]、荔枝花[8]、油茶花[9]、苹果花[10]。这些研究为精准农业和智能农业机器人应用提供了有力支持，推动了花卉检测技术的发展。

本文的设施樱桃为纺锤形矮化密植种植模式。目前针对樱桃花的检测研究相对较少，其他花卉的检测技术虽取得了显著进展，尚无法直接应用于本文所研究的设施樱桃种植的实际需求，为此，本文提出一种基于 CEG－YOLO 的樱桃花检测方法，旨在实现对樱桃花的精确识别，以期为后续的设施樱桃智能化机械授粉提供可靠的视觉检测支持。

1　材料与方法

1.1　数据来源

数据集采自山东省烟台市栖霞市北方果蔬果品苗木基地（121.19°N，37.18°E）。数据采集时间为 2024 年 2 月 29 日，拍摄距离为 30～50 cm，拍摄设备为荣耀 90 Pro 型智能手机，图像格式为 JPG。经过对原始图像筛选，获得符合试验要求的图像 1 074 幅，并将所有图像像素统一调整为 640 像素×640 像素。

在模型训练之前，采用 LabelImg 标注工具对数据集中的图像进行人工标注。标注结果如图 1 所示，图像标注了两个类别：花蕊标注为“stamen”，樱桃花标注为“flower”。此类别的选择是为后续将模型应用到授粉机器人时，能够精确定位樱桃花的不同部分，从而实现对樱桃花的精准识别和授粉。标注完成后，对 1 074 幅樱桃花图像进行数据增强处理，使用添加噪声、调整亮度、剪裁、旋转、平移和翻转 6 种数据增强方式，随机选择其中的 1～3 种方式进行组合，对每幅原始图像进行 5 次扩充，最终获得 6 444 幅图像，并将其按比例 7∶2∶1 分为训练集、验证集、测试集。训练集图像 4 512 幅，验证集图像 1 290 幅，测试集图像 642 幅。扩充后数据集图像示例如图 2 所示。

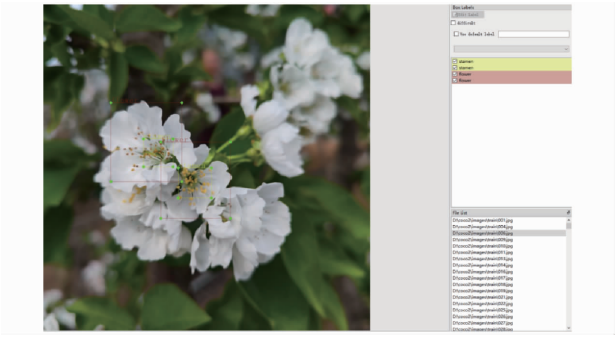


图 1　樱桃花数据集标注

Fig. 1　Cherry blossom dataset labelling

1.2　CEG－YOLO 模型

在农业检测领域，YOLO v8 模型结构成熟，能够在精度、速度和资源消耗之间实现良好平衡，特别适用于对实时性和资源消耗要求严格的机器人授粉应用。其经过优化的结构可在较低计算资源下实现高效检测，更加契合机器人平台的硬件条件。相较之下，YOLO v9 浮点运算量较大，对实时性要求较高的应用不够友好；YOLO v10 虽浮点运算量与参数量控制较好，但其准确率和整体检测精度相对较低，存在性能不足的问题；而 YOLO 11 的相关研究和部署经验仍相对有限，其在特定应用场景中的稳定性和适

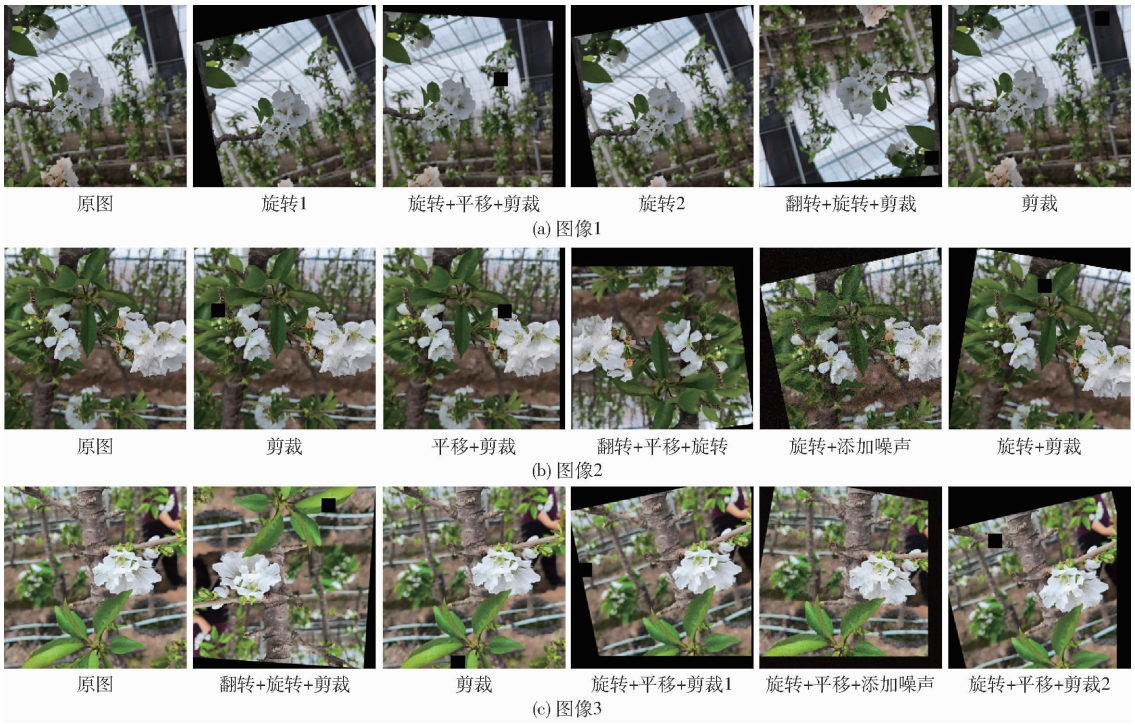


图 2 樱桃花数据集图像示例

Fig. 2 Example image of cherry blossom dataset

应性尚需进一步验证。因此,本文在 YOLO v8 模型的基础上进行改进,以提高模型在设施环境下对樱桃花的检测性能。首先引入 CSPPC 结构,替换 Backbone 和 Neck 网络中的 C2f 模块,降低模型参数量和浮点运算量,并提高模型的特征提取和融合的效率,进而提高模型的检测性能。其次,在 SPPF 模块前引入 ECA 注意力机制,在不增加模型参数量和浮点运算量的前提下,进一步增强模型的特征表达能力。最后,将 Neck 中的 Conv 模块替换为 GSConv 模块,进一步降低模型的参数量和浮点运算量,并优化特征图的传递过程,增强多尺度特征的融合效果,提高模型的整体检测性能和实时性。CEG - YOLO 模型结构如图 3 所示。

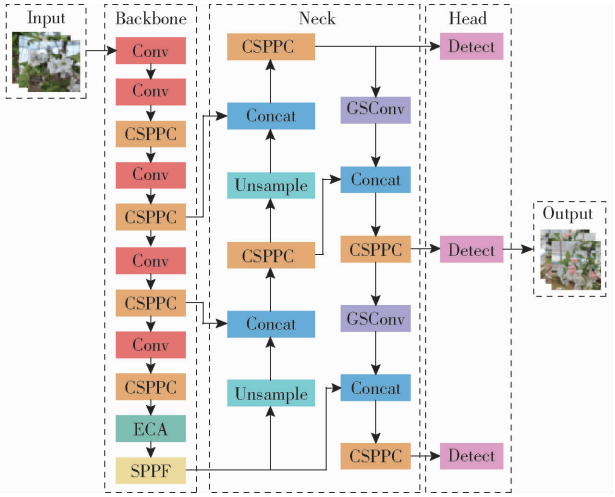


图 3 CEG - YOLO 模型结构图

Fig. 3 CEG - YOLO model structure diagram

1.2.1 CSPPC 模块

CSPPC(Integration of cross-stage partial networks and partial convolution)[11]模块结合了双重卷积和部分卷积(Partial convolution, PConv)结构,是一种基于 PConv 的轻量级创新模块。CSPPC 把原先 C2f 里 Bottleneck 中的普通卷积替换为 PConv,并且结合了双分支结构的思想,不仅增强了网络的特征提取能力,还通过减少冗余的通道特征降低了计算冗余和内存访问,从而减少了模型的参数量,使得模型计算效率大幅提升,同时保持了较高的检测精度[12]。特别是在处理小型目标时,CSPPC 能够有效减少模型内存占用量,便于在资源受限的设备上部署,降低了设备的开发成本[13]。CSPPC 模块结构如图 4 所示,其中 n 表示重复堆叠 PConv 的数量,h 表示特征图高度,w 表示特征图宽度,c_p 表示特征图通道数,k 表示卷积核大小。

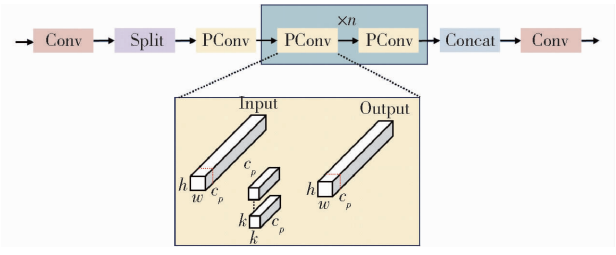


图 4 CSPPC 结构图

Fig. 4 CSPPC structure diagram

在樱桃花检测方面,CSPPC 模块能够在保持高精度特征提取的同时,降低网络的复杂性和计算开

销。可使得模型更加适用于资源受限的设备，降低了部署成本，并加速了实时检测的速度。尤其是在面对小物体和复杂背景时，CSPPC 模块能够更加精准地提取关键特征，进而提高樱桃花检测的精度和鲁棒性。

1.2.2　ECA 注意力机制

ECA（Efficient channel attention）[14] 注意力机制是一种高效且轻量的通道注意力机制，是由 SE（Squeeze-and-excitation）[15] 注意力机制改进而来。与 SE 机制不同，ECA 去除了全连接层，采用自适应的一维卷积来捕捉通道间的交互关系，从而避免 SE 机制中全连接层降维可能引发的副作用，提高特征提取能力并降低计算复杂度。ECA 注意力机制结构如图 5 所示，其中 C 表示特征图通道数，H 表示特征图的高度，W 表示特征图的宽度。该机制首先对输入特征图进行全局平均池化（GAP），将空间维度压缩为 1×1，得到每个通道的全局信息。并利用自适应函数选择卷积核大小，通过一维卷积操作学习通道间的依赖关系，并通过 Sigmoid 激活生成每个通道的注意力权重。最后将这些权重与原始特征图的各个通道逐元素相乘，得到加权后的特征图[16]。通过上述方式，ECA 不仅增强了模型对重要通道特征的关注，还降低了计算资源的消耗，因此能够在保证性能的同时显著减小模型的体积，适用于实时目标检测任务。

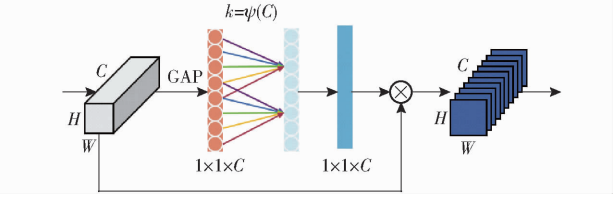


图 5　ECA 结构图

Fig. 5　ECA structure diagram

对于樱桃花检测而言，ECA 机制的引入能够有效提升模型对细节特征的敏感度，尤其在复杂背景和小物体的情况下，能够更精准地识别樱桃花的特征。同时，ECA 机制通过灵活选择卷积核大小提升了模型性能，尤其在樱桃花检测任务中，能够增强对重要特征的关注，减少背景噪声的干扰，同时保持较小的模型规模和高效的计算能力。

1.2.3　GSConv 模块

GSConv（Grouped spatial convolution）模块[17] 是一种轻量级卷积结构，通过结合标准卷积（Standard convolution，SC）和深度可分离卷积（Depth-wise separable convolution，DSC），并引入洗牌（shuffle）操作，降低卷积操作的计算复杂度，同时保持较高的特征提取精度。GSConv 结构如图 6 所示。其将输入

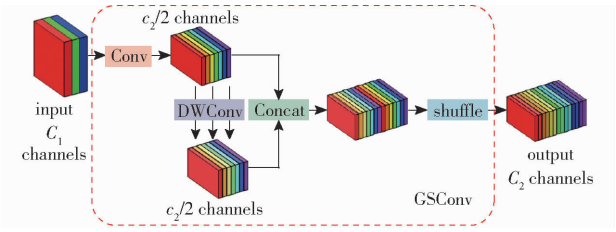


图 6　GSConv 结构图

Fig. 6　GSConv structure diagram

特征图分为两部分，一部分采用标准卷积进行特征提取，另一部分则采用深度可分离卷积。标准卷积能够提取丰富的特征信息，而深度可分离卷积则有助于减少模型浮点运算量。其次，GSConv 将这两部分的卷积结果进行拼接，并通过通道混洗操作增强特征之间的信息流通与交互，确保输出特征图既包含丰富的特征信息，又保持较低的计算复杂度[18]。

对于樱桃花检测任务，GSConv 模块能够在不增加过多浮点运算量的情况下，提取更丰富的特征信息。使得检测模型在保留高精度的同时，能够处理更多的输入数据和复杂场景[19]。特别是在资源受限的设备或边缘计算环境中，GSConv 模块的轻量级设计能够大幅减少模型的浮点运算量和内存占用量，使得樱桃花检测模型更加适合在这些设备上部署，提升了实时检测的效率和部署的灵活性。

2　结果与讨论

2.1　试验设置与评价指标

采用的操作系统为 Linux ubuntu 22.04，CPU 型号为 Intel（R）Xeon（R）Platinum 8352V，GPU 型号为 NVIDIA GeForce RTX 4090，运行内存为 24 GB，编程语言为 Python 3.10，采用 PyTorch 2.1.0 深度学习框架训练，GPU 加速库为 CUDA 12.1。

为评估网络模型在樱桃花检测任务中的性能，采用精确率（Precision，P）、召回率（Recall，R）、平均精度均值（mean Average Precision，mAP）、参数量和浮点运算量作为主要评价指标[20]。

2.2　CSPPC 模块对比试验

为验证本文采用的 CSPPC 模块的性能，分别采用 CSPHet、GELAN 和 ScConv 模块在模型相同位置进行同一模块的替换，与本文的 CSPPC 模块进行对比试验，结果如表 1 所示。

由表 1 可知，YOLO v8－CSPPC 模型相较于 YOLO v8 模型，精确率、召回率和 mAP 分别提高 0.6、1.1、0.9 个百分点，且参数量和浮点运算量分别降低 29.56% 和 27.16%。与其他模型相比，YOLO v8－CSPPC 模型精确率和 mAP 表现优于其他模型，虽召回率略低于 YOLO v8－CSPHet 模型，

表 1 不同模块检测结果对比

Tab. 1 Comparison of detection results for different modules

模型	精确率/%	召回率/%	mAP/%	参数量	浮点运算量
YOLO v8	88.2	89.4	93.0	3.01×10^6	8.1×10^9
YOLO v8 - CSPHet	87.2	90.9	93.5	2.42×10^6	6.8×10^9
YOLO v8 - CSPPC	88.8	90.5	93.9	2.12×10^6	5.9×10^9
YOLO v8 - GELAN	88.4	89.3	93.8	2.14×10^6	5.9×10^9
YOLO v8 - ScConv	88.0	89.5	92.9	2.20×10^6	6.2×10^9

但仍高于其他模型;且 YOLO v8 - CSPPC 模型的参数量和浮点运算量均小于其他模型。这表明 YOLO v8 - CSPPC 模型在提高检测性能的同时,显著优化了模型的参数量和浮点运算量,具有较为优越的检测性能。

2.3 ECA 注意力模块对比试验

为验证本文添加的 ECA 注意力机制的性能,分别在模型的同样位置添加 CA、CBAM、ESE、SA、SEA 和 STA 注意力机制,与本文注意力机制进行性能对比,结果如图 7 所示。由图 7 可知,与 YOLO v8 模型相比,YOLO v8 - ECA 模型精确率、召回率和 mAP 分别提高 1.1、1.7、1.2 个百分点。与其他模型对比,YOLO v8 - ECA 的精确率为所有模型中最优,尽管其召回率略低于 YOLO v8 - ESE 模型,但仍高于其他模型。虽 YOLO v8 - ECA 模型与 YOLO v8 - CBAM 模型的 mAP 相同,但其优于其他模型,整体检测性能更好。

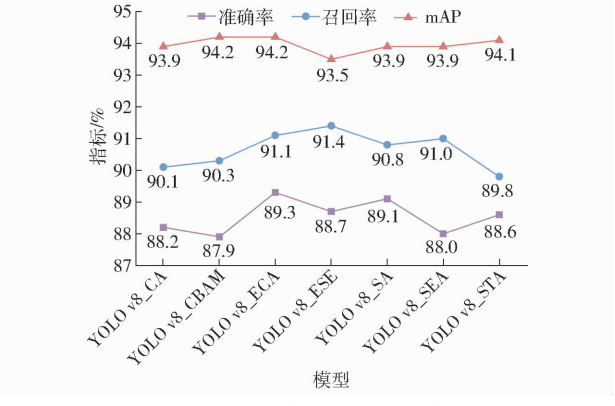


图 7 不同注意力机制对比结果

Fig. 7 Comparative results of different attention modules

2.4 GSConv 模块对比试验

为验证本文采用的 GSConv 模块的性能,分别采用 DWConv、MBConv 和 ODConv 模块在模型相同位置进行同一模块的替换,与本文 GSConv 模块进行性能对比,结果如表 2 所示。

由表 2 可知,YOLO v8 - GSConv 模型相比于 YOLO v8 模型,精确率、召回率和 mAP 分别提高 1.6、1.9、1.8 个百分点,同时参数量和浮点运算量分别减少 32.56% 和 27.16%。与其他模型相比,YOLO v8 - GSConv 模型精确率、召回率和 mAP 均表现优异,虽然其参数量略高于 YOLO v8 - DWConv 模型和 YOLO v8 - MBConv 模型,但其参数量仍小于其他模型,且模型浮点运算量也相对减小,展现出较低的计算成本。这表明 YOLO v8 - GSConv 模型适用于对计算资源要求较高的目标检测任务中。

表 2 不同 Conv 模块对检测结果的影响

Tab. 2 Effect of different Conv modules on detection results

模型	精确率/%	召回率/%	mAP/%	参数量	浮点运算量
YOLO v8	88.2	89.4	93.0	3.01×10^6	8.1×10^9
YOLO v8 - DWConv	88.4	91.1	94.7	1.94×10^6	5.7×10^9
YOLO v8 - GSConv	89.8	91.3	94.8	2.03×10^6	5.8×10^9
YOLO v8 - MBConv	88.5	91.2	94.1	1.98×10^6	5.8×10^9
YOLO v8 - ODConv	88.6	90.9	94.7	2.68×10^6	5.7×10^9

2.5 消融试验

为验证改进模型 CEG - YOLO 的有效性,以本文基础模型 YOLO v8 和最新 YOLO 11 为基础模型,在自制的樱桃花数据集上进行消融试验,评估不同改进模块对模型性能的影响。为确保结果的可比性,YOLO v8 和 YOLO 11 中各模块的引入方式及其位置一致。表 3 为消融试验结果,表中“√”表示引入此模块,“×”表示未引入,C 为 CSPPC 模块,E 为 ECA 注意力机制,G 为 GSConv 模块。

由表 3 可知,将 CSPPC 模块分别引入到 YOLO v8 和 YOLO 11 中,得到 YOLO v8 - C 和 YOLO 11 - C 模型。YOLO v8 - C 较原 YOLO v8 模型,精确率、召回率和 mAP 分别提高 0.6、1.2、0.9 个百分点,参数量和浮点运算量分别减少 29.56% 和 27.16%;与 YOLO 11 - C 模型相比,精确率、召回率和 mAP 分别提高 0.5、1.1、0.6 个百分点,参数量和浮点运算量略有减少。将 ECA 注意力机制分别引入到 YOLO v8 和 YOLO 11 中,得到 YOLO v8 - E 和 YOLO 11 - E 模型,YOLO v8 - E 较原 YOLO v8 模型,精确率、召回率和 mAP 分别提高 1.1、0.7、1.2 个百分点,且参数量和浮点运算量不变;与 YOLO 11 - C 模型相比,精确率、召回率和 mAP 分别提高 0.8、0.7、0.6 个百分点,但参数量和浮点运算量有所增加。将 GSConv 模块分别引入到 YOLO v8 和 YOLO 11 中,得到 YOLO v8 - G 和 YOLO 11 - G 模型,YOLO v8 - G 模型较原 YOLO v8 模型,精确率、召回率和 mAP 分别提高 0.4、0.5、0.8 个百分点,参数量和浮点运算量略有减少;与 YOLO 11 - G 模型相比,精确率、召回率和 mAP 分别提高 0.2、0.3、0.3 个百分点,但

表 3　消融试验结果

Tab. 3　Result sof ablation experiment

基础模型	模型	CSPPC	ECA	GSConv	精确率/%	召回率/%	mAP/%	参数量	浮点运算量
YOLO v8	YOLO v8	×	×	×	88.2	89.4	93.0	3.01×10^6	8.1×10^9
	YOLO v8－C	√	×	×	88.8	90.6	93.9	2.12×10^6	5.9×10^9
	YOLO v8－E	×	√	×	89.3	90.1	94.2	3.01×10^6	8.1×10^9
	YOLO v8－G	×	×	√	88.6	89.9	93.8	2.92×10^6	8.0×10^9
	YOLO v8－CE	√	√	×	89.5	90.6	94.4	2.12×10^6	5.9×10^9
	YOLO v8－CG	√	×	√	89.6	90.8	94.6	2.03×10^6	5.8×10^9
	YOLO v8－EG	×	√	√	89.4	90.8	94.7	2.92×10^6	8.0×10^9
	CEG－YOLO	√	√	√	89.8	91.3	94.8	2.03×10^6	5.8×10^9
YOLO 11	YOLO 11	×	×	×	88.1	89.0	93.1	2.58×10^6	6.3×10^9
	YOLO 11－C	√	×	×	88.3	89.5	93.3	2.16×10^6	6.0×10^9
	YOLO 11－E	×	√	×	88.5	89.4	93.6	2.58×10^6	6.3×10^9
	YOLO 11－G	×	×	√	88.4	89.6	93.5	2.62×10^6	6.4×10^9
	YOLO 11－CE	√	√	×	88.7	90.2	93.8	2.19×10^6	6.1×10^9
	YOLO 11－CG	√	×	√	88.6	90.4	93.6	2.19×10^6	6.1×10^9
	YOLO 11－EG	×	√	√	88.9	90.7	93.9	2.62×10^6	6.4×10^9
	YOLO 11－CEG	√	√	√	89.3	90.9	94.4	2.20×10^6	6.0×10^9

参数量和浮点运算量有所增加。结果表明，单独引入 CSPPC、ECA 和 GSConv 模块均能有效提升模型的检测性能。

同时将 CSPPC 模块与 ECA 注意力机制分别引入到 YOLO v8 和 YOLO 11 中，得到 YOLO v8－CE 和 YOLO 11－CE 模型，YOLO v8－CE 模型较 YOLO v8、YOLO v8－C 和 YOLO v8－E 模型，精确率、召回率和 mAP 均有所提高，且参数量和浮点运算量较 YOLO v8 和 YOLO v8－E 有所减少，与 YOLO v8－C 模型保持一致；与 YOLO 11－CE 模型相比，精确率、召回率和 mAP 分别提高 0.8、0.4、0.6 个百分点，参数量和浮点运算量略有减少。同时将 CSPPC 模块与 GSConv 模块分别引入到 YOLO v8 和 YOLO 11 中，得到 YOLO v8－CG 和 YOLO 11－CG 模型，YOLO v8－CG 模型较 YOLO v8、YOLO v8－C 和 YOLO v8－G 模型，精确率、召回率和 mAP 均有所提高，参数量和浮点运算量也均有所减少；与 YOLO 11－CG 模型相比，精确率、召回率和 mAP 分别提高 1.0、0.4、1.0 个百分点，参数量和浮点运算量略有减少。同时将 ECA 注意力机制与 GSConv 模块分别引入到 YOLO v8 和 YOLO 11 中，得到 YOLO v8－EG 和 YOLO 11－EG 模型，YOLO v8－EG 模型精确率、召回率和 mAP 较 YOLO v8、YOLO v8－E 和 YOLO v8－G 模型有所提高，并且参数量和浮点运算量均低于 YOLO v8、YOLO v8－E 模型，且与 YOLO v8－G 模型保持一致；与 YOLO 11－EG 模型相比，精确率、召回率和 mAP 分别提高 0.5、0.1、0.8 个百分点，参数量和浮点运算量有所增加。

同时将 CSPPC 模块、ECA 注意力机制和 GSConv 模块引入到 YOLO v8 和 YOLO 11 中，得到 CEG－YOLO 和 YOLO 11－CEG 模型，CEG－YOLO 模型相较于 YOLO v8 模型，精确率、召回率和 mAP 分别提高 1.6、1.9、1.8 个百分点，参数量和浮点运算量分别减少 32.56% 和 28.40%；相较于 YOLO 11 模型，精确率、召回率和 mAP 分别提高 1.7、2.3、1.7 个百分点，参数量和浮点运算量分别减少 21.31% 和 7.94%；相较于 YOLO 11－CEG 模型，精确率、召回率和 mAP 分别提高 0.5、0.4、0.4 个百分点，参数量和浮点运算量均有所减少。CEG－YOLO 在各项评估指标上均优于其他改进模型，表现出优异的检测性能。消融试验证明了所提方法的有效性与合理性。将 CSPPC、ECA 和 GSConv 模块引入 YOLO v8，不仅显著提升了检测精度，还大幅降低了参数量和浮点运算量，增强效果尤为明显。因此，该方法更适合部署于边缘设备或移动端等资源受限场景。

2.6　不同模型对比试验

为进一步验证本文算法 CEG－YOLO 的有效性，与当前主流的一阶段目标检测算法（YOLO v3[21]、YOLO v5[22]、YOLO v7[23]、YOLO v8、YOLO v9[24]、YOLO v10[25]和 YOLO 11[26]模型）进行对比试验，同时与 Faster R－CNN 模型[3]、YOLO v5s－P－CBAM 模型[7]和 LT－YOLO 模型[10]进行对比，不同模型对比结果如表 4 所示。由表 4 可知，本文模型的精确率为 89.8%、召回率为 91.3%、mAP 为 94.8%、参数量为 2.03×10^6、浮点运算量为 5.8×10^9。尽管与 YOLO v5 模型相比，CEG－YOLO 模型的参数量和浮点运算量略高，但其精确率、召回率和 mAP 分别提高 0.7、3.6、3.9 个百分点，展现出更优

表 4 不同模型性能对比试验

Tab. 4 Comparative tests of different models

模型	精确率/%	召回率/%	mAP/%	参数量	浮点运算量
YOLO v3	88.0	83.3	87.1	8.67×10^6	1.29×10^{10}
YOLO v5	89.1	87.7	90.9	1.76×10^6	4.10×10^9
YOLO v7	88.4	90.0	94.1	6.01×10^6	1.30×10^{10}
YOLO v8	88.2	89.4	93.0	3.01×10^6	8.10×10^9
YOLO v9	88.5	90.6	92.7	2.62×10^6	1.07×10^{10}
YOLO v10	86.2	90.5	91.7	2.70×10^6	8.20×10^9
YOLO 11	88.1	89.0	93.1	2.58×10^6	6.30×10^9
Faster R-CNN			86.1		
YOLO v5s-P-CBAM	91.62	83.02	94.06		
LT-YOLO	83.16	82.15	87.47		
CEG-YOLO	89.8	91.3	94.8	2.03×10^6	5.8×10^9

的检测性能。与 YOLO v3、YOLO v7、YOLO v8、YOLO v9、YOLO v10 和 YOLO 11 模型相比，CEG-YOLO 模型的精确率分别提高 1.8、1.4、1.6、1.3、3.6、1.7 个百分点；召回率分别提高 8.0、1.3、1.9、0.7、0.8、2.3 个百分点；mAP 分别提高 7.7、0.7、1.8、2.1、3.1、1.7 个百分点。在计算复杂度方面，CEG-YOLO 模型相比于这些模型的参数量和浮点运算量均表现出明显优势，其中参数量分别减少 76.59%、71.53%、32.56%、55.09%、24.81% 和 21.31%，浮点运算量分别减少 55.04%、45.28%、28.40%、32.56%、29.27% 和 7.9%。与 Faster R-CNN 模型相比，CEG-YOLO 模型的 mAP 提高 8.7 个百分点。与 YOLO v5s-P-CBAM 模型相比，CEG-YOLO 模型的精确率虽较低，但召回率和 mAP 分别提高 8.28、0.74 个百分点。与 LT-YOLO 模型相比，CEG-YOLO 模型的精确率、召回率和 mAP 分别提高 6.64、9.15、7.33 个百分点。结果表明，CEG-YOLO 模型在樱桃花识别任务中不仅能够提供高准确性的检测性能，同时也有效降低了计算复杂度。

2.7 可视化分析对比

为评价本文构建的樱桃花检测模型 CEG-YOLO 的检测性能，将其与 YOLO v5、YOLO v8、YOLO v9、YOLO v10 和 YOLO 11 模型进行对比，检测结果如图 8 所示。在单目标的樱桃花图像上，CEG-YOLO 模型能够精准检测出樱桃花和花蕊，而 YOLO v5、YOLO v8、YOLO v9、YOLO v10 和 YOLO 11 模型虽也能检测到樱桃花和花蕊，但在准确性上略低于 CEG-YOLO 模型，同时 YOLO v5 出现了误检的情况，将樱桃花误检为花蕊，YOLO v10 出现了将一个花蕊检测成两个花蕊的情况。在多目标的樱桃花图像上，易受到花朵重叠影响，导致漏检率高，但 CEG-YOLO 模型能够精准检测出较多的樱桃花和花蕊且漏检率较低，而 YOLO v5、YOLO v8、YOLO v9、YOLO v10 和 YOLO 11 模型均存在漏检情况，YOLO v5 还存在误检情况。在远目标中，樱桃花图像易受到不均匀光照条件的影响，导致图像中花朵的颜色和对比度变化，进而影响检测的准确性，而 CEG-YOLO 模型依旧能够精准检测出樱桃花和花蕊且能够保持较高的准确性，但 YOLO v5 模型出现了误检现象；YOLO v8 和 YOLO v9 虽也能检测到樱桃花和花蕊，但准确性低于 CEG-YOLO 模型；YOLO v10 和 YOLO 11 模型则出现漏检情况。因此通过可视化分析进一步验证了 CEG-YOLO 模型在目标检测任务中的先进性和实用性。

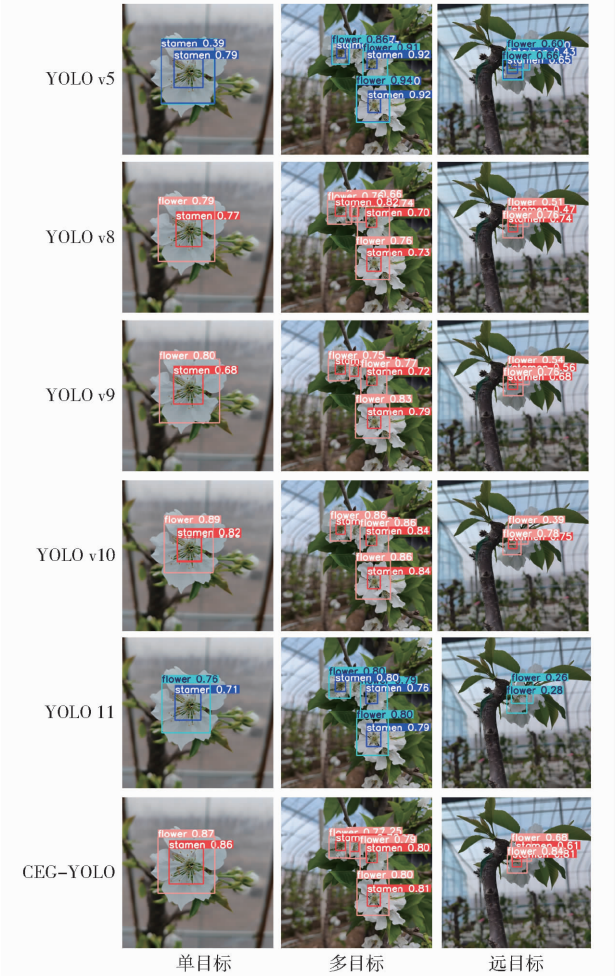


图 8 不同模型检测结果图

Fig. 8 Map of detection results of different models

3 结论

(1) 为实现设施环境中樱桃花目标的准确检测，以 YOLO v8 模型为基础，提出一种适用于设施环境樱桃花目标检测模型 CEG-YOLO。通过引入

CSPPC 模块、ECA 注意力机制和 GSConv 模块，CEG－YOLO 模型在提高检测精度的同时，减少了浮点运算量和参数量。

（2）CEG－YOLO 模型的精确率为 89.8%、召回率为 91.3%、mAP 为 94.8%、参数量为 2.03×10^6、浮点运算量为 5.8×10^9。与原始 YOLO v8 模型相比，该模型的精确率、召回率和 mAP 分别提高 1.6、1.9、1.8 个百分点，参数量和浮点运算量分别减少 32.56% 和 28.40%。在与 YOLO v3、YOLO v5、YOLO v7、YOLO v9、YOLO v10 和 YOLO 11 检测模型的对比中，CEG－YOLO 模型在精确率、召回率和 mAP 等多个关键指标上均表现出了明显优势，在实际检测结果中，CEG－YOLO 模型能够有效地减少漏检现象。

参 考 文 献

[1] 伊贤贵，李蒙，王贤荣. 樱亚属分类学研究进展[J]. 南京林业大学学报(自然科学版)，2024，48(3)：46－57.
YI Xiangui，LI Meng，WANG Xianrong. A review on the taxonomy study of *Prunus* subgen. *Cerasus* (Mill) A. Gray[J]. Journal of Nanjing Forestry University (Natural Science Edition)，2024，48(3)：46－57. (in Chinese)

[2] 陈旭阳. 华中樱桃种间杂交初步研究[D]. 长沙：中南林业科技大学，2023.
CHEN Xuyang. Preliminary study on interspecific hybridization of *Prunus conradinae*[D]. Changsha：Central South Forestry University of Science and Technology，2023. (in Chinese)

[3] LIN P，LEE W S，CHEN Y M，et al. A deep-level region-based visual representation architecture for detecting strawberry flowers in an outdoor field[J]. Precision Agriculture，2020，21：387－402.

[4] XU X，WANG H，MIAO M，et al. Cucumber flower detection based on YOLOv5s－SE7 within greenhouse environments[J]. IEEE Access，2023，11：64358－64369.

[5] ZHAO W，WU D，ZHENG X. Detection of chrysanthemums inflorescence based on improved CR－YOLOv5s algorithm[J]. Sensors，2023，23(9)：4234.

[6] LI G，SUO R，ZHAO G，et al. Real-time detection of kiwifruit flower and bud simultaneously in orchard using YOLOv4 for robotic pollination[J]. Computers and Electronics in Agriculture，2022，193：106641.

[7] 孙乐琳，高媛，周桂红，等. 基于改进 YOLOv5s 的自然环境下梨花识别[J]. 河北农业大学学报，2024，47(6)：54－61.
SUN Lelin，GAO Yuan，ZHOU Guihong，et al. Pear flower recognition in natural environment based on improved YOLOv5s[J]. Journal of Hebei Agricultural University，2024，47(6)：54－61. (in Chinese)

[8] 叶进，吴梦岚，邱文杰，等. 基于 polyphyletic 损失函数的荔枝花检测方法[J]. 农业机械学报，2023，54(5)：253－260.
YE Jin，WU Menglan，QIU Wenjie，et al. Litchi flower detection method based on polyphyletic loss function[J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(5)：253－260. (in Chinese)

[9] 郭鑫. 基于改进 YOLOv3 的油茶花识别技术研究[D]. 长沙：中南林业科技大学，2023.
GUO Xin. Research on camellia flower identification technique based on modified YOLOv3[D]. Changsha：Central South University of Forestry and Technology，2023. (in Chinese)

[10] 高昂，吴昆，宋月鹏，等. 基于 LT－YOLO 检测与机器视觉的苹果激光疏花试验台参数优化与试验[J]. 农业机械学报，2025，56(2)：393－401.
GAO Ang，WU Kun，SONG Yuepeng，et al. Parameter optimization and testing of apple laser flower thinning test bed based on LT－YOLO inspection and machine vision[J]. Transactions of the Chinese Society for Agricultural Machinery，2025，56(2)：393－401. (in Chinese)

[11] CHEN J，KAO S，HE H，et al. Run，don't walk：chasing higher FLOPS for faster neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition，2023：12021－12031.

[12] LIU R M，SU W H. APHS－YOLO：a lightweight model for real-time detection and classification of *Stropharia rugoso*-annulata[J]. Foods，2024，13(11)：1710.

[13] ZHANG X，CHEN L. Bud－YOLO：a real-time accurate detection method of cotton top buds in cotton fields[J]. Agriculture，2024，14(9)：1651.

[14] WANG Q，WU B，ZHU P，et al. ECA－Net：efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition，2020：11534－11542.

[15] HU J，SHEN L，SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition，2018：7132－7141.

[16] 刘忠意，魏登峰，李萌，等. 基于改进 YOLO v5 的橙子果实识别方法[J]. 江苏农业科学，2023，51(19)：173－181.
LIU Zhongyi，WEI Dengfeng，LI Meng，et al. Orange fruit recognition method based on improved YOLO v5[J]. Jiangsu Agricultural Sciences，2023，51(19)：173－181. (in Chinese)

[17] LI H，LI J，WEI H，et al. Slim-neck by GSConv：a lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing，2024，21(3)：62.

[18] WU Z，ZHANG Y，WANG X，et al. Algorithm for detecting surface defects in wind turbines based on a lightweight YOLO model[J]. Scientific Reports，2024，14(1)：24558.

[19] 廖娟,刘凯旋,杨玉青,等. 基于 RDN - YOLO 的自然环境下水稻病害识别模型研究[J]. 农业机械学报,2024,55(8):233 - 242.
LIAO Juan, LIU Kaixuan, YANG Yuqing, et al. Rice disease recognition in natural environment based on RDN - YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(8):233 - 242. (in Chinese)

[20] DU Y, GAO A, SONG Y, et al. Young apple fruits detection method based on improved YOLO v5[J]. INMATEH-Agricultural Engineering, 2024, 73(2). 84 - 93.

[21] 张帆,郭思媛,任方涛,等. 基于改进 YOLO v3 的玉米叶片气孔自动识别与测量方法[J]. 农业机械学报,2023,54(2):216 - 222.
ZHANG Fan, GUO Siyuan, REN Fangtao, et al. Automatic identification and measurement of maize leaves stomata based on YOLO v3[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(2):216 - 222. (in Chinese)

[22] 冀汶莉,刘洲,邢海花. 基于 YOLO v5 的农田杂草识别轻量化方法研究[J]. 农业机械学报,2024,55(1):212 - 222,293.
JI Wenli, LIU Zhou, XING Haihua. Lightweight method for identifying farmland weeds based on YOLO v5[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(1):212 - 222,293. (in Chinese)

[23] 袁杰,谢霖伟,郭旭,等. 基于改进 YOLO v7 的苹果叶片病害检测方法[J]. 农业机械学报,2024,55(11):68 - 74.
YUAN Jie, XIE Linwei, GUO Xu, et al. Apple leaf disease detection method based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(11):68 - 74. (in Chinese)

[24] HUANG Y, HUANG H, QIN F, et al. YOLO - IAPs: a rapid detection method for invasive alien plants in the wild based on improved YOLOv9[J]. Agriculture,2024,14(12):2201.

[25] MAI R, WANG J. UM - YOLOv10: underwater object detection algorithm for marine environment based on YOLO v10 model [J]. Fishes,2025,10(4):173.

[26] HUO Y,ZHANG Y, XU J, et al. A small-sample target detection method for transmission line hill fires based on meta-learning YOLO 11[J]. Energies,2025,18(6):1511.

(上接第 606 页)

[22] WANG Y, LI J. Branching in rice[J]. Current Opinion in Plant Biology, 2011,14(1): 94 - 99.

[23] RUSSELL B C, TORRALBA A, MURPHY K P, et al. LabelMe: a database and web-based tool for image annotation[J]. International Journal of Computer Vision, 2008,77: 157 - 173.

[24] KHANAM R, HUSSAIN M. Yolov11: an overview of the key architectural enhancements[J]. arXiv Preprint, arXiv:2410.17725,2024.

[25] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779 - 788.

[26] LI Y, HOU Q, ZHENG Z, et al. Large selective kernel network for remote sensing object detection[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 16794 - 16805.

[27] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2818 - 2826.

[28] HE T, ZHANG Z, ZHANG H, et al. Bag of tricks for image classification with convolutional neural networks[C]// Proceedings of the the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 558 - 567.

[29] SHUAI L, MU J, JIANG X, et al. An improved YOLOv5-based method for multi-species tea shoot detection and picking point location in complex backgrounds[J]. Biosystems Engineering, 2023,231: 117 - 132.

[30] GAO H, WANG Z, JI S. Channelnets: compact and efficient convolutional neural networks via channel-wise convolutions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(8): 2570 - 2581.