

基于改进 YOLOv8n 的密集分布猕猴桃花期检测方法

刘建江, 李书琴*

(西北农林科技大学信息工程学院, 杨凌 712100)

摘要: 为解决不同花期猕猴桃花朵大量遮挡、重叠现象导致检测困难的问题, 该研究提出一种基于改进 YOLOv8n 的密集分布猕猴桃花期检测模型 YOLOv8-KFP。首先, 以 YOLOv8n 为基准模型, 采用 StarBlock 改进 YOLOv8n 的 C2f, 保持模型轻量同时增强特征表达能力。其次, 引入 SSFF (scale sequence feature fusion) 模块、TFE (triple feature encoder) 模块、DySample 上采样器改进 Neck 网络, 动态适应不同尺度、形状、边界的花朵目标, 提升模型多尺度信息提取能力, 减少对遮挡、重叠猕猴桃花朵的误检和漏检。最后, 利用 Soft-NMS 进行后处理, 减少目标候选框的误删。结果表明, YOLOv8-KFP 模型的精确率、召回率和平均精度均值分别达到了 89.1%、88.7% 和 92.4%, 相比于 YOLOv8n 模型分别提高了 4.9、5.1 和 3.8 个百分点, 浮点运算量和参数量分别降低了 6.2% 和 11.6%。与主流目标检测模型 SSD、YOLOv9t、YOLOv10n、YOLOv11n 和 YOLOv12n 进行对比, YOLOv8-KFP 模型的平均精度均值分别提高了 7.0、4.0、5.5、4.2 和 4.1 个百分点, 其在花苞期、半开期、全开期和凋落期上的召回率分别为 90.8%、85.9%、90.0% 和 88.1%。YOLOv8-KFP 模型在保持模型轻量化的同时提高了检测精度, 能够实现对密集分布猕猴桃花期的有效检测, 可为猕猴桃花朵的自动化授粉提供技术支撑。

关键词: 深度学习; 目标检测; 模型; YOLOv8n; 猕猴桃花期; 多尺度特征融合

doi: 10.11975/j.issn.1002-6819.202502138

中图分类号: S24;TP391.4

文献标志码: A

文章编号: 1002-6819(2025)-12-0172-10

刘建江, 李书琴. 基于改进 YOLOv8n 的密集分布猕猴桃花期检测方法[J]. 农业工程学报, 2025, 41(12): 172-181. doi: 10.11975/j.issn.1002-6819.202502138 <http://www.tcsae.org>

LIU Jianjiang, LI Shuqin. Method for detecting densely distributed kiwifruit flowering period based on improved YOLOv8n[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2025, 41(12): 172-181. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202502138 <http://www.tcsae.org>

0 引言

中国是猕猴桃生产大国^[1], 猕猴桃的高质高产对于推动农业经济发展、促农增收具有重要意义。猕猴桃是雌雄异株、异花授粉植物^[2], 花期较短。在实际果园环境中, 生物授粉的效率较低^[3], 对果实品质带来不利影响^[4], 而人工辅助授粉方式需要消耗巨大的人力物力^[5-6]。随着自动化机器人技术在农业领域的不断发展^[7], 大量专家学者将基于深度学习的花朵检测模型引入机器人技术以实现自动授粉^[8]。尽管授粉机器人能够大大提升授粉效率^[9], 但自然环境下的猕猴桃花朵生长分布十分密集, 花朵间存在大量互相遮挡的现象, 导致在实际应用中花朵漏检、误检、授粉率低的问题。因此, 如何快速、准确地对密集分布的猕猴桃花期进行检测成为授粉机器人的研究热点问题。

随着深度学习技术的发展, 单阶段方法在不断优化的过程中已逐渐缩小了与双阶段方法的性能差距^[10], 其代表算法 YOLO 系列直接从图像中预测所有目标的位置

和类别^[11], 体现出巨大的速度优势, 已被广泛应用于花朵检测任务。尚钰莹等^[12]提出了一种基于 YOLOv5s 深度学习的苹果花朵检测方法, 对田间拍摄得到的图像进行检测并达到了 87.70% 的精确率, 并对不同天气下、不同花朵颜色、逆光顺光条件下的检测情况进行比较分析, 为苹果栽培的机械疏花提供支持。吴利刚等^[13]提出一种基于 YOLOv8-ABW 的黄花成熟度检测方法, 采用结合注意力机制的尺度特征交互机制、双向特征金字塔特征融合网络、WIOUv3 改进 YOLOv8, 获得 82.32% 的精确率、83.71% 的召回率, 助力黄花智能化实时采摘研究。BAI 等^[14]提出了一种改进 YOLOv7 算法, 通过引入 Swin Transformer 预测头和 GS-ELAN 优化模块, 有效提升了检测效率, 平均精度均值达到 92.1%, 检测速度为 45 帧/s。

尽管 YOLO 检测模型已成为花朵检测领域最快速、最准确的模型之一^[15-17], 但由于猕猴桃花朵多以簇生形式生长, 单簇花朵数通常为 2~5 朵, 棚架种植模式释放垂直空间, 花朵垂直分布在 10~20 cm 之间且整体开放向下, 在自下而上的角度呈现出更加密集分布^[18], 花朵间存在严重的相互遮挡、重叠, 给模型的检测效果带来了巨大的挑战。龚惟新等^[19]在提出一种基于改进 YOLOv5s 的猕猴桃花朵检测模型 YOLOv5s_S_N_CB_CA 时, 将检测结果出现的漏检、误检归因为 3 个方面: 亮度不足、花朵间的相互遮挡与重叠现象和不同生长阶段花朵的近似性。针对猕猴桃花朵图像存在的亮度不足、

收稿日期: 2025-02-25 修订日期: 2025-05-26

基金项目: 国家重点研发计划子课题项目 (2022YFD1300201)

作者简介: 刘建江, 研究方向为目标检测。

Email: liujianjiang@nwsafu.edu.cn

*通信作者: 李书琴, 教授, 博士生导师, 研究方向为农业信息化与智能信息系统。Email: lsq_cie@nwsuaf.edu.cn

噪声等问题，杜金芝等^[20]提出一种基于改进 GAN (generative adversarial network) 的猕猴桃低光照花朵图像增强模型，有效改善了检测效果。但猕猴桃花朵间的相互遮挡和重叠现象依然对猕猴桃花朵检测效果造成严重影响。

直接使用 YOLO 系列主流检测模型 YOLOv5、YOLOv8 进行猕猴桃花期检测，会忽略大尺寸特征图上的详细信息，从而在密集、重叠的猕猴桃花朵检测任务上出现大量误检、漏检现象。同时，遮挡问题使得网络能够提取到的花朵特征不完全，采用常规的上采样方法会导致特征信息丢失。不同花期的花朵大小、形态差异较大，密集分布的特性使得网络难以从遮挡、重叠的不同花期的花朵中提取出有效的特征。因此，针对以上问题，本文提出一种基于改进 YOLOv8n 的密集分布猕猴桃花期检测方法。通过改进 YOLOv8n 的特征融合网络和特征提取网络，结合相应上采样方法以及后处理技术，实现对不同花期的猕猴桃花朵的准确快速检测，以期对猕猴桃花朵的自动化授粉提供技术支撑。

1 材料与方法

1.1 图像采集与数据获取

密集分布猕猴桃花期图像分别采集自西北农林科技大学眉县猕猴桃试验站、山东省临沂市沂南县猕猴桃农户，猕猴桃品种包括“海沃德”“泰山一号”。图像采集设备为数码相机 (Canon EOS 6D Mark II) 和手机 (HUAWEI Mate 30、HUAWEI P30)，采集时间为 2021 年 (1 334 张) 和 2024 年 (2 519 张) 的 4—5 月。在自然环境下进行拍摄，采用仰视视角，焦距、曝光采用自动模式，为得到条件更多样的数据，拍摄距离为 20~60 cm，拍摄时间段为 8:00—18:00，包括逆光、顺光不同光照条件。采集的图像包括花朵、花苞相互遮挡 (1 083 张)，花朵相互遮挡 (934 张)，花朵被枝叶遮挡 (879 张)，具有多种遮挡状况 (957 张)，共计 3 853 张图像。

1.2 数据集制作

将所有图像尺寸统一为 640×640 像素，根据猕猴桃花朵的客观生长规律，本文对猕猴桃花期分为花苞期、半开期、全开期、凋落期 4 个时期。花苞期是花朵生长的初始阶段，通常表现为较小、密闭的结构。随着时间的推移，花苞会逐渐膨胀，花瓣逐渐打开但未完全张开，此时为半开期。当花瓣完全展开，花蕊完全暴露在外，为全开期，是授粉的最佳时期^[21]。花朵授粉完成后，花瓣逐渐脱落，花朵开始枯萎，为凋落期^[22]。在实际授粉作业中，对花苞期、半开期花朵进行授粉时可能因花朵未完全开放导致授粉不完全，产出小果、畸形果，并且授粉工作多次重复，需要区分凋落期花朵避免再次授粉^[23]。因此，采用上述 4 个时期进行检测，针对全开期花朵进行授粉，提升授粉质量。使用 LabelImg 软件对不同花期下的猕猴桃花朵进行人工标注，具体标注形式为最小的外接矩形框，标注后的各个类别目标数量分别为

花苞期 (12 763 个)、半开期 (11 767 个)、全开期 (13 862 个)、凋落期 (11 328 个)。按照 7:1:2 的比例将 3 853 张图片划分为 2 698 张训练集、385 张验证集和 770 张测试集。

2 密集分布猕猴桃花期检测方法

YOLOv8n 是 YOLOv8 系列的超轻量级版本^[24]，专为低计算资源的设备设计，如移动端和嵌入式设备，初步符合猕猴桃花朵检测的实际应用条件，但在对密集分布猕猴桃花期检测时会出现大量漏检、误检的问题。

因此，本研究针对密集分布猕猴桃花期检测任务，以 YOLOv8n 为基础网络，采取多种方法对模型进行改进，提出 YOLOv8-KFP。首先，由于自然环境中的猕猴桃花朵形态特征复杂，且不同花期的花朵之间存在一定的相似性，采用 StarNet 中的 StarBlock 改进 YOLOv8n 的 C2f，在保持模型轻量的同时增强模型的特征提取能力。其次，针对猕猴桃花朵大量遮挡、重叠现象导致的误检、漏检问题，采用 SSFF (scale sequence feature fusion) 模块与 TFE (triple feature encoder) 模块对 YOLOv8n 的颈部网络进行改进，通过结合图像的空间和尺度特征，提升模型在处理重叠、遮挡花朵场景的性能。针对最近邻插值的上采样方式会导致目标边缘模糊的问题，对 YOLOv8n 采用 DySample 上采样代替传统的上采样，以动态适应不同形状和边界的花朵特征，提高遮挡、重叠花朵的上采样效果。最后，针对传统 NMS (non-maximum suppression) 在处理密集目标检测时会误删重叠度较高的目标候选框的问题^[25]，采用 Soft-NMS 更好地处理密集分布花朵的检测，减少误删。基于上述改进的最终网络结构如图 1 所示。

2.1 改进 C2f

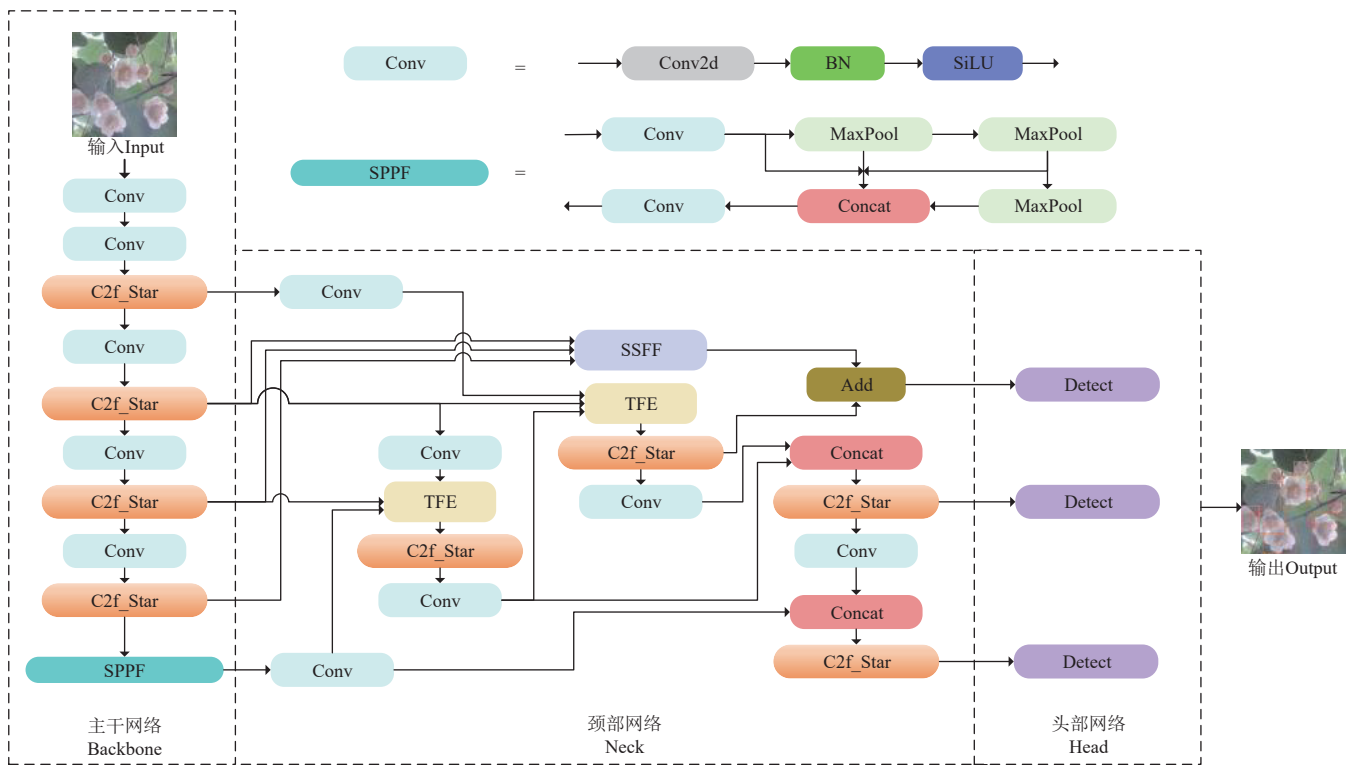
StarBlock^[26] 引入星操作，即通过逐元素乘法将特征映射到更高维度的非线性空间，提高模型的表达能力而不显著增加计算量。将 StarBlock 引入 YOLOv8 的 C2f 模块，代替 C2f 中的 BottleNeck 模块，得到 C2f_Star 模块，结构如图 2 所示，C2f_Star 模块通过多个 StarBlock 对特征进行处理。

对于每一个 StarBlock，结构如图 3 所示，首先经过 1 个深度卷积，然后通过 2 个全连接层调整特征通道数，对得到的两组特征进行逐元素乘法，即星操作，将每个位置的特征与其对应位置的特征进行乘积，将特征映射到更高维的非线性空间，提升了特征的表达能力，之后通过后续层进一步处理。C2f_Star 模块在保持轻量化和低计算量的前提下，增强了模型对复杂特征的提取能力。

2.2 尺度序列特征融合


YOLOv8 的特征融合部分主要采用了 FPN (feature pyramid network) + PAN (path aggregation network) 结构^[27-28]，但这种结构不能有效地利用所有金字塔特征图之间的相关性，对于密集重叠的小物体，会忽略大尺度特征层中的详细信息，在捕捉猕猴桃花朵特征上存在局限性。为更好地利用多尺度特征图，采用 SSFF 模块增

强网络的多尺度信息提取能力, 采用 TFE 模块融合不同尺度的特征映射^[29], 增加特征信息。



注: Conv2d 表示二维卷积; Conv 表示卷积模块; Concat 表示特征融合; Detect 表示检测模块; BN 表示批量归一化; SiLU 表示 SiLU 激活函数; MaxPool 表示最大池化; Add 表示张量相加; SPPF 表示快速空间金字塔池化层; C2f_Star、SSFF、TFE 为合成模块。下同。
 Note: Conv2d represents two-dimensional convolution; Conv represents convolution module; Concat represents feature fusion; Detect represents detect block; BN represents batch normalization; SiLU represents the SiLU activation function; MaxPool represents maximum pooling; Add represents tensor addition; SPPF represents spatial pyramid pooling fast; C2f_Star, SSFF and TFE are synthesis modules. The same below.

图 1 YOLOv8-KFP 网络结构图
 Fig.1 Network structure diagram of YOLOv8-KFP




注: Split 表示特征图划分; StarBlock 为合成模块。
 Note: Split represents feature map partitioning; StarBlock is a synthesis module.

图 2 C2f_Star 结构图
 Fig.2 C2f_Star structure diagram

在 SSFF 模块中, 对从骨干网络中提取的不同层的输出特征图进行融合, 这些特征图捕获了猕猴桃花朵的各种大小、形状的不同空间尺度。首先, 以最大尺寸特征图为参考, 分别采用卷积核大小为 1×1 的卷积模块和上采样操作对其他更小尺寸特征图的特征通道数和图像尺寸进行调整。然后, 利用 Unsqueeze 方法增加一个新的尺度维度, 为后续三维卷积做准备。将来自不同尺度的特征图沿尺度维度堆叠, 用三维卷积学习它们之间的关系。这样做不仅融合了多尺度的信息, 还捕捉了各尺


度之间的上下文依赖关系, 输出更具表达力和适应性的特征图。之后, 依次经过三维批量归一化和 LeakyReLU 激活函数, 优化多尺度特征融合的效果, 提升模型的稳定性。



注: DW-Conv 表示深度卷积; FC 表示全连接; ReLU6 表示 ReLU6 激活函数; *表示乘运算。
 Note: DW-Conv represents depthwise convolution; FC represents fully connected; ReLU6 represents the ReLU6 activation function; *represents multiplication operation.

图 3 StarBlock 结构图
 Fig.3 StarBlock structure diagram

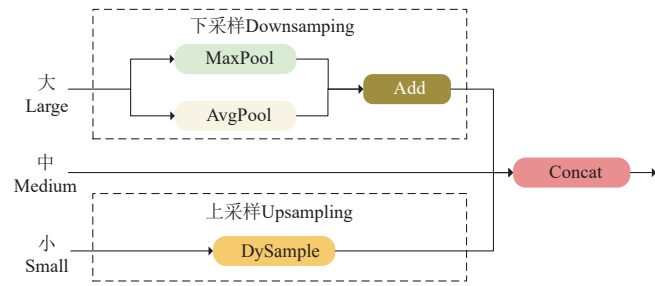
最后, 通过三维最大池化在不同尺度的特征堆叠上沿尺度维度取最大值, 完成多尺度信息的压缩, 并利用 Squeeze 方法移除冗余维度, 恢复成标准的四维特征图格式。SSFF 模块的特征融合过程如图 4 所示。



注：Upsampling 表示上采样；Unsqueeze 表示扩展维度；Stack 表示把多个张量在新的维度上堆叠，形成新的张量；3D Conv 表示三维卷积；3D BN 表示三维批量归一化；LeakyReLU 表示 LeakyReLU 激活函数；MaxPool3d 表示三维最大池化；Squeeze 表示压缩维度。
 Note: Upsampling represents upsampling; Unsqueeze represents expanding dimensions; Stack represents stacking multiple tensors along a new dimension to form a new tensor; 3D Conv represents 3D convolution; 3D BN represents 3D batch normalization; LeakyReLU represents LeakyReLU activation function; MaxPool3d represents 3D max pooling; Squeeze represents squeezing dimensions.

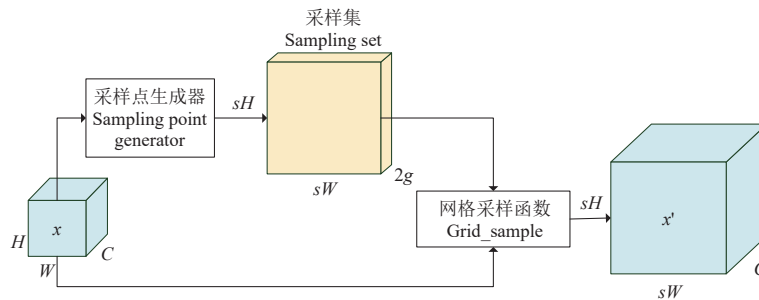
图 4 尺度序列特征融合过程
 Fig.4 Scale sequence feature fusion process

本文对 TFE 模块进行简化，结构如图 5 所示，对大尺寸特征图采用最大池化与平均池化的混合结构进行下采样，这有助于降低特征的空间维度并实现平移不变性，增强网络对输入图像的空间变化和和平移的鲁棒性。对小尺寸的特征图进行上采样操作，用于保留局部特征并防止小目标特征信息的丢失。最后，将已调整为相同尺寸三个维度的特征图进行拼接。



注：AvgPool 表示平均池化；DySample 表示 DySample 上采样器。
 Note: AvgPool represents average pooling; DySample represents DySample upsampler.

图 5 三重特征编码
 Fig.5 Triple feature encoder



注：x 表示输入的特征图；H、W、C 分别表示特征图的高度、宽度、通道数；s 表示上采样比例因子；sH、sW、2g 分别表示采样集的高度、宽度、通道数；x' 表示上采样后的特征图。下同。
 Note: x represents the input feature map; H, W, and C represent the height, width, and number of channels of the feature map; s represents the upsampling scale factor; sH, sW, and 2g represent the height, width, and number of channels of the sampling set; x' represents the upsampled feature map. The same below.

图 6 DySample 的上采样过程
 Fig.6 DySample upsampling process

采样点生成器结构如图 7 所示，以基于静态范围因子的采样方法为例，给定一个大小为 $C \times H \times W$ 的特征图 x 和一个上采样比例因子 s ， x 首先通过 1 个输入和输出通道分别为 C 和 $2gs^2$ 的线性层，接着乘以大小为 0.25 的静态范围因子，然后进行像素重组得到大小为 $2g \times sH \times sW$ 的偏移量 O 。最后，采样集 S 为偏移量 O 和原始采样网格 G 的总和，过程如式 (2) ~ (3) 所示：

$$O = 0.25\text{Linear}(x) \quad (2)$$

$$S = G + O \quad (3)$$

式中 Linear 表示线性层，0.25 是静态范围因子的大小。动态范围因子方法则使用两个线性层，一个线性层执行标准线性操作，另一个线性层后使用 0.5sigmoid 函数，将二者结果相乘来调整偏移，过程如式 (4) 所示。

2.3 DySample 上采样器

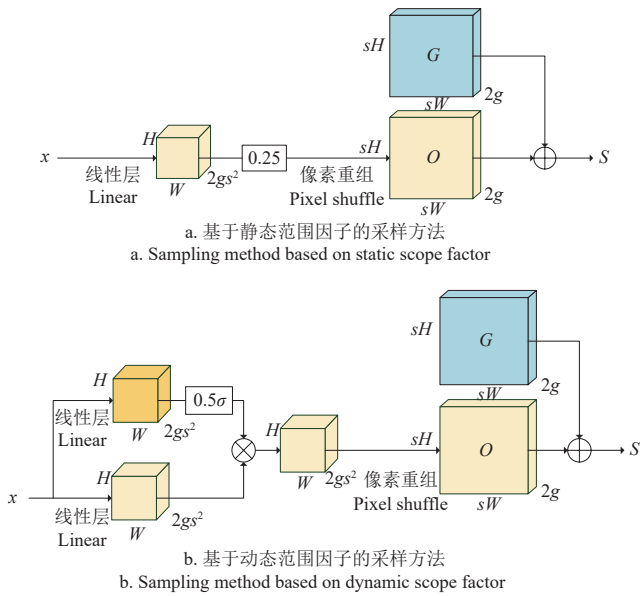
上采样操作在目标检测任务中起到关键作用^[30]，能够帮助模型更有效地识别目标、融合多尺度特征、保持空间位置精度等。最近邻插值的上采样方式会在目标边缘和细节区域产生不平滑的过渡，而且可能导致目标轮廓模糊，模型在定位和边界预测上难以达到高精度，影响检测性能。

DySample^[31] 是一种轻量级、高效的动态上采样器，旨在通过自适应采样点的位置来实现更精准的上采样。DySample 根据特征图中的内容动态调整采样位置，适应不同形状和边界的目标，提高上采样效果，特别适合猕猴桃花朵检测中存在的花朵密集的复杂场景。DySample 的上采样过程如图 6 所示。

给定一个大小为 $C \times H \times W$ 的特征图 x 和一个大小为 $2g \times sH \times sW$ 的采样集 S ，其中采样集由采样点生成器生成，Grid_sample 函数使用采样集 S 中的位置对 x 重新采样得到大小为 $C \times sH \times sW$ 的特征图 x' ，如式 (1) 所示。

$$x' = \text{Grid_sample}(x, S) \quad (1)$$

$$O = 0.5\text{sigmoid}(\text{Linear}_1(x)) \cdot \text{Linear}_2(x) \quad (4)$$



注: G 表示原始采样网格; O 表示偏移量; S 表示采样集; σ 表示 sigmoid 函数; $2gs^2$ 表示特征图通过线性层后的通道数。
Note: G represents original sampling grid; O represents offset; S represents sampling set; σ represents sigmoid function; $2gs^2$ represents the number of channels of the feature map after passing through the linear layer.

图 7 采样点生成器

Fig.7 Sampling point generator

2.4 Soft-NMS

在目标检测任务中, NMS (non-maximum suppression) 被用于去除冗余边界框, 其基本思想是在多个候选框中, 选择置信度最高的框并剔除与其重叠度 (intersection over union, IoU) 较大的框。在检测密集分布的花朵目标时检测框重叠度高, 传统 NMS 可能剔除掉一些真实目标的候选框。为了解决这些问题, YOLOv8-KFP 采用 Soft-NMS^[32] 算法对目标边界框进行后处理。Soft-NMS 的核心思想是通过调整候选框的置信度, 而不是直接剔除它们, 从而更有效地保留重叠目标。首先, Soft-NMS 会根据检测框的置信度得分对候选框进行降序排序并选定一个分数最高的预测框作为当前框。然后计算当前框与其他候选框之间的 IoU, 当候选框与当前框的 IoU 值较大时, 候选框的置信度根据高斯函数进行调整。最后保留置信度高的候选框。高斯函数计算如式 (5) 所示。

$$s_i = s_i e^{-\frac{\text{IoU}(M, b_i)^2}{\sigma}} \quad (5)$$

式中 s_i 表示候选框的置信度得分, IoU 表示两个框的交并比, M 表示置信度分数最高的当前框, b_i 表示候选框, σ 是控制衰减程度的超参数, 可以调整其值来控制重叠框的抑制程度。

2.5 模型训练与评价指标

2.5.1 训练平台及训练参数

本试验平台采用 Ubuntu 20.04.3 LTS 作为操作系统, CPU 和 GPU 分别为 Intel(R) Xeon(R) Gold 5318Y CPU @ 2.10 GHz 和 NVIDIA A40 (48 GB), 使用 Python3.11.11 编程语言、Cuda12.1 运算架构和 Pytorch2.2.2 深度学习

框架训练模型。

设置训练轮数为 300 轮, 初始学习率为 0.01, 批尺寸为 16, 动量系数为 0.937, 权重衰减系数为 0.0005。模型训练过程中, 加入图像平移与缩放、图像色彩增强、mosaic 数据增强、随机擦除等多种数据增强方法, 增强数据多样性, 以此提升模型的鲁棒性。

2.5.2 模型评价指标

本文在试验过程中采用精确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision, $\text{mAP}_{0.5}$)、参数量 (parameters)、浮点运算量 (floating point of operations, FLOPs) 和检测速度对模型进行全面、有效的评价。

2.5.3 模型训练

对模型进行训练, 训练过程中损失值变化曲线如图 8 所示。损失值包括用于衡量目标检测框回归效果的边界框损失和分布焦点损失, 以及用于衡量分类效果的分类损失。由图 8 可知, 随着训练轮数的不断增加, 损失值逐渐减小, 且没有出现拟合、欠拟合现象。在训练 200 个轮次后, 验证集上损失值趋于收敛, 模型训练表现良好, 可正常进行结果分析。

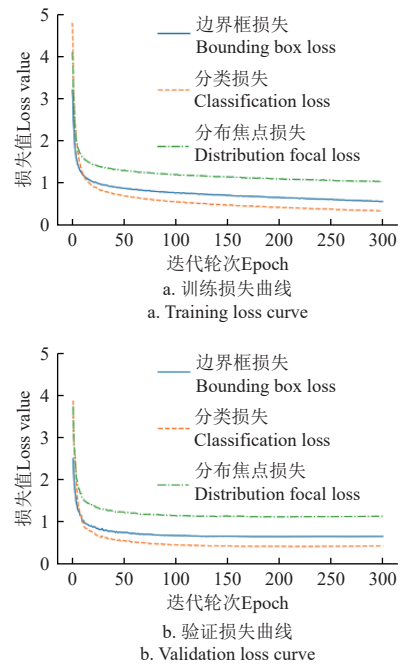


图 8 YOLOv8-KFP 损失函数变化曲线

Fig.8 Loss function variation curve of YOLOv8-KFP

3 结果与分析

3.1 消融试验

为了验证模型各模块对最终性能的贡献, 本文设计并进行消融试验。以 YOLOv8n 为基准, 通过逐步添加或改进模型中的关键模块, 分析它们对各个性能指标的影响, 从而评估模型的有效性。试验结果如表 1 所示。

由表 1 可知, 对 YOLOv8n 使用 Soft-NMS 进行后处理, 模型的精确率、召回率和平均精度均值分别提高了 0.1、0.5 和 0.2 个百分点, 表明了 Soft-NMS 相较于传统

NMS 在密集分布猕猴桃花期检测任务上的有效性。在此基础上对单独引入各个模块的性能进行分析。引入 C2f_Star 模块后, 模型的精确率、召回率和平均精度均值分别提高了 2.5、2.2 和 1.8 个百分点, 浮点运算量和参数量分别降低至 7.2 G 和 2.60 M。这表明 C2f_Star 模块在提高检测性能的同时, 降低了模型复杂度。引入 SSFF+TFE 模块后, 模型的精确率、召回率和平均精度均值分别提高了 3.5、2.9 和 2.6 个百分点。性能的显著提升验证了尺度序列特征融合在多尺度信息提取能力上的优越性。引入 DySample 模块后, 模型的精确率、召回率和平均精度均值分别提高了 2.9、2.6 和 2.1 个百分点, 证明其在猕猴桃花期复杂场景中出色的动态上采样能力。在每一个单项模块改进的基础上, 分别进行组合, 进一步评估模块间的协同效果。可以发现, 在 4 种优化方法联合引入后, 本文提出的 YOLOv8-KFP 模型性能达到最优, 相比 YOLOv8n 其精确率、召回率和平均精度均值分别提高了 4.9、5.1 和 3.8 个百分点, 同时浮点运算量和参数量分别降低 6.2% 和 11.6%, 表明改进后模型实现了检测性能、参数量、浮点运算量的平衡优化。

表 1 消融试验

Table 1 Ablation experiments

Soft-NMS	C2f_Star	SSFF+TFE	DySample	P/ %	R/ %	mAP _{0.5} / %	FLOPs/ G	参数量 Parameters/M
-	-	-	-	84.2	83.6	88.6	8.1	3.01
√	-	-	-	84.3	84.1	88.8	8.1	3.01
√	√	-	-	86.8	86.3	90.6	7.2	2.60
√	-	√	-	87.8	87.0	91.4	8.5	3.05
√	-	-	√	87.2	86.7	90.9	8.1	3.02
√	√	√	-	88.0	87.5	92.0	7.6	2.64
√	√	-	√	87.9	87.2	91.5	7.2	2.61
√	-	√	√	88.4	88.0	92.1	8.5	3.06
√	√	√	√	89.1	88.7	92.4	7.6	2.66

注：“-”表示不采用该模块；“√”表示采用该模块；P 为精确率；R 为召回率；mAP_{0.5} 表示 IoU 阈值为 0.5 时的平均精度均值；FLOPs 为浮点运算量。下同。

Note: “-” represents that the module is not used; “√” represents that the module is used; P represents precision; R represents recall; mAP_{0.5} represents the mean average precision when the IoU threshold is set to 0.5; FLOPs represents the number of floating point operations. The same below.

3.2 颈部网络改进对比

目标检测的颈部网络通过结合不同尺度的特征图, 提升了对多尺度物体的检测能力, 对于增强模型对细节特征的捕捉能力至关重要。为了评估 SSFF+TFE 模块改进颈部网络的性能表现, 采用主流颈部网络改进方法 BiFPN^[33]、Slim-Neck^[34]、RepGFPN^[35]、HS-FPN^[36] 对 YOLOv8n 进行改进, 对 YOLOv8n 和采用各个方法改进后的模型进行对比, 试验结果如表 2 所示。

表 2 颈部网络改进对比

Table 2 Comparison of neck network improvement

模型 Model	P/%	R/%	mAP _{0.5} /%
YOLOv8n	84.2	83.6	88.6
YOLOv8n-BiFPN	84.1	84.7	89.2
YOLOv8n-SlimNeck	83.8	82.4	88.0
YOLOv8n-HSFPN	82.5	83.2	87.9
YOLOv8n-RepGFPN	86.0	84.7	90.3
YOLOv8n-SSFF+TFE	87.5	86.7	91.2

由表 2 可知, 采用 SSFF+TFE 模块改进后的

YOLOv8n 的精确率、召回率和平均精度均值分别为 87.5%、86.7% 和 91.2%, 检测效果最好, 说明其有效提升了猕猴桃花期检测精度。

3.3 对比试验

为了进一步验证 YOLOv8-KFP 模型在猕猴桃花期检测任务中的性能, 本文选取经典目标检测模型 SSD^[37]、YOLOv5n、YOLOv6n^[38], 以及先进目标检测模型 YOLOv8n、YOLOv8s、RT-DETR-r18^[39]、YOLOv9t^[40]、YOLOv10n^[41]、YOLOv11n、YOLOv12n^[42] 进行对比, 在相同数据集上采用相同的训练方式进行训练和测试, 结果如表 3 所示。

表 3 对比试验

Table 3 Comparative experiments

模型 Model	P/%	R/%	mAP _{0.5} /%	FLOPs/G	参数量 Parameters/ M	检测速度 Detection speed/(帧·s ⁻¹)
SSD	81.8	78.5	85.4	274.5	24.01	61.53
YOLOv5n	84.1	82.1	87.8	7.1	2.50	126.08
YOLOv6n	82.3	83.0	88.0	11.8	4.23	138.41
YOLOv8n	84.2	83.6	88.6	8.1	3.01	134.19
YOLOv8s	84.8	85.1	89.7	28.4	11.13	131.55
RT-DETR-r18	86.2	85.9	88.0	57.0	19.88	50.41
YOLOv9t	84.0	83.2	88.4	7.6	1.97	65.84
YOLOv10n	83.7	82.3	86.9	8.2	2.70	101.68
YOLOv11n	82.1	85.5	88.2	6.3	2.58	102.44
YOLOv12n	84.0	83.9	88.3	5.8	2.51	74.04
YOLOv8-KFP	89.1	88.7	92.4	7.6	2.66	83.68

由表 3 可知, YOLOv8-KFP 模型的精确率、召回率和平均精度均值分别为 89.1%、88.7% 和 92.4%, 均为所有模型中最高。与 SSD、YOLOv9t、YOLOv10n、YOLOv11n 和 YOLOv12n 相比, YOLOv8-KFP 模型的平均精度均值分别提高了 7.0、4.0、5.5、4.2 和 4.1 个百分点。此外, YOLOv8-KFP 模型的浮点运算量和参数量分别为 7.6 G 和 2.66 M。与 SSD、YOLOv6n、YOLOv8s 和 RT-DETR-r18 相比, YOLOv8-KFP 模型的浮点运算量分别降低了 97.2%、35.6%、73.2% 和 86.7%; 参数量分别降低了 88.9%、37.1%、76.1% 和 86.6%。在检测速度上, YOLOv8-KFP 模型达到 83.68 帧/s, 相比 SSD、RT-DETR-r18、YOLOv9t、YOLOv12n 分别提高了 36.0%、66.0%、27.1% 和 13.0%。综合来看, YOLOv8-KFP 模型较好平衡了检测性能、计算复杂度和实时性, 能够满足猕猴桃花期检测在实际应用中的高精度与高效率需求。

为了验证 YOLOv8-KFP 模型在其他品种猕猴桃花期检测任务上的性能, 本文从 LI 等^[43] 采集的图像中筛选出 300 张原始图像, 制作“徐香”品种猕猴桃花期图像数据集进行泛化试验, 结果如表 4 所示。

表 4 泛化试验

Table 4 Generalization experiments

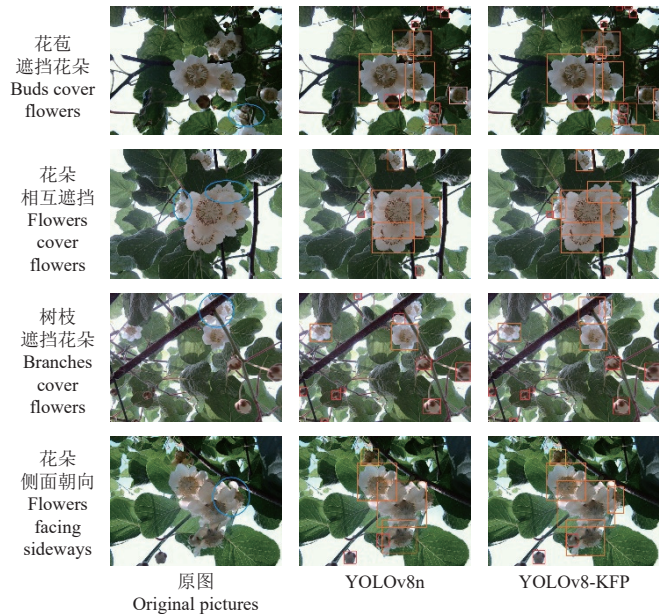
模型 Model	P/%	R/%	mAP _{0.5} /%
YOLOv8n	82.9	82.4	87.0
YOLOv9t	82.5	82.3	86.7
YOLOv10n	81.6	80.0	85.5
YOLOv11n	81.2	83.4	86.0
YOLOv12n	82.7	80.7	86.4
YOLOv8-KFP	84.1	83.5	88.8

由表 4 可知, 在“徐香”品种猕猴桃花期检测任务

中 YOLOv8-KFP 相较于 YOLOv8n 精确率、召回率和平均精度均值分别提高了 1.2、1.1 和 1.8 个百分点, 改进效果有效。与先进目标检测模型 YOLOv9t、YOLOv10n、YOLOv11n 和 YOLOv12n 对比, YOLOv8-KFP 的平均精度均值分别提高了 2.1、3.3、2.8 和 2.4 个百分点, 体现出 YOLOv8-KFP 良好的泛化能力。

3.4 密集分布花朵检测效果分析

为了更加直观地验证改进效果, 本文对密集分布猕猴桃花朵的检测效果进行分析, 图 9 展示了 YOLOv8n 和 YOLOv8-KFP 在不同场景下的检测框和预测结果。



注: 蓝圈内是漏检或误检的花朵, 红色检测框对应花苞期, 粉色检测框对应半开期, 橙色检测框对应全开期, 黄色检测框对应凋落期。下同。
Note: The flowers in the blue circle are missed or incorrectly detected, The red detection box corresponds to the bud stage, the pink detection box corresponds to the half open stage, the orange detection box corresponds to the full open stage, and the yellow detection box corresponds to the withering stage. The same below.

图 9 改进前后密集分布花朵检测效果

Fig.9 Detection performance for densely distributed flowers before and after improvement

由图 9 可知, 在花苞遮挡花朵方面, 对于被 2 个花苞期花朵遮挡住的全开期花朵, YOLOv8n 出现漏检, 而 YOLOv8-KFP 正确检测。在花朵相互遮挡方面, YOLOv8-KFP 相比 YOLOv8n 多检测出 2 个全开期花朵。在树枝遮挡花朵方面, 对于被树枝遮挡的全开期花朵和半开期花朵, YOLOv8n 将其误检为 1 个花苞期花朵, 而 YOLOv8-KFP 均能正确检测。在花朵侧面朝向方面, YOLOv8n 出现漏检, 而 YOLOv8-KFP 正确检测。因此, YOLOv8-KFP 在多种密集分布场景下相较于 YOLOv8n 减少了误检和漏检的情况, 表现出更加全面的检测性能。

3.5 不同花期检测效果分析

处于不同花期的猕猴桃花朵时会受到尺度、形态、相似特征等因素的影响, 出现误检现象。本文对不同花期花朵的检测效果进行分析, 图 10 展示了 YOLOv8n 和 YOLOv8-KFP 对不同花期花朵的检测框和预测结果。

由图 10 可知, 在混淆全开期和半开期方面, 部分花

朵受开放角度影响, 难以完整呈现花瓣张开幅度, YOLOv8n 将 2 朵全开期花朵误检为半开期, YOLOv8-KFP 均能正确检测。在混淆半开期和全开期方面, YOLOv8n 将 1 朵半开期花朵误检为全开期, YOLOv8-KFP 检测正确。在混淆半开期和花苞期方面, 1 朵处于半开期的猕猴桃花朵尚未完全绽放, 花瓣包裹性较强, YOLOv8n 将其误检为花苞期花朵, YOLOv8-KFP 检测正确。YOLOv8n 还存在将凋落期花朵混淆为半开期的情况, YOLOv8-KFP 则能正确检测, 展现出更强的花期判别能力。

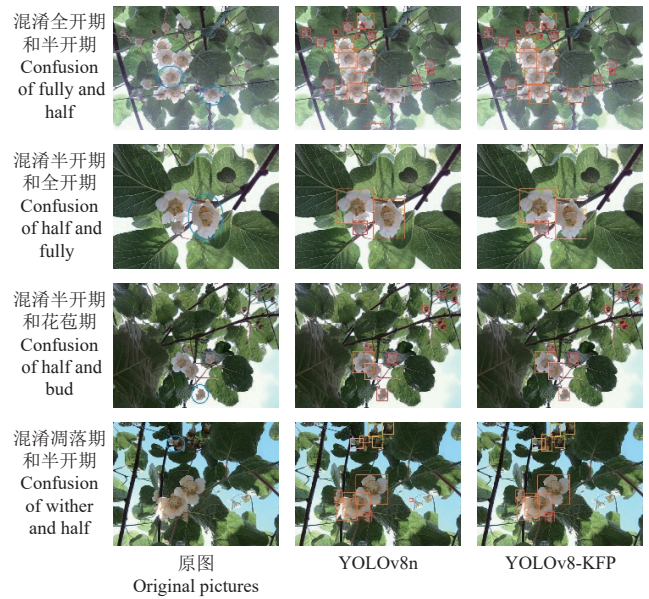


图 10 改进前后不同花期检测效果

Fig.10 Detection performance for different flowering periods before and after improvement

3.6 不同花期误检分析

为了验证花期误检的具体分布, 分析花期混淆情况, 采用 YOLOv8-KFP 的归一化混淆矩阵进行评估。如图 11 所示, 矩阵中的数值表示属于横坐标对应类别的所有真实样本中, 有多少比例被预测为纵坐标对应类别, 矩阵从左上到右下的对角线上的数值, 为对应类别真实样本中正确预测的比例, 即召回率。

预测标签 Predicted label	花苞期 Bud	半开期 Half	全开期 Fully	凋落期 Wither	背景 Background
花苞期 Bud	90.8%	3.6%	0.1%	1.5%	27.3%
半开期 Half	2.4%	85.9%	4.7%	1.0%	20.6%
全开期 Fully	0.1%	5.0%	90.0%	1.9%	22.2%
凋落期 Wither	1.0%	1.0%	1.1%	88.1%	29.9%
背景 Background	5.7%	4.5%	4.1%	7.5%	

真实标签
True label

图 11 不同花期混淆矩阵

Fig.11 Confusion matrix for different flowering periods

YOLOv8-KFP 在花苞期、半开期、全开期和凋落期上的召回率分别为 90.8%、85.9%、90.0% 和 88.1%。半开期正确预测的比例相对较低, 5.0% 的半开期花朵被预测为全开期花朵, 3.6% 的半开期花朵被预测为花苞期花朵。此外, 2.4% 的花苞期花朵被预测为半开期花朵, 4.7% 的全开期花朵被预测为半开期花朵。因此, YOLOv8-KFP 对花期的混淆主要发生在花苞期与半开期、半开期与全开期, 且错误预测比例最高不超过 5.0%。同时, YOLOv8-KFP 在其他花期间的错误预测比例均在 2.0% 以下, 体现了其对不同花期良好的区分能力。

4 结 论

针对自然环境中不同花期的猕猴桃花朵形态多样、花朵之间存在相互遮挡的问题, 本研究基于 YOLOv8n 模型进行改进, 提出了一种兼顾检测性能和模型轻量的密集分布猕猴桃花期检测模型 YOLOv8-KFP, 并得到以下结论:

1) 通过采用 StarNet 中的 StarBlock 改进 YOLOv8n 的 C2f, 引入星操作, 减小模型的参数量。采用 SSFF (scale sequence feature fusion) 模块与 TFE (triple feature encoder) 模块对 YOLOv8n 的颈部网络进行改进, 提升模型利用多尺度特征的能力。采用 DySample 上采样器改进上采样过程, 进一步提升检测性能。采用 SoftNMS 进行后处理, 减少重叠目标候选框的误删。改进后的 YOLOv8-KFP 相比 YOLOv8n 其精确率、召回率和平均精度均值分别提高了 4.9、5.1 和 3.8 个百分点, 同时浮点运算量和参数量分别降低 6.2% 和 11.6%。

2) 将改进的 YOLOv8-KFP 模型与 SSD、YOLOv5n、YOLOv6n、YOLOv8n、YOLOv8s、RT-DETR-r18、YOLOv9t、YOLOv10n、YOLOv11n、YOLOv12n 等目标检测模型进行对比, YOLOv8-KFP 模型的精确率、召回率和平均精度均值达到 89.1%、88.7% 和 92.4%, 均领先于其他模型。同时, YOLOv8-KFP 模型的浮点运算量为 7.6 G, 参数量为 2.66 M, 检测速度为 83.68 帧/s, 这表明本文方法 YOLOv8-KFP 在提高检测精度的同时, 能够兼顾浮点运算量、参数量等轻量化评价指标, 得到综合的性能提升以满足实际应用。

3) 采用 YOLOv8-KFP 的归一化混淆矩阵进行花期误检分析, 其在花苞期、半开期、全开期和凋落期上的召回率分别为 90.8%、85.9%、90.0% 和 88.1%, 且易混淆类别间的错误预测比例最高不超过 5.0%, 表明 YOLOv8-KFP 在区分不同花期花朵方面的良好性能。

【参 考 文 献】

[1] 潘时佳, 吴津乐, 程梅, 等. 基于改进 CNN 的猕猴桃根区土壤含水率反演方法[J]. *农业工程学报*, 2024, 40(11): 85-91. PAN Shijia, WU Jinle, CHENG Mei, et al. Inversion method for root soil water content using improved CNN[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(11): 85-91. (in Chinese with English abstract)

[2] SUN J Y, WANG D X, XIAO X T, et al. Study of pollen deposition performance of an airflow-assisted targeted

pollinating device for kiwi fruit flower[J]. *Biosystems Engineering*, 2025, 251: 31-47.

[3] NICHOLSON C C, EGAN P A. Natural hazard threats to pollinators and pollination[J]. *Global Change Biology*, 2020, 26(2): 380-391.

[4] CASTRO H, SIOPA C, CASAIS V, et al. Pollination as a key management tool in crop production: Kiwifruit orchards as a study case[J]. *Scientia Horticulturae*, 2021, 290: 110533.

[5] 胡淑芬, 曹昕奕, 邓勇杰, 等. 植保无人机飞行参数对油茶授粉雾滴分布及坐果率的影响[J]. *农业工程学报*, 2023, 39(20): 92-100. HU Shufen, CAO Xinyi, DENG Yongjie, et al. Effects of the flight parameters of plant protection drone on the distribution of pollination droplets and the fruit setting rate of camellia[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2023, 39(20): 92-100. (in Chinese with English abstract)

[6] 丁素明, 薛新宇, 方金豹, 等. 手持式风送授粉机工作参数优化与试验[J]. *农业工程学报*, 2015, 31(8): 68-75. DING Suming, XUE Xinyu, FANG Jinbao, et al. Parameter optimization and experiment of air-assisted pollination device[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2015, 31(8): 68-75. (in Chinese with English abstract)

[7] YEPEZ-PONCE D F, SALCEDO J V, ROSEROMONTALVO P D, et al. Mobile robotics in smart farming: Current trends and applications[J]. *Frontiers in Artificial Intelligence*, 2023, 6: 1213330.

[8] 岑海燕, 朱月明, 孙大伟, 等. 深度学习在植物表型研究中的应用现状与展望[J]. *农业工程学报*, 2020, 36(9): 1-16. CEN Haiyan, ZHU Yueming, SUN Dawei, et al. Current status and future perspective of the application of deep learning in plant phenotype research[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2020, 36(9): 1-16. (in Chinese with English abstract)

[9] GAO C, HE L, FANG W, et al. A novel pollination robot for kiwifruit flower based on preferential flowers selection and precisely target[J]. *Computers and Electronics in Agriculture*, 2023, 207: 107762.

[10] 郭庆梅, 刘宁波, 王中训, 等. 基于深度学习的目标检测算法综述[J]. *探测与控制学报*, 2023, 45(6): 10-20. GUO Qingmei, LIU Ningbo, WANG Zhongxun, et al. Review of deep learning based object detection algorithms[J]. *Journal of Detection & Control*, 2023, 45(6): 10-20. (in Chinese with English abstract)

[11] 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. Las Vegas, NV, USA: IEEE, 2016: 779-788.

[12] 尚钰莹, 张倩如, 宋怀波. 基于 YOLOv5s 的深度学习在自然场景苹果花朵检测中的应用[J]. *农业工程学报*, 2022, 38(9): 222-229. SHANG Yuying, ZHANG Qianru, SONG Huaibo. Application of deep learning using YOLOv5s to apple flower detection in natural scenes[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(9): 222-229. (in Chinese with English abstract)

[13] 吴利刚, 陈乐, 刘泽鹏, 等. 基于 YOLOv8-ABW 的黄花成熟度检测方法[J]. *农业工程学报*, 2024, 40(13): 262-272. WU Ligang, CHEN Le, LIU Zepeng, et al. YOLOv8-ABW based method for detecting *Hemerocallis citrina* Baroni maturity[J]. *Transactions of the Chinese Society of*

- [Agricultural Engineering \(Transactions of the CSAE\)](#), 2024, 40(13): 262-272. (in Chinese with English abstract)
- [14] BAI Y, YU J, YANG S, et al. An improved YOLO algorithm for detecting flowers and fruits on strawberry seedlings[J]. [Biosystems Engineering](#), 2024, 237: 1-12.
- [15] 陈金荣, 许燕, 周建平, 等. 基于 YOLO-SSAR 的自然环境下红花检测算法[J]. [农业工程学报](#), 2025, 41(2): 215-223. CHEN Jinrong, XU Yan, ZHOU Jianping, et al. Detecting safflower in the natural environment using YOLO-SSAR[J]. [Transactions of the Chinese Society of Agricultural Engineering \(Transactions of the CSAE\)](#), 2025, 41(2): 215-223. (in Chinese with English abstract)
- [16] 张秀花, 魏华杰, 孔德刚, 等. 自然环境下基于改进 YOLOv7 的梨花识别方法[J]. [农业工程学报](#), 2025, 41(2): 224-232. ZHANG Xiuhua, WEI Huajie, KONG Degang, et al. Recognizing pear blossom in the natural environment using improved YOLOv7[J]. [Transactions of the Chinese Society of Agricultural Engineering \(Transactions of the CSAE\)](#), 2025, 41(2): 224-232. (in Chinese with English abstract)
- [17] 张新月, 胡广锐, 李浦航, 等. 基于改进 YOLOv8n 的轻量化红花识别方法[J]. [农业工程学报](#), 2024, 40(13): 163-170. ZHANG Xinyue, HU Guangrui, LI Puhang, et al. Recognizing safflower using improved lightweight YOLOv8n[J]. [Transactions of the Chinese Society of Agricultural Engineering \(Transactions of the CSAE\)](#), 2024, 40(13): 163-170. (in Chinese with English abstract)
- [18] 任洋. 猕猴桃靶向喷雾授粉参数研究与控制系统设计[D]. 成都: 西华大学, 2023. REN Yang. Research on Targeted Spray Pollination Parameters of Kiwifruit and Controlsystem Design[D]. Chengdu: Xihua University, 2023. (in Chinese with English abstract)
- [19] 龚惟新, 杨珍, 李凯, 等. 基于改进 YOLOv5s 的自然环境下猕猴桃花朵检测方法[J]. [农业工程学报](#), 2023, 39(6): 177-185. GONG Weixin, YANG Zhen, LI Kai, et al. Detecting kiwi flowers in natural environments using an improved YOLOv5s[J]. [Transactions of the Chinese Society of Agricultural Engineering \(Transactions of the CSAE\)](#), 2023, 39(6): 177-185. (in Chinese with English abstract)
- [20] 杜金芝, 李书琴. 基于改进 GAN 的猕猴桃低光照花朵图像增强模型[J]. [农业工程学报](#), 2024, 40(24): 165-171. DU Jinzhi, LI Shuqin. Model for enhancing low-light kiwifruit flower images based on improved GAN[J]. [Transactions of the Chinese Society of Agricultural Engineering \(Transactions of the CSAE\)](#), 2024, 40(24): 165-171. (in Chinese with English abstract)
- [21] 石复习, 蒋宗谨, 马驰, 等. 双流体喷嘴靶向授粉沉积量控制参数研究[J]. [农业机械学报](#), 2019, 50(12): 115-124. SHI Fuxi, JIANG Zongjin, MA Chi, et al. Controlled parameters of targeted pollination deposition by air-liquid nozzle[J]. [Transactions of the Chinese Society for Agricultural Machinery](#), 2019, 50(12): 115-124. (in Chinese with English abstract)
- [22] 张雨娜, 王茸茸, 张九东, 等. 毛花猕猴桃雌雄花的形态特征比较与杂交授粉研究[J]. [陕西农业科学](#), 2024, 70(2): 23-27. ZHANG Yuna, WANG Rongrong, ZHANG Jiudong, et al. Morphological characteristics comparison of actinidia eriantha female and male flowers and their cross pollination[J]. [Shaanxi Journal of Agricultural Sciences](#), 2024, 70(2): 23-27. (in Chinese with English abstract)
- [23] 龚惟新. 果园不同花期猕猴桃花朵的识别与开放朝向估测研究[D]. 杨凌: 西北农林科技大学, 2024. GONG Weixin. Identification of Kiwifruit Flowers at Different Flowering Stages and Estimation of Blooming Orientation in Orchards[D]. Yangling: Northwest A&F University, 2024. (in Chinese with English abstract)
- [24] 岳凯, 张鹏超, 王磊, 等. 基于改进 YOLOv8n 的复杂环境下柑橘识别[J]. [农业工程学报](#), 2024, 40(8): 152-158. YUE Kai, ZHANG Pengchao, WANG Lei, et al. Recognizing citrus in complex environment using improved YOLOv8n[J]. [Transactions of the Chinese Society of Agricultural Engineering \(Transactions of the CSAE\)](#), 2024, 40(8): 152-158. (in Chinese with English abstract)
- [25] 蔡舒平, 孙仲鸣, 刘慧, 等. 基于改进型 YOLOv4 的果园障碍物实时检测方法[J]. [农业工程学报](#), 2021, 37(2): 36-43. CAI Shuping, SUN Zhongming, LIU Hui, et al. Real-time detection methodology for obstacles in orchards using improved YOLOv4[J]. [Transactions of the Chinese Society of Agricultural Engineering \(Transactions of the CSAE\)](#), 2021, 37(2): 36-43. (in Chinese with English abstract)
- [26] MA X, DAI X, BAI Y, et al. Rewrite the stars[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE, 2024: 5694-5703.
- [27] LIN T, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 2117-2125.
- [28] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 8759-8768.
- [29] KANG M, TING C, TING F F, et al. ASF-YOLO: A novel YOLO model with attentional scale sequence fusion for cell instance segmentation[J]. [Image and Vision Computing](#), 2024, 147: 105057.
- [30] 范天浩, 顾寄南, 王文波, 等. 基于改进 YOLOv5s 的轻量化金银花识别方法[J]. [农业工程学报](#), 2023, 39(11): 192-200. FAN Tianhao, GU Jinan, WANG Wenbo, et al. Lightweight honeysuckle recognition method based on improved YOLOv5s[J]. [Transactions of the Chinese Society of Agricultural Engineering \(Transactions of the CSAE\)](#), 2023, 39(11): 192-200. (in Chinese with English abstract)
- [31] LIU W, LU H, FU H, et al. Learning to upsample by learning to sample[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE, 2023: 6027-6037.
- [32] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS--improving object detection with one line of code[C]// Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 5561-5569.
- [33] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE, 2020: 10781-10790.
- [34] 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.
- [35] XU X, JIANG Y, CHEN W, et al. Damo-yolo: A report on real-time object detection design[EB/OL]. (2023-04-24)[2025-02-07]. <https://arxiv.org/abs/2211.15444>.

- [36] CHEN Y, ZHANG C, CHEN B, et al. Accurate leukocyte detection based on deformable-DETR and multi-level feature fusion for aiding diagnosis of blood diseases[J]. *Computers in Biology and Medicine*, 2024, 170: 107917.
- [37] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector[C]// *Computer Vision—ECCV 2016: 14th European Conference*. Amsterdam, The Netherlands: Springer, 2016: 21-37.
- [38] LI C, LI L, JIANG H, et al. YOLOv6: A single-stage object detection framework for industrial applications[EB/OL]. (2022-09-07)[2025-02-07]. <https://arxiv.org/abs/2209.02976>.
- [39] ZHAO Y, LV W, XU S, et al. Detsr beat yolos on real-time object detection[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, WA, USA: IEEE, 2024: 16965-16974.
- [40] WANG C, YEH I, MARK LIAO H. YOLOv9: Learning what you want to learn using programmable gradient information[C]// *European Conference on Computer Vision*. Milan, Italy: Springer, 2024: 1-21.
- [41] WANG A, CHEN H, LIU L, et al. Yolov10: Real-time end-to-end object detection[J]. *Advances in Neural Information Processing Systems*, 2024, 37: 107984-108011.
- [42] TIAN Y, YE Q, DOERMANN D. Yolov12: Attention-centric real-time object detectors[EB/OL]. (2025-02-18)[2025-03-20]. <http://arxiv.org/abs/2502.12524>.
- [43] LI G, FU L, GAO C, et al. Multi-class detection of kiwifruit flower and its distribution identification in orchard based on YOLOv5l and Euclidean distance[J]. *Computers and Electronics in Agriculture*, 2022, 201: 107342.

Method for detecting densely distributed kiwifruit flowering period based on improved YOLOv8n

LIU Jianjiang , LI Shuqin*

(College of Information Engineering, Northwest A & F University, Yangling 712100, China)

Abstract: In order to solve the problem of difficult detection caused by the heavy occlusion and overlap of kiwifruit flowers at different flowering periods, this study proposes YOLOv8-KFP, a densely distributed kiwifruit flowering period detection model based on improved YOLOv8n. Firstly, taking the lightweight YOLOv8n as the benchmark model, StarBlock is used to improve the C2f of YOLOv8n, and the "Star operation" is used to enhance the ability of feature expression, so as to reduce the amount of model parameters and calculation and improve the ability of feature extraction. Secondly, the scale sequence feature fusion (SSFF) module and the triple feature encoder (TFE) module are introduced into the neck network to fuse the feature maps of different scales, so as to enhance the ability of the model to capture the multi-scale details and alleviate the problem of false detection and missing detection of blocked and overlapping kiwifruit flowers; The DySample upsampler is used to replace the traditional interpolation method to dynamically adapt to flower targets with different scales, shapes and boundaries, alleviate the fuzzy problem of dense flower edges, and improve the target positioning accuracy. Finally, the Soft-NMS post-processing algorithm is introduced to further optimize the detection effect of dense targets by adjusting the confidence of overlapping candidate boxes to reduce false deletion. 3 853 images of kiwifruit flowers densely distributed under natural conditions were collected and labeled according to the bud stage, half open stage, full open stage and withering stage. Combined with a variety of data enhancement strategies, 300 epochs of iterative training were completed on NVIDIA A40 GPU platform. Ablation experiments show that the use of C2f_Star module to improve the backbone network, the introduction of SSFF module and TFE module to improve the neck network, the use of DySample upsampler, and the use of Soft-NMS post-processing algorithm can respectively improve the performance of the model to a certain extent, and the improved module has a significant synergy. The final model achieved the precision (P) of 89.1%, the recall (R) of 88.7%, and the mean average precision (mAP) of 92.4% at an intersection over union (IoU) ratio of 0.5, while reducing the number of parameters and floating point of operations (FLOPs) to 2.66 M and 7.6 G, respectively. The improvement effect of the feature fusion network using SSFF module and TFE module and various feature fusion networks such as BiFPN, Slim-Neck, RepGFPN, HS-FPN on YOLOv8n were compared. The YOLOv8n using SSFF module and TFE module to improve the feature fusion network achieved the best effect in precision, recall and $mAP_{0.5}$, showing its excellent performance in multi-scale feature fusion of kiwifruit flowers. Compared with the mainstream lightweight target detection models SSD, YOLOv9t, YOLOv10n, YOLOv11n and YOLOv12n, the $mAP_{0.5}$ of YOLOv8-KFP is increased by 7.0, 4.0, 5.5, 4.2 and 4.1 percentage points respectively. Compared with the more complex YOLOv8s, YOLOv8-KFP is increased by 2.7 percentage points on $mAP_{0.5}$, the amount of FLOPs is reduced by 73.2%, and the amount of parameters is reduced by 76.1%, giving good consideration to the detection accuracy and the lightweight of the model. Moreover, the visualization results show that the improved model significantly reduces the missed detection rate in complex scenes such as branches and leaves occlusion and flowers occlusion, and can more accurately distinguish flower targets in different flowering periods, and has stronger robustness in the densely distributed kiwifruit flowering period detection task. The research results provide a high-precision and lightweight detection method reference for kiwifruit intelligent pollination robot, and have practical application value for improving the level of orchard automation management.

Keywords: deep learning; object detection; model; YOLOv8n; kiwifruit flowering period; multi-scale feature fusion