刘力源,张学林,陈洪,等.基于YOLOv11-FS模型的柑橘花粉活力检测[J].华中农业大学学报,2026,45(3):77-86.
DOI:10.13300/j.cnki.hnlkxb.2026.03.007

基于YOLOv11-FS模型的柑橘花粉活力检测

刘力源[1],张学林[1],陈洪[1],李伟夫[1],廖健华[2],解凯东[2],伍小萌[2],郭文武[2],陈耀晖[3]

1.华中农业大学信息学院,武汉 430070; 2.果蔬园艺作物种质创新与利用全国重点实验室,武汉 430070;
3.华中农业大学工学院,武汉 430070

摘要 为促进无核柑橘品种培育、满足高品质柑橘生产需求,提出一种新的花粉活力检测模型YOLOv11-FS。通过人工采集和专家标注的方式,构建了适用于花粉活力检测的数据集,改进了YOLOv11深度神经网络;检测过程中,采用Focal-EIOU损失函数替换YOLOv11的EIOU损失,改善对不均衡样本的检测性能,结合Soft-NMS提升检测框精度,克服柑橘花粉颗粒抱团明显、体积较小且背景复杂等挑战。结果显示,改进的YOLOv11-FS模型在花粉检测任务方面表现优秀,预测的花粉活力与真实的花粉活力误差仅为0.70百分点,可育花粉和不可育花粉检测的召回率、精确率和F_1-score分别达98.76%、99.67%、99.22%和94.87%、98.89%、96.84%,满足花粉活力检测基本需求。以上结果表明,该检测方法可实现柑橘花粉活力的高效、精准识别。

关键词 柑橘;花粉活力检测;YOLOv11-FS;Soft-NMS;Focal-EIOU损失
中图分类号 TP391.4;S666 **文献标识码** A **文章编号** 1000-2421(2026)03-0077-10

柑橘是全球种植与消费规模最大的水果品类,含有丰富的维生素C、膳食纤维,以及具有保健功效的类黄酮、类胡萝卜素等多种营养成分,因此,柑橘鲜果及其加工制品(如果汁、果脯等)在世界范围内备受青睐,拥有庞大的消费群体。我国作为全球柑橘生产大国,柑橘产业在我国南方地区广泛分布,是极具经济价值的农作物之一[1-2]。

在经济高速发展、社会不断进步以及人民生活水平不断提高的当下,大众对于水果这一生活必需品的品质追求和种类需求越来越高。因此,不断培育高品质的柑橘新品种是满足市场对柑橘品种多样性和果实品质高要求的关键举措。其中,无核(或少核)特性是衡量柑橘品质优良的重要指标之一,也是长期以来我国柑橘育种工作重点关注的目标[3]。值得注意的是,大多数柑橘品种具有一定程度的单性结实能力,即便果实中缺乏种子,依然能够正常发育成熟,这一独特特性为雄性不育柑橘品种实现无核果实的形成提供了坚实的生理条件[4-6]。

雄性不育是指雄蕊(花药)发育异常,不能产生有正常生活力花粉的现象[7]。因此统计花粉活力是培育无核柑橘的重要一环[8]。花粉活力的估算可通过计算整体花粉中可育花粉与不可育花粉的比例来实现。然而,传统的以人工标注和计数方式估算花粉活力的方法,存在耗时久、操作繁杂以及成本高昂等弊端。显然,这项任务是一项费力、耗时的活动,需要熟练的技术人员参与。然而,人工标注的结果不容易统一,Escriche等[9]研究发现,几个经过认证的花粉分析实验室针对相同的蜂蜜样本给出了不同的检测结果。该方法易受技术人员主观因素影响,其原因包括快速出具结果的压力、长时间进行图像分析导致的疲劳,以及区分花粉与众多植物物种所面临的困难。因此,开发一个自动检测花粉活力的程序具有重大意义。近些年来,研究人员对花粉图像的自动检测进行了广泛的研究。这些研究主要集中于利用传统机器学习算法和神经网络模型从花粉图像中提取花粉的独特特征,实现花粉颗粒的识别和分类,助力花粉识别准确性的提升。为降低图像特征向量的维度,Travieso等[10]基于轮廓特征提出

收稿日期:2025-07-02
基金项目:国家重点研发计划项目(2023YFD1200103);教育部学科突破先导项目(JYB2025XDXM701);中央高校基本业务费专项(2662024SZ002)
刘力源,E-mail:llys@webmail.hzau.edu.cn
通信作者:陈耀晖,E-mail:yaohui.chen@mail.hzau.edu.cn

了一种隐马尔可夫模型特征描述子，并将该方法应用于花粉的自动分类任务。Rodriguez-Damian等[11]提出的以亮度和形状为基础的特征描述子，先通过Hough Transform来估计花粉的轮廓，再利用活动轮廓模型来获得更精确的边界，最终得到能够确定花粉类别信息的特征描述子。Scharring等[12]采用了一种基于灰度不变量的花粉自动识别技术，该技术提取花粉特征不依赖于花粉粒在显微镜样品上的位置和方向，而是结合透射光和荧光显微镜的灰度图像信息。Pedersen等[13]利用了多层感知机强大的非线性拟合能力，从每张图像中提取包含43个特征的特征向量，从而判断图像中的物体是否是花粉颗粒。由于浅层神经网络可以逼近任意函数，Del Pozo-Baños等[14]使用多个特征描述子从花粉图像中提取了26维纹理特征和24维几何特征，将它们组合成50维特征向量，输入到只有一个隐藏层的人工神经网络作为分类器。Daood等[15]使用包含6个卷积层的卷积神经网络对花粉进行分类，不再依赖于预先设计的特征，同时将迁移学习应用到花粉识别上进一步提高了花粉分类器的性能。为进一步提高模型对不同尺度的花粉目标识别精度，谢永华等[16]基于高斯金字塔算法与粗糙度直方图提出了新的花粉图像特征提取方法，既保留了图像的大致信息，还实现了提取特征的几何不变性质，该方法在2个真实的花粉数据集上（包括Confoca与Pollenmonitor花粉数据）取得了理想的预测结果，测试精度分别为96.12%和91.33%。朱延刚[17]采用的方法是将原始图像与梯度方向直方图（histogram of oriented gradient）特征融合作为输入的方案，实现花粉图像高效识别，在Confocal和Pollenmonitor花粉库上平均识别率分别达到96.2%与93.4%，效果显著优于传统方法。Mahmood等[18]利用POLLEN73S、POLLEN23E和CRETAN花粉数据集验证了提出的新的CNN（APFA Net）的有效性。Valiente等[19]利用从西班牙柑橘和迷迭香蜂蜜中获得的花粉数据集对APFA Net模型进行了验证与分析，并在该工作中提出了一种全新的卷积神经网络模型——PolleNetV1，用于实现花粉的自动识别。Valiente等[20]构建了花粉图像数据集（POLLEN24_SP），并使用EfficientNetV2M网络实现了较高的分类准确性。综上所述，当前花粉图像领域的研究多数都聚焦于自动分类方面，关于花粉活力检测的研究显得较为匮乏。

自动分类任务中的核心目标是精准预测花粉的种类信息；而花粉活力预测任务的关键则是估计可育花粉与不可育花粉之间的比例关系。除此之外，花粉检测领域的相关数据集存在明显不足。目前大多数研究所依赖的数据集中，每张图片内仅包含1粒花粉[21]，然而如图1所示，对于花粉活力预测来说，面临的任务是要精准识别出特定区域内所有的花粉颗粒，现有的数据集数量与质量难以满足这一实际需求。再者，花粉颗粒自身的一些特性也导致了研究的复杂性。在实际图像中（图1），花粉颗粒的呈现状态易受采集方式和镜检方式的影响，往往存在体积较小、容易抱团、破裂畸形的问题，同时它们还容易与背景相互混淆，而背景信息本身也较为杂乱。针对以上问题，本研究构建了花粉活力自动检测算

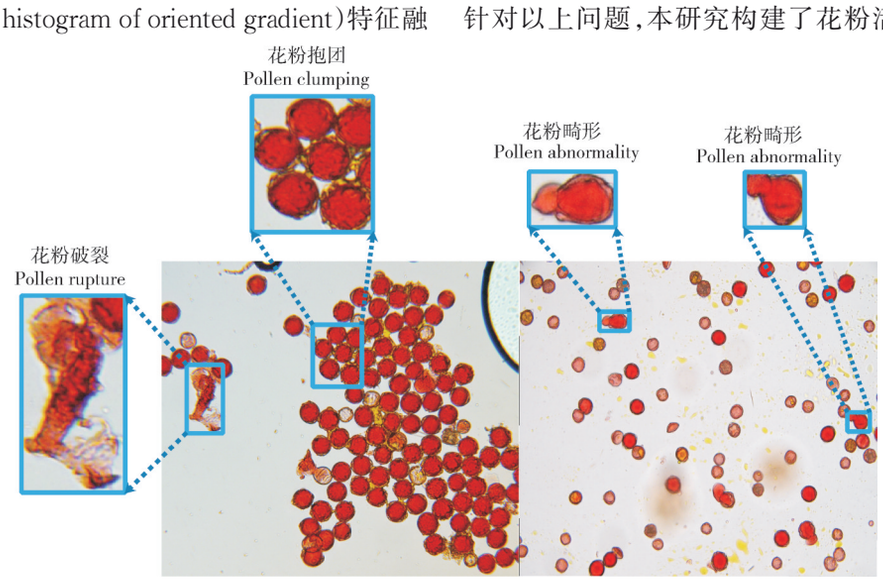


图1 花粉染色后样本

Fig. 1 Sample image after pollen staining

法研究数据集，并根据花粉数据集特点改进 YOLOv11 模型，提出 YOLOv11-FS 模型，以期为筛选花粉培育无核柑橘提供技术支撑。

1　材料与方法

1.1　材料采集及模型构建

柑橘花粉样本[不知火橘（*Citrus reticulata* ‘Shiranui’）、大果夏橙（*Citrus sinensis* ‘Algerian Summer Orange’）、稻叶温州蜜柑（*Citrus unshiu* ‘Inaba’）、贡水白柚（*Citrus maxima* ‘Gongshui Baiyou’）、马家柚（*Citrus maxima* ‘Majiayou’）、克里曼丁橘（*Citrus*×*clementina*）、露德红夏橙（*Citrus sinensis* ‘Rohde Red Valencia’）、椪柑（*Citrus reticulata* ‘Ponkan’），纽荷尔脐橙（*Citrus sinensis* ‘Newhall’）、蒙特利尔橘（*Citrus reticulata* ‘Montreal’）、春香橘柚（*Citrus*×*tangelo* ‘Chunxiang’）、春见（*Citrus reticulata* ‘Chunjian’）、马利索橘（*Citrus reticulata* ‘Maliso’）、奥兰多橘柚（*Citrus* × *tangelo* ‘Orlando’）、金秋砂糖橘（*Citrus reticulata* ‘Jinqiu Shatangju’）、黄金蜜柚（*Citrus maxima* ‘Huangjin Miyou’）]采集自湖北省武汉市华中农业大学柑橘种质资源圃（30°28′N，114°21′E）。

1）花药的采集与预处理。于华中农业大学试验田的柑橘种植区人工采集花药，并将其置于烘干设备中进行干燥处理。取适量烘干后的花药置于载玻片上，滴加染液，用镊子将花药仔细碾碎，去除杂质后覆盖盖玻片[8]。

2）显微镜观察与图像采集。将制备好的玻片标本置于奥林巴斯 BX61 万能显微镜下进行镜检，利用 DPC 控制器采集染色图像，可育花粉呈深红色，不可育花粉为淡黄色或灰色。

3）花粉数量统计与分析。借助 ImageJ 软件对采集到的图像进行处理，统计花粉数量，每个品种统计 500～800 粒花粉，以确保实验数据的准确性和可靠性。对捕获的花粉图像进行清洁，去除不清晰的图像；再用图像标记软件标记清洁的花粉图像，以区分可育花粉和不可育花粉；经统计，最终构建的数据集共包含 275 幅图像、16 个柑橘品种、12 201 粒花粉，其中可育花粉 9 938 粒，不可育花粉 2 263 粒，可育花粉占比约 81.5%，数据集整体呈现明显的类别不平衡特征（图 2）。

4）模型训练。数据处理好之后，将花粉图像和标记文件输入深度学习模型进行训练。

5）模型检测。最后将 1 组新图像发送到训练好的深度学习模型进行检测，以评估模型性能并选择最佳模型。

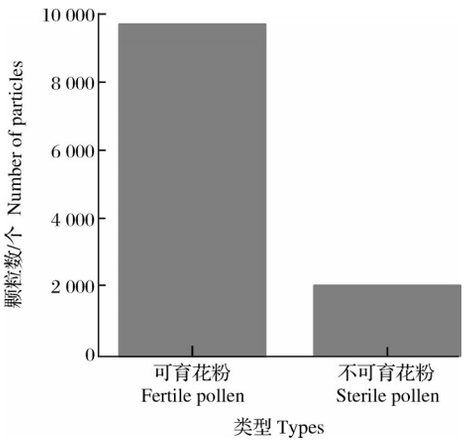


图 2　数据集中可育花粉和不可育花粉个数

Fig. 2　Number of fertile pollen and sterile pollen in the dataset

1.2　YOLOv11-FS 检测网络

YOLOv11[22]是 Ultralytics 团队公开的最新版本 YOLO 系列算法，不仅支持目标检测任务，还可以完成目标追踪、实例分割以及姿态检测等任务。YOLOv11 网络在检测精度、检测速度以及模型参数量 3 个关键指标上均表现优秀。与 YOLOv8 网络相比，YOLOv11 在主干网络中通过引入创新性的多尺度特征融合（C3k2）模块和注意力特征优化（C2PSA）模块来强化网络的特征提取能力；此外，还对检测头部使用了轻量化设计，有效减少了模型的参数量。输入图像在经过数据增强等预处理操作后，会根据网络的输入要求进行相应的缩放处理，随后被送入 Backbone 网络以进行特征提取。而 Backbone 网络通过高效的网络聚合方式，显著提升了模型的特征提取性能。提取到的特征随后经由 Neck 模块进行融合，生成 3 种不同尺度的特征图，这些融合后的特征进一步被送入 Head 部分进行最终的检测。由于网络存在对每个特征点的重复检测情况，因此采用 NMS（非极大值抑制）算法来筛选出置信度（con）最高的预测框作为最终输出（图 3）。

除此之外，YOLOv11 模型中还使用了一种新的损失函数-EIoU（Enhanced IoU）[23]。与传统方法相比，EIoU 能够更精确地计算预测框与真实框的重叠程度，改善边界框回归效果，提高检测任务的整体性能。EIoU 损失函数的参数示意图如图 4 所示。

EIoU 的计算公式如下所示：

$$L_{\mathrm{EIOU}}=L_{\mathrm{IoU}}+L_{\mathrm{dis}}+L_{\mathrm{asp}}$$

$$=1-J_{\mathrm{IoU}}+\frac{\rho(\mathrm{A}',\mathrm{B}')}{c^2}+\frac{\rho(W_{\mathrm{A}},W_{\mathrm{B}})}{{W_{\mathrm{C}}}^2}+\frac{\rho(H_{\mathrm{A}},H_{\mathrm{B}})}{{H_{\mathrm{C}}}^2} \quad (1)$$

$$J_{\mathrm{IoU}}=\frac{\mathrm{A}\cap\mathrm{B}}{\mathrm{A}\cup\mathrm{B}} \quad (2)$$

式(1)～(2)中,$\rho(\boldsymbol{W}_{\mathrm{A}},\boldsymbol{W}_{\mathrm{B}})$和$\rho(\boldsymbol{H}_{\mathrm{A}},\boldsymbol{H}_{\mathrm{B}})$分别表示宽的差的平方和高的差的平方,$c$是所求的最小外接框C的对角线长度。但是使用这种损失构建的算法在实际应用中,例如当花粉可育和不可育数据存在分布不均衡问题时,其效果不佳。因此,本研究基于原始YOLOv11模型,使用Focal-EIoU损失[23]替代YOLOv11所使用的EIoU损失[22]。该改进方法引入Focal聚焦机制以筛选优质锚框,并结合IoU对EIoU损失进行加权,使得损失函数能够重点关注难以分辨的样本,进而显著提升目标检测算法的检测性能。Focal-EIoU的计算公式如下所示:

$$L_{\text{Focal-EIoU}}=J_{\mathrm{IoU}}^{\gamma}L_{\mathrm{EIoU}} \quad (3)$$

式(3)中,γ为可调节的超参数用来控制异常值的抑制程度,当γ取值小于1时,IoU作为置信度再次加权:高IoU(易回归)框权重被削弱;低IoU(难回归、少数样本)框权重被放大。为简要说明上述加权机制的有效性,给出高低IoU框的权重比值关系:

$$\frac{J_{\mathrm{IoU}\,高}^{\gamma}}{J_{\mathrm{IoU}\,低}^{\gamma}}\leqslant\frac{J_{\mathrm{IoU}\,高}}{J_{\mathrm{IoU}\,低}} \quad (4)$$

式(4)中,$J_{\mathrm{IoU}\,高}$代表易回归样本的高IoU值,$J_{\mathrm{IoU}\,低}$代表难回归样本的低IoU值。该不等式清晰印证了前文所述的"高IoU框权重相对降低、低IoU框权重相对提升"的特性:在$\gamma<1$的条件下,高IoU与低IoU样本的权重比值被进一步缩小,难回归样本在损失计算中的占比被相对放大,易回归样本的影响被相对抑制。

因此,Focal-EIoU损失通过这种重加权机制,可有效缓解目标检测中的正负样本不均衡与类别不平衡问题,尤其适用于本研究中可育花粉(多数类)与不可育花粉(少数类)数量差异显著的检测场景。

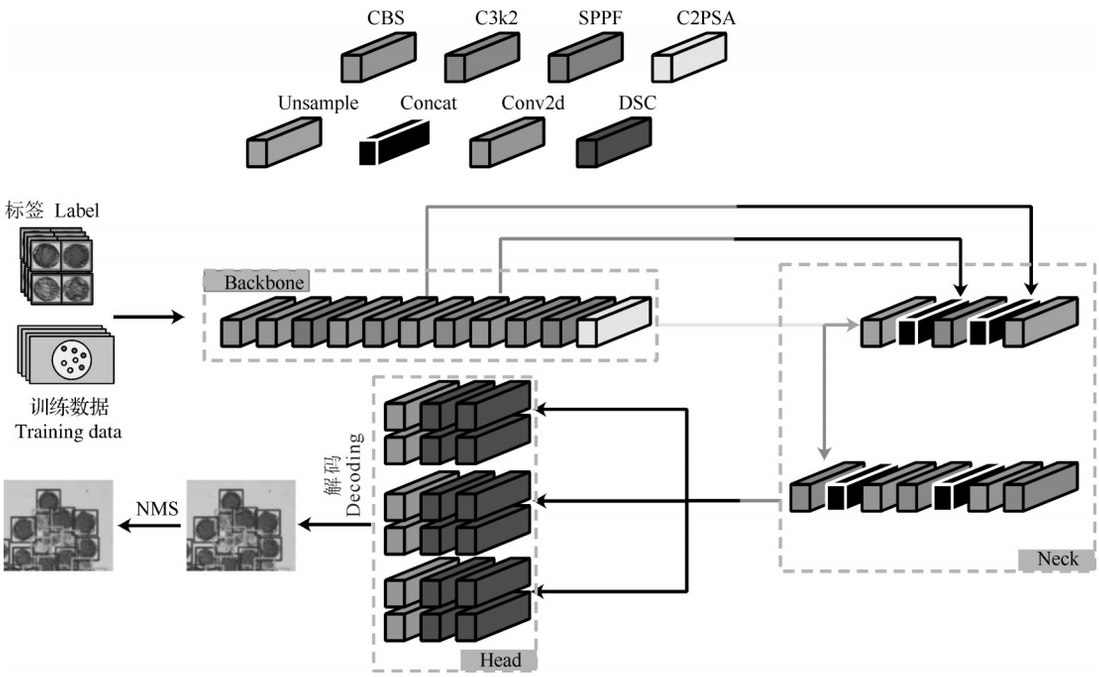
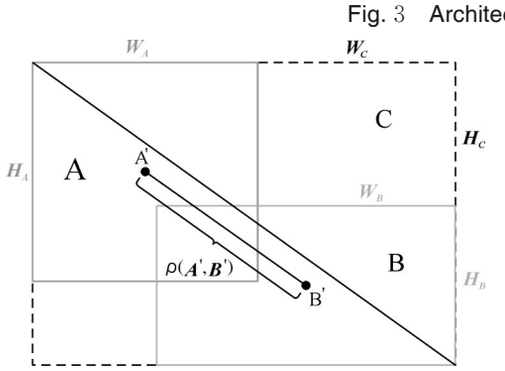


图3 YOLOv11结构图

Fig. 3 Architecture diagram of YOLOv11



A:真实框,B:预测框,C:A和B的最小外接框;$\boldsymbol{W}_{\mathrm{A}}$、$\boldsymbol{W}_{\mathrm{B}}$、$\boldsymbol{W}_{\mathrm{C}}$以及$\boldsymbol{H}_{\mathrm{A}}$、$\boldsymbol{H}_{\mathrm{B}}$、$\boldsymbol{H}_{\mathrm{C}}$分别为A、B、C 3个框的宽和高;$\rho(A',B')$为A框中心点$A'$到B框中心点$B'$的距离。A: Ground-truth box, B: Predicted box, C: Minimum enclosing rectangle of A and B. $\boldsymbol{W}_{\mathrm{A}}$, $\boldsymbol{W}_{\mathrm{B}}$, $\boldsymbol{W}_{\mathrm{C}}$ and $\boldsymbol{H}_{\mathrm{A}}$, $\boldsymbol{H}_{\mathrm{B}}$, $\boldsymbol{H}_{\mathrm{C}}$ denote the widths and heights of boxes A, B, and C, respectively. $\rho(A',B')$ represents the euclidean distance between the center point A' of box A and the center point B' of box B.

图4 EIoU参数示意图

Fig. 4 EIOU parameter schematic diagram

除了将Focal-EIOU损失函数引入YOLOv11网络外，为应对花粉重叠现象对检测框准确性的影响，本研究还使用了Soft-NMS[24]对重叠检测框进行高斯加权来调整其置信度，以降低NMS操作误删重叠检测框的概率，具体公式如下所示：

$$s_i = s_i \exp\left(-\frac{(\mathrm{IoU}(M,b_i))^2}{\delta}\right) \tag{5}$$

式(5)中，s_i代表原检测框的置信度，M为当前检测框的置信度，b_i为与其重叠的检测框的置信度。传统的NMS定义为：

$$s_i = \begin{cases} s_i, \mathrm{IoU}(M,b_i) \leqslant N_t, \\ 0, \mathrm{IoU}(M,b_i) > N_t \end{cases} \tag{6}$$

式(6)中，N_t是预先设定的阈值。结合式(5)、(6)可以看出，在NMS中，当IoU(M, b_i)超过阈值N_t时会导致s_i为零，而在Soft-NMS中，即使IoU数值很高，框的置信度仅会被减弱而非清零，重叠目标仍有机会保留。在相同置信度条件下，检测框的重叠度与置信度得分呈反比，即重叠度越高，置信度得分越低。由图5可知，A、B、C 3个检测框均满足阈值要求。在NMS的操作过程中，往往只会保留置信度最高的检测框A，然后直接剔除掉邻近的检测框B、C。尽管此方法能够保证目标检测的唯一性，却可能误删正确的检测框(C检测框)。相比之下，Soft-NMS通过引入对置信度加权的机制，适当降低邻近检测框的置信度，使得可以在保留C检测框的同时，提升整体检测精度。综上所述，本研究在YOLOv11模型的基础上，引入了Focal-EIOU损失和Soft-NMS技术，以提高花粉活力检测的精度。

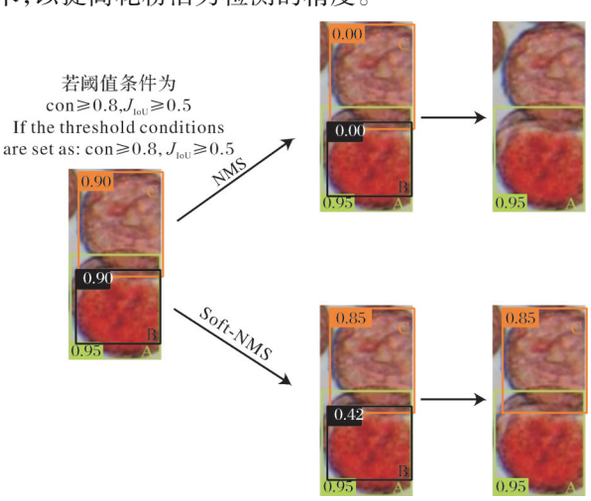


图5　花粉活力检测中的Soft-NMS示意图

Fig. 5　Schematic of Soft-NMS for pollen viability detection

1.3　实验环境及配置

本研究实验环境为台式电脑，Windows 10操作系统，处理器为Intel (R) Core (TM) i9-9900K CPU@3.60 GHz，显卡为NVIDIA GeForce RTX2060(6 GB)，运行内存为16 GB，开发环境为Python 3.8。本研究将YOLOv11-FS模型与Faster R-CNN、YOLOv9、YOLOv10、YOLOv11和YOLOv12深度学习模型进行性能比较。

1.4　实验参数设置

本研究的超参数设置如下：学习率采用余弦退火策略，初始值设为0.01，此设置参考了YOLOv11[22]的官方实现方式；优化器选用随机梯度下降(SGD)，动量设置为0.937，权重衰减为0.000 5，遵循YOLOv11的默认配置[22]，批次大小设置为8，该参数是依据实验所使用的硬件(RTX2060 6 GB)来确定的，目的是在避免出现内存溢出的情况下，尽可能增大批大小以此提高训练效率，最大迭代次数设定为300，经过重复试验验证，模型在大约230个epochs后损失趋向于平稳，这样的设置能够有效避免出现过拟合现象，损失函数权重γ设为0.5，依据文献[23]的消融实验结果，这个取值对于不平衡样本的优化效果是最好的；Soft-NMS阈值设置为δ=0.5、N_t=0.6，采用的是Bodla等[24]的推荐值，以此来保留高IoU的目标框。训练集、验证集、测试集按照14∶3∶3随机划分，按柑橘品种进行分层抽样，保证每个品种在训练集中的代表性。

1.5　花粉检测性能评估指标

为了评估新网络在花粉活力检测中的性能，使用平均交并比(mean intersection over union, mIoU)作为关键指标，用于计算检测框与真实框之间的重合程度。此外还使用精确率(precision，P)来衡量网络预测结果中正样本的准确性，即预测为正类的结果中有多少是真正的正类；而召回率(recall，R)则关注所有实际的正样本中，网络能够正确预测为正类的比例；F_1-score则综合考虑了精确率和召回率，能够更全面地反映模型在检测任务中的性能，相关指标的具体计算公式如下所示：

$$P = \frac{T_\mathrm{P}}{T_\mathrm{P} + F_\mathrm{P}} \tag{7}$$

$$R = \frac{T_\mathrm{P}}{T_\mathrm{P} + F_\mathrm{N}} \tag{8}$$

$$F_1 = 2 \times \frac{R \times P}{R + P} \tag{9}$$

式(7)～(9)中，T_P表示被网络正确检测到的正类个数；F_P表示被网络错误预测的正类个数；F_N表示

未被网络检测到的正类个数。

2 结果与分析

2.1 检测框预选

在YOLOv11-FS网络架构中，特征提取层会生成13×13、26×26、52×52三种不同尺度的特征图。其中，为了适应较小尺寸的特征图，往往需要较大的先验框。Tian等[25]的研究证明，迁移训练可以使算法的底层CNN形成形状、颜色和其他特征的记忆。因此，本研究采用迁移学习策略开展模型训练，用来得到预训练权重，从而优化算法性能。具体而言，网络的初始权重是由COCO数据集上的预训练模型迁移获得，并用于柑橘花粉数据集的迁移训练。该方法有效缩短了模型训练周期，降低了对计算硬件的要求，同时提升了检测精度。然而，目标检测任务中，COCO数据集经大量实验训练得到的默认先验框尺寸，与本研究柑橘花粉数据集的目标尺度特征不匹配。为此，本研究结合模型特性与花粉检测任务需求，对模型参数进行初始化与优化：采用*K*-means聚类算法对人工标注的可育花粉尺寸进行聚类分析，得到不同尺度下的最优先验框大小（表1），并将其作为网络的初始先验框参数，以进一步提升模型的检测精确率。

表1 先验框聚类结果

Table 1 Clustering results of prior boxes

特征图 Feature map	感受野 Receptive field	先验框 Prior boxes		
13×13	大 Large	10×18	11×25	16×32
26×26	中 Medium	6×12	7×16	8×21
52×52	小 Small	3×7	5×9	4×12

2.2 不同模型花粉活力检测

为验证YOLOv11-FS模型在花粉活力检测中的准确性，本研究对比了YOLOv9、YOLOv10、YOLOv11、YOLOv11-FS、YOLOv12及Faster R-CNN共6种模型的性能，结果如表2所示。YOLOv11-FS模型的预测花粉活力为76.15%，与真实花粉活力（76.85%）的误差仅为0.70百分点，远低于其他对比模型。结果表明，YOLOv11-FS模型在花粉活力估计任务中准确性最高，能够精准还原人工统计的真实活力率，显著优于其他对比模型。

针对可育花粉（多数类样本）的检测任务，各模型的正检、漏检、误检数量及Precision、Recall、F_1-score如表3所示。YOLOv11-FS模型实现了最优的综合性能：正检数为1 839，漏检数为23、误检数为6，Precision为99.67%、Recall为98.76%、F_1-score高达99.22%，指标均显著领先于其他模型。结果表明，YOLOv11-FS模型在多数类样本检测中实现了极低的漏检与误检，兼顾了检测精度与召回率，可有效完成可育花粉的精准识别。

表2 不同模型花粉活力检测结果对比

Table 2 Comparison of pollen vitality rates estimated by different models

模型 Model	预测花粉活力/% Predicted pollen viability	真实花粉活力/% True pollen viability	误差（百分点） Error(percentage points)
YOLOv9	72.48	77.14	4.66
YOLOv10	72.17	77.29	5.12
YOLOv11	72.66	76.68	4.02
YOLOv11-FS	76.15	76.85	0.70
YOLOv12	74.36	76.39	2.03
Faster R-CNN	58.57	73.93	15.36

针对不可育花粉（少数类样本）的检测任务，各模型的检测结果如表3所示。YOLOv11-FS模型同样展现出最优性能：正检数为536，漏检数为29、误检数为6，Precision为98.89%、Recall为94.87%、F_1-score达96.84%，显著优于其他模型。结果表明，YOLOv11-FS模型通过针对性优化，有效解决了数据集的类别不平衡问题，在不可育花粉（少数类样本）检测中实现了高精度、高召回率的检测效果，解决了传统模型对少数类样本漏检率高的问题。

2.3 不同模型花粉检测结果可视化

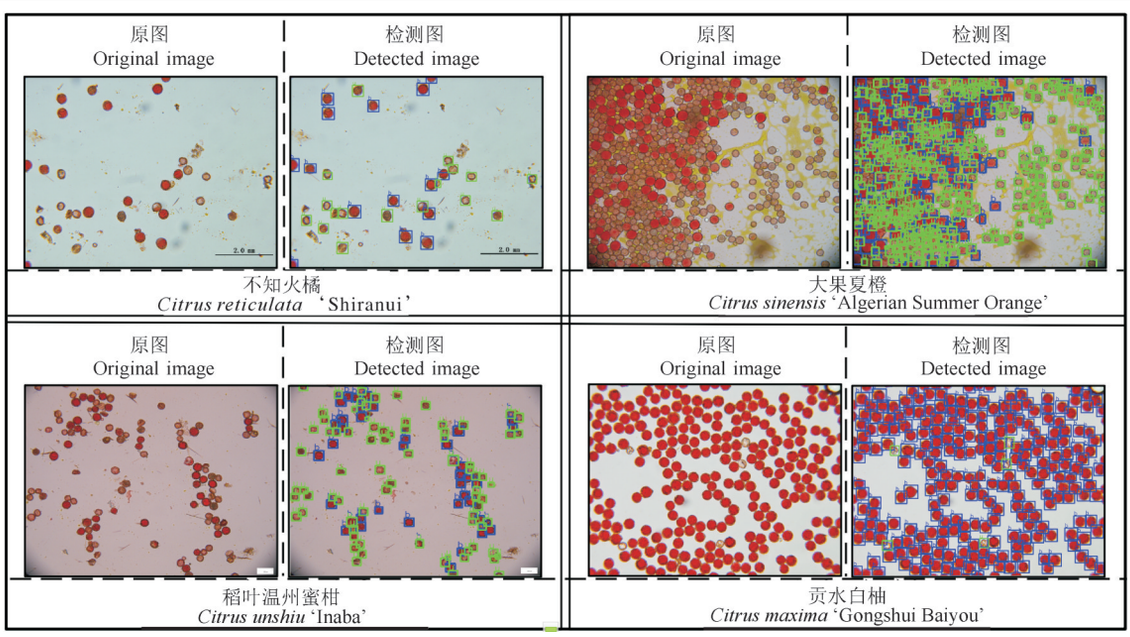
由图6可知，YOLOv11-FS模型对不知火橘、大果夏橙、稻叶温州蜜柑、贡水白柚4种柑橘品种的花粉均实现了有效检测，可准确区分可育花粉与不可育花粉。其中，不知火橘、大果夏橙、稻叶温州蜜柑等品种的可育花粉数量占比较低，对应花粉活力水平较低。

为进一步验证YOLOv11-FS模型相较于主流目标检测模型及YOLOv11基准模型的性能优势，对比了不同模型下4个不同柑橘品种花粉的检测结果。由图7可知，相较于其他模型，YOLOv11-FS能够精准分割可育与不可育花粉，无显著漏检与误检现象。该检测效果与表2～表3中的定量评估结果高度一致，模型在各项指标上的表现均最优。总体而言，YOLOv11-FS在检测数量与精度上表现突出，相比

表 3　不同模型检测可育花粉和不可育花粉的结果对比

Table 3　Comparison of detection results of fertile and sterile pollen using different models

模型 Model	可育花粉 Fertile pollen						不可育花粉 Sterile pollen					
	正检 True positive	漏检 False negative	误检 False positive	精确率/% Precision	召回率/% Recall	F_1分数/% F_1-score	正检 True positive	漏检 False negative	误检 False positive	精确率/% Precision	召回率/% Recall	F_1分数/% F_1-score
YOLOv9	1 620	176	72	95.74	90.20	92.89	403	138	30	93.07	74.49	82.75
YOLOv10	1 675	156	37	97.84	91.48	94.55	429	120	22	95.12	78.14	85.80
YOLOv11	1 717	123	28	98.40	93.32	95.79	499	62	10	98.04	88.95	93.27
YOLOv11-FS	1 839	23	6	99.67	98.76	99.22	536	29	6	98.89	94.87	96.84
YOLOv12	1 691	130	14	99.18	92.86	95.92	501	70	11	97.85	87.74	92.52
Faster R-CNN	892	605	371	70.63	59.59	64.64	316	168	87	78.41	71.17	74.62



蓝色检测框代表检测到可育花粉，绿色检测框代表检测到的不可育花粉。The blue detection box represents the detection of fertile pollen, and the green detection box represents the detection of sterile pollen.

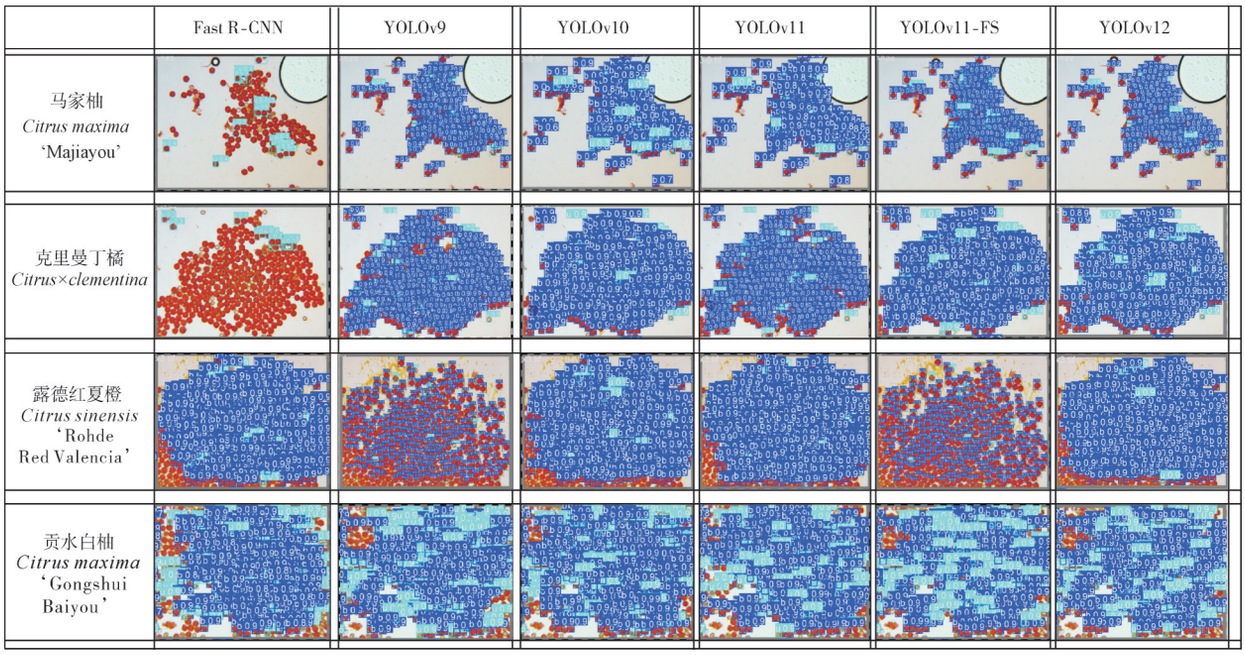
图 6　不同品种柑橘花粉的 YOLOv11-FS 模型检测结果可视化

Fig. 6　Visualization of YOLOv11-FS detection results of different citrus pollen varieties

之下，YOLOv11 基准模型虽正检数量与之相当，但漏检数量明显更高。区别于对比方法中其他的 YOLO 模型，YOLOv11-FS 网络在其 Backbone 和 Neck 架构中新增了 C3k2 和 C2PSA 等组件，增强了特征提取与关键像素区域识别的能力，使其适用于更复杂的精细目标识别与检测任务。而对照方法 Faster R-CNN 网络的漏检数目最高、检测效果并不理想，其对花粉颗粒这类分布密集的小目标检测能力较差，这可能是由于 Faster R-CNN 网络需要通过 RPN 先生成上千个候选框，再做分类。重叠目标会输出大量高 IoU 的重复检测框，后续 NMS 极易错误消除，造成漏检。而且 Faster R-CNN 的主干网络经过 4 次下采样后，小目标在特征图上仅占据 1～2 像素，有效信息大量丢失。而 YOLO 系列网络直接在多尺度特征图上回归框和类别，避免候选框重叠与 NMS 错误消除，各项指标显著高于 Faster R-CNN。此外，对比最新开发的 YOLOv12 模型，虽然大部分指标优于 Faster R-CNN、YOLOv9、YOLOv10、YOLOv11，但是仍旧不及针对于不平衡和花粉重叠样本优化后的 YOLOv11-FS 模型。

3　讨　论

本研究构建了包含 275 幅图像、16 个柑橘品种的柑橘花粉活力检测数据集，并按照 14∶3∶3 划分训练



深蓝色检测框代表检测到可育花粉，淡蓝色检测框代表检测到的不可育花粉。The dark blue detection box represents the detection of fertile pollen, and the light blue detection box represents the detection of sterile pollen.

图7 不同品种柑橘花粉在不同模型下的检测结果可视化

Fig. 7 Visualization of detection results of different citrus pollen varieties under different network models

集、验证集与测试集。结果表明，所提YOLOv11-FS模型的花粉活力预测误差仅为0.70百分点，可育花粉检测精确率、召回率、F_1-score分别达99.67%、98.76%、99.22%，不可育花粉检测对应指标分别为98.89%、94.87%、96.84%，各项性能均优于YOLOv9、YOLOv10、YOLOv11、YOLOv12及Faster R-CNN等主流模型。相较于基准YOLOv11，该模型不可育花粉召回率提升5.92百分点，花粉活力预测误差降低3.32百分点，有效缓解了数据集类别不平衡问题。

然而本研究存在着一些局限性：(1)如数据集仅覆盖16个柑橘品种，样本多样性有待拓展；(2)仅设置可育/不可育二分类标签，未实现花粉活力等级细分；(3)模型未充分适配田间逆境等复杂场景，实际应用范围受限。未来研究将拓展数据类别，新增15个无核柑橘主栽品种及3个有核对照品种的花粉图像，以覆盖早、中、晚熟类型；此外在现有"可育/不可育"二元标签基础上，增添"畸形破裂""失水干瘪""正常饱满"等精细活力等级；并补充黄龙病、溃疡病、炭疽病等5种病害感染的花粉样本，以及干旱、低温、药害3类逆境胁迫下的花粉图像，以模拟实际果园复杂场景。这些改进将进一步提升算法的普适性和准确性，为无核柑橘育种以及柑橘果园的智能化管理提供更全面的技术支撑。

参考文献 References

[1] 邓秀新，彭抒昂. 柑橘学[M]. 北京：中国农业出版社，2013. DENG X X, PENG S A. Citrology[M]. Beijing: China Agriculture Press, 2013(in Chinese).

[2] 郭文武，叶俊丽，邓秀新. 新中国果树科学研究70年：柑橘[J]. 果树学报，2019，36(10)：1264-1272. GUO W W, YE J L, DENG X X. Fruit scientific research in New China in the past 70 years: *Citrus*[J]. Journal of fruit science, 2019, 36(10): 1264-1272 (in Chinese with English abstract).

[3] LI S Q, YANG D C, ZHU Y G. Characterization and use of male sterility in hybrid rice breeding[J]. Journal of integrative plant biology, 2007, 49(6): 791-804.

[4] VARDI A, LEVIN I, CARMI N. Induction of seedlessness in citrus: from classical techniques to emerging biotechnological approaches[J]. Journal of the American Society For Horticultural Science, 2008, 133(1): 117-126.

[5] ZHENG B B, FANG Y N, PAN Z Y, et al. iTRAQ-based quantitative proteomics analysis revealed alterations of carbohydrate metabolism pathways and mitochondrial proteins in a male sterile cybrid pummelo[J]. Journal of proteome research, 2014, 13(6): 2998-3015.

[6] LIANG M, CAO Z H, ZHU A D, et al. Evolution of self-compatibility by a mutant *Sm-RNase* in citrus[J]. Nature plants,

2020,6(2):131-142.

[7] SCOTT R J, SPIELMAN M, DICKINSON H G. Stamen structure and function[J]. The plant cell, 2004, 16(suppl): S46-S60.

[8] WANG R, SHI Y C, XIE K D, et al. The citrus somatic cybrids exhibit various degrees of male sterility conferred by mitochondrial genome of Satsuma mandarin (*Citrus unshiu*)[J/OL]. Scientia horticulturae, 2024, 338: 113624[2025-07-02]. https://doi.org/10.1016/j.scienta.2024.113624.

[9] ESCRICHE I, JUAN-BORRÁS M, VISQUERT M, et al. An overview of the challenges when analysing pollen for monofloral honey classification[J/OL]. Food control, 2023, 143: 109305[2025-07-02]. https://doi. org/10.1016/j. foodcont.2022.109305.

[10] TRAVIESO C M, BRICENO J C, TICAY-RIVAS J R, et al. Pollen classification based on contour features [C]//Proceedings of the 15th IEEE International Conference on Intelligent Engineering Systems. June 23-25, 2011, Poprad, Slovakia. Poprad: IEEE, 2011: 17-21.

[11] RODRIGUEZ-DAMIAN M, CERNADAS E, FORMELLA A, et al. Pollen classification using brightness-based and shape-based descriptors[C]//Proceedings of the 17th International Conference on Pattern Recognition. August 26-26, 2004, Cambridge, UK. Cambridge: IEEE, 2004: 212-215.

[12] SCHARRING S, RONNEBERGER O, KOCH W. Automatic pollen recognition-developments and perspectives automatische pollenerkennung-entwicklungen und perspektiven [J]. Nachrichtenblatt des deutschen pflanzenschutzdienstes, 2006, 58(11): 309-314.

[13] PEDERSEN B, BAILEY D G, HODGSON R M, et al. Model and feature selection for the classification of dark field pollen images using the classifynder system[C]//2017 International Conference on Image and Vision Computing New Zealand (IVCNZ). December 4-6, 2017, Christchurch, New Zealand. Christchurch: IEEE, 2017: 1-5.

[14] DEL POZO-BAÑOS M, TICAY-RIVAS J R, CABRERA-FALCN J, et al. Image processing for pollen classification[M/OL]//LAMEED G A. Biodiversity enrichment in a diverse world. [S.l.]: InTechOpen, 2012. (2012-08-29)[2025-07-02]. https://www.intechopen.com/chapters/38677.

[15] DAOOD A, RIBEIRO E, BUSH M. Pollen grain recognition using deep learning[C]//Advances in Visual Computing. ISVC 2016. December 12-14, 2016, Las Vegas, NV, USA. Cham: Springer, 2016: 321-330.

[16] 谢永华,徐赵飞,范文晓. 基于高斯尺度空间粗糙度描述子的花粉图像分类识别[J]. 计算机应用, 2015, 35(7): 2039-2042. XIE Y H, XU Z F, FAN W X. Pollen image classification and recognition based on Gaussian scale-space roughness descriptor[J]. Journal of computer applications, 2015, 35(7): 2039-2042 (in Chinese with English abstract).

[17] 朱延刚. 基于多特征融合的花粉图像识别算法研究[D]. 南京: 南京信息工程大学, 2018. ZHU Y G. Research on pollen image recognition algorithm based on multi-feature fusion[D]. Nanjing: Nanjing University of Information Science & Technology, 2018 (in Chinese with English abstract).

[18] MAHMOOD T, CHOI J, PARK K R. Artificial intelligence-based classification of pollen grains using attention-guided pollen features aggregation network[J]. Journal of King Saud University computer and information sciences, 2023, 35(2): 740-756.

[19] VALIENTE J M, JUAN-BORRÁS M, LÓPEZ-GARCÍA F, et al. Automatic pollen recognition using convolutional neural networks: the case of the main pollens present in Spanish citrus and rosemary honey[J/OL]. Journal of food composition and analysis, 2023, 123: 105605[2025-07-02]. https://doi.org/10.1016/j.jfca.2023.105605.

[20] VALIENTE J M, MARTÍN-OSUNA J J, PERAL A M, et al. Assisting monofloral honey classification by automated pollen identification based on convolutional neural networks[J/OL]. Ecological informatics, 2025, 90: 103340[2025-07-02]. https://doi.org/10.1016/j.ecoinf.2025.103340.

[21] 杨倩,陈欣,张平冬,等. 杨树 2n 花粉形态判别方法的比较[J]. 东北林业大学学报, 2015, 43(2): 33-35. YANG Q, CHEN X, ZHANG P D, et al. Discrimination methods in 2n pollen in *Populus*[J]. Journal of Northeast Forestry University, 2015, 43(2): 33-35 (in Chinese with English abstract).

[22] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements [PP/OL]. arXiv, 2024: 2410.17725 [2025-07-02]. https://doi. org/10.48550/arXiv.2410.17725.

[23] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.

[24] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS: improving object detection with one line of code[PP/OL]. arXiv, 2017: 1704.04503 [2025-07-02]. https://doi. org/10.48550/arXiv.1704.04503.

[25] TIAN Y N, YANG G D, WANG Z, et al. Apple detection during different growth stages in orchards using the improved YOLO-V3 model[J]. Computers and electronics in agriculture, 2019, 157: 417-426.

YOLOv11-FS model-based detection of pollen viability in citrus

LIU Liyuan[1], ZHANG Xuelin[1], CHEN Hong[1], LI Weifu[1], LIAO Jianhua[2], XIE Kaidong[2], WU Xiaomeng[2], GUO Wenwu[2], CHEN Yaohui[3]

1.*College of Informatics, Huazhong Agricultural University, Wuhan 430070, China*;
2.*National Key Laboratory for Germplasm Innovation & Utilization of Horticultural Crops, Wuhan 430070, China*;
3.*College of Engineering, Huazhong Agricultural University, Wuhan 430070, China*

Abstract A dataset of detecting pollen viability in citrus was constructed to promote the breeding of citrus seedless varieties and meet the demand for high-quality production of citrus. A new model of detecting pollen vitality was proposed by improving the YOLOv11 deep neural network. A dataset suitable for detecting pollen vitality was established through manual collection and expert annotation. The YOLOv11 deep neural network was improved to develop the YOLOv11-FS model. The Focal-EIOU loss function was used to replace the EIOU loss of YOLOv11 to enhance detection performance on imbalanced samples during the process of detection. Soft-NMS was incorporated to improve the precision of detection boxes, overcoming challenges including obvious clustering, small size, and complex backgrounds of pollen grains in citrus. Results showed that the improved YOLOv11-FS model performed excellently in the task of detecting pollen, the predicted pollen viability deviates from the true pollen viability by only 0.70 percentage points. The recall, precision, and F_1-score of detecting fertile pollen and sterile pollen reached 98.76%, 99.67%, 99.22%, and 94.87%, 98.89%, 96.84%, respectively, meeting the basic needs of detecting pollen vitality. It is indicated that the method of detection establshed can achieve efficient and accurate identification of pollen vitality in citrus.

Keywords citrus; detection of pollen viability; YOLOv11-FS; Soft-NMS; Focal EIOU loss

(责任编辑:葛晓霞)