

文飞, 莫嘉维, 胡宇琦, 等. 基于卷积神经网络遥感图像的荔枝花期长势评估 [J]. 华南农业大学学报, 2023, 44(1): 123-133.  
WEN Fei, MO Jiawei, HU Yuqi, et al. The assessment of litchi flowering growth based on remote sensing image of convolutional neural network[J]. Journal of South China Agricultural University, 2023, 44(1): 123-133.

# 基于卷积神经网络遥感图像的荔枝花期长势评估

文 飞<sup>1</sup>✉, 莫嘉维<sup>1</sup>, 胡宇琦<sup>1</sup>, 兰玉彬<sup>1,2</sup>, 陈 欣<sup>1,2</sup>, 陆健强<sup>1,2</sup>, 邓小玲<sup>1,2</sup>✉

(1 华南农业大学 电子工程学院/国家精准农业航空施药技术国际联合研究中心, 广东 广州 510642;

2 岭南现代农业科学与技术广东省实验室, 广东 广州 510642)

**摘要:**【目的】通过无人机获取荔枝冠层的遥感图像, 评估每棵荔枝的开花率, 以期为后续荔枝花期疏花保果、精准施肥施药提供决策依据。【方法】以遥感图像为研究对象, 利用实例分割的方法分割每棵荔枝冠层后, 结合园艺专家的综合判断, 按开花率为 0、10%~20%、50%~60%、80% 及以上将开花率分为 4 类, 使用 ResNet、ResNeXt、ShuffleNetv2 进行开花率分类比较, 试验过程中发现 ShuffleNetv2 在识别准确率、参数量、训练和验证时间都有很大优势; 在 ShuffleNetv2 上引入了空间注意力模块 (Spatial attention module, SAM) 后, 增加了模型对位置信息的学习, 在不显著增加参数量的情况下, 提升荔枝冠层花期分类的精度。【结果】通过对多个主流深度神经网络的比较分析, ResNet50、ResNeXt50、ShuffleNetv2 的分类精度分别达到 85.96%、87.01% 和 86.84%, 而改进后的 ShuffleNetv2 分类精度更高, 达到 88.60%; ResNet50、ResNeXt50、ShuffleNetv2 和改进后的 ShuffleNetv2 对测试集单张冠层图像验证的时间分别为 8.802、9.116、7.529 和 7.507 ms, 改进后的 ShuffleNetv2 单张冠层图像验证时间最短。【结论】改进后的 ShuffleNetv2 能够挖掘学习更为细节的荔枝冠层花期信息, 具有较高的识别准确率, 对荔枝花期的评估有很大的优势, 可为荔枝保花疏花、生产精准管控提供智能决策支持。

**关键词:** 无人机遥感; 荔枝; 花期长势; 卷积神经网络; 图像处理; 注意力模块

中图分类号: TP79;S252

文献标志码: A

文章编号: 1001-411X(2023)01-0123-11

## The assessment of litchi flowering growth based on remote sensing image of convolutional neural network

WEN Fei<sup>1</sup>✉, MO Jiawei<sup>1</sup>, HU Yuqi<sup>1</sup>, LAN Yubin<sup>1,2</sup>, CHEN Xin<sup>1,2</sup>, LU Jianqiang<sup>1,2</sup>, DENG Xiaoling<sup>1,2</sup>✉

(1 College of Electronic Engineering, South China Agricultural University/National Center for International Collaboration Research on Precision Agricultural Aviation Pesticides Spraying Technology, Guangzhou 510642, China; 2 Guangdong Laboratory for Lingnan Modern Agriculture, Guangzhou 510642, China)

**Abstract:** 【Objective】In order to provide decision-making basis for subsequent litchi flower thinning, fruit retention and precise fertilization application, this work evaluated the flowering rate of each litchi by analyzing UAV remote sensing images of litchi canopy. 【Method】The remote sensing image of each litchi canopy was segmented through instance segmentation algorithm. The flowering rates were classified into four categories combining with comprehensive judgment of horticultural experts, which were 0, 10%~20%, 50%~60%, 80% and above. ResNet50, ResNeXt50 and ShuffleNetv2 were adopted to compare flowering rate classification. Due

收稿日期: 2022-01-12 网络首发时间: 2022-10-24 14:35:02

首发网址: <https://kns.cnki.net/kcms/detail/44.1110.s.20221021.0939.002.html>

作者简介: 文 飞, 硕士研究生, 主要从事农业航空遥感应用研究, E-mail: [wenfei@stu.scau.edu.cn](mailto:wenfei@stu.scau.edu.cn); 通信作者: 邓小玲, 副教授, 博士, 主要从事农业航空遥感应用研究, E-mail: [dengxl@scau.edu.cn](mailto:dengxl@scau.edu.cn)

基金项目: 广东省重点领域研发计划 (2019B020214003); 广州市重点研发计划 (202103000090); 广东高校重点领域 (人工智能) 专项 (2019KZDZX1012); 岭南现代农业科学与技术广东省实验室科研项目 (NT2021009)

to the great advantages in recognition accuracy, number of parameters, training and verification time, ShuffleNetv2 was adopted as the instance segmentation algorithm, and optimized by introducing the spatial attention module (SAM) to increase the model’s learning of location information, and improve the accuracy of litchi canopy flowering classification without significantly increasing the number of parameters. 【Result】 Through comparison of the mainstream deep learning algorithms, the classification accuracy of ResNet50, ResNeXt50 and ShuffleNetv2 reached 85.96%, 87.01% and 86.84% respectively, and the improved ShuffleNetv2 reached 88.60%, higher than the above three algorithms. The verification time of single canopy image on test set using ResNet50, ResNeXt50, ShuffleNetv2 and the improved ShuffleNetv2 were 8.802, 9.116, 7.529 and 7.507 ms respectively, showing that the improved ShuffleNetv2 single canopy image got the shortest verification time. 【Conclusion】 The improved ShuffleNetv2 can excavate and learn more detailed flowering information of litchi canopy, with high recognition accuracy and great advantages in the evaluation of litchi flowering, providing an intelligent decision support for flower protection and sparseness, and precise control of production.

**Key words:** UAV remote sensing; Litchi; Florescence growth; Convolutional neural network; Image processing; Attention module

我国是世界第一荔枝生产大国，种植面积和产量分别约占全世界的 80% 和 65% 以上，荔枝栽培历史悠久，品种资源和生产经验丰富，其中，广东省是我国荔枝种植大省。荔枝的花量通常都偏多，尤其是大花穗品种，1 个花穗其小花量可达数千朵，荔枝常年花量偏大，消耗的养分过多反而影响坐果<sup>[1]</sup>。荔枝花期的现白点时间、花穗数量、花量、雄花数、雌花数、开花时间、谢花时间等指标要素对荔枝生产精准管理格外重要。根据果树花期长势监测结果，在修剪促萌、灌水、环割作业时间或药剂处理上进行精准控制，以实施精准促花壮花或疏化保花等措施，有利于提高坐果率。近年来，多项研究表明，在花期进行合理的管控有利于果实产量与品质的提升，如疏花加快了无核荔枝果实生长发育，并提高了果实的产量和品质<sup>[2]</sup>。在花穗生长中期修剪花穗，能明显提高单穗挂果数和产量，综合效果最好<sup>[3]</sup>。通过“一疏二控三割”控穗疏花技术可以显著提高‘妃子笑’的最终坐果率、株产和果实固酸比<sup>[4]</sup>。不同程度的疏花方式均能够显著减少花量，缩短开花时期，并增加坐果量<sup>[5]</sup>。疏花可以提高单个花穗的雌花比例，提前一批雄花和第一批雌花的开放高峰，延长雌花的持续开放时间，进而增加初始坐果量，降低生理落果<sup>[6]</sup>。此外，随着荔枝种植规模的扩大，人力成本越来越高，基于无人机遥感的大面积果园果树花期长势的智能监测需求日益增加。

近距离拍摄荔枝花的图像，并利用计算机视觉和机器学习的方法进行花期识别和诊断，是目前主流的研究方法。Wang 等<sup>[7]</sup>提出夜间环境下修正的芒果花分割方法，该方法将拍摄效果好的图像作为

参照图像，使用归一化放缩法将其他图像灰度放缩到参照图像的灰度范围内，从而起到修正作用。用固定的阈值分割出芒果花、叶片和枝干后，训练识别花的支持向量机，精确分割出芒果花，并计算花密度，其准确率达到 85.8%。Yousefi 等<sup>[8]</sup>得出基于随机森林的油棕榈开花期分类模型在准确率和  $F$  度量值 ( $F$ -measure) 方面要高于  $K$  最近邻算法 ( $K$ -nearest neighbor,  $K$ -NN) 和支持向量机 (Support vector machine, SVM) 算法，证明了利用随机森林模型对油棕榈开花期 4 个阶段进行分类的可行性，随机森林模型的阶段分类准确率可以达到 72.36%。Lu 等<sup>[9]</sup>通过摄像头进行柑橘开花率评估，利用 MobileNetv3 作为特征提取器，结合深度可分离卷积进一步加速，改进的柑橘开花率统计模型均值平均精度 (Mean average percision, mAP) 为 84.84%，在保证一定精度的前提下，具有内存占用少、检测速度快等优点。朱永宁等<sup>[10]</sup>提出结合枸杞开花期和果实成熟期的植物学特征，利用 Faster R-CNN 方法对图像进行训练、分类，构建枸杞开花期和果实成熟期的识别算法，mAP 达到 74%。杨其晟等<sup>[11]</sup>提出一种改进 YOLOv5 的苹果花朵生长状态检测方法，对花蕾、半开、全开、凋落这 4 类苹果树开花期花朵生长状态进行检测。该方法首先对跨阶段局部网络模块进行改进，并调整模块数量，结合协同注意力模块设计主干网络，提高模型检测性能并减少参数，mAP 达到 92.2%。熊俊涛等<sup>[12]</sup>提出一种基于深度语义分割网络识别荔枝花、叶片像素并实现分割的方法，构建深度为 34 层的 ResNet 主干网络，引入稠密特征传递方法和注意力模块，提取荔枝

花、叶片的特征;最后通过全卷积网络层对荔枝花、叶片进行分割,模型的平均交并比 (Mean intersection over union, mIoU) 为 0.734,像素识别准确率达到 87%。邓颖等<sup>[13]</sup>提出基于实例分割的柑橘花朵识别与花量统计方法,以花期的柑橘树冠图像为样本进行花朵实例的识别及分割,通过对 Mask R-CNN 主体卷积部分和掩膜分支部分的优化,实现对复杂结构图像中密集小尺度柑橘花朵目标的高效检测,获取图像中可见花数量识别神经网络的平均精度为 36.3,花量计算误差为 11.9%。

随着无人机行业的发展,低空遥感已经开始应用于农业农事的判断和管理,无人机低空遥感相比于地面摄像头和人工采集图像,可以获得更加丰富的农作物和地理信息,相比于卫星遥感具有获取方式更灵活、时效高、影像分辨率高等特点,在农情监测、精准农业等领域得到越来越多的应用<sup>[14-17]</sup>。杜蒙蒙等<sup>[18]</sup>在小麦分蘖期内获取可见光波段的无人机遥感图像,建立植被指数与小麦茎蘖密度地面真值之间的预测模型,在田块尺度上定量反演小麦茎蘖密度,小麦茎蘖密度定量反演 BP 神经网络模型的均方根误差及平均绝对百分比误差分别为 19% 及 3.62%,具有较高的小麦茎蘖密度预测精度。朱圣等<sup>[19]</sup>通过获取水稻田的低空遥感图像,分析得到杂草分布图,构建 CNN 网络对图像的分类,精度达到 92.41%,生成的水稻田杂草分布图效果最好。杨蜀秦等<sup>[20]</sup>提出一种改进的玉米雄蕊识别模型,能够准确地检测无人机遥感图像中尺寸较小的玉米雄蕊,检测精度分别比 Faster R CNN 和 YOLO v4 模型高 26.22% 和 3.42%,为玉米抽雄期的农情监测提供参考。

综合研究表明,目前大多通过地面摄像头和人工手持相机采集荔枝花数据,由于角度受限,导致地面拍摄的花期信息不够全面,无法应用于大规模荔枝园。由于荔枝花主要集中在冠层,侧面花较少,且荔枝树均较高,人工观测荔枝冠层耗时长、收效低,因此利用无人机拍摄冠层可以获取更多荔枝花期的信息,同时能够节省部分人力和物力,一定程度上可以提升农业农事的效率。兰玉彬教授研究团队在基于无人机遥感技术进行果树大面积智能监测方面,积累了较好的研究经验,Mo 等<sup>[21]</sup>从无人机获取的图像中对果树冠层进行实例分割,对于果园的精准管理具有重要意义;李继宇等<sup>[22]</sup>基于文献计量学,得出农用无人机仍处于活跃的发展阶段,应用场景日趋丰富,纵向发展稍有阻滞,未来可能会在畜牧业和渔业上挖掘到新的研究应用方向。现有的研究鲜见通过荔枝冠层进行观测分析,本研究拟采用大疆精灵 P4 Multispectral 无人机采集荔枝花期冠层数据,重点优选和优化荔枝开花率评估分类模型,并建立更加精准的荔枝花期长势评估模型,以期为后续荔枝花期疏花保果、精准施肥施药提供决策依据。

# 1 材料与方法

## 1.1 研究区域

研究区域位于广东省广州市从化区荔博园 (23°58'N,113°62'E),如图 1a 所示,该区域属亚热带季风区,气候温和,雨量充沛,全年平均气温 22.0℃,年降雨量 2305.1 mm,年日照 1638.0 h,适宜的温度、肥沃的土壤共同组成了荔枝生长的理想环境。

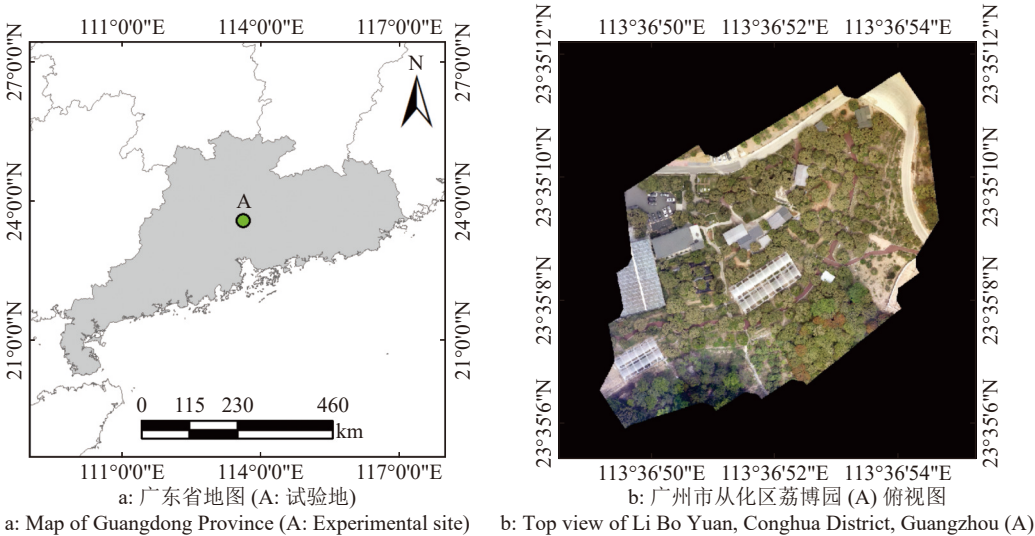


图 1 试验地概况  
Fig. 1 The overview of experimental site



1.2 图像采集与数据集构建

采用大疆精灵 P4 Multispectral 拍摄园区荔枝树冠层可见光图像, 该无人机采用 TimeSync 时间同步系统, 通过将飞控、相机与 RTK 的时钟系统进行微秒级同步, 实现相机成像时刻的毫秒级误差。系统还对每个相机镜头中心点位置与天线中心位置, 结合设备姿态信息, 进行实时补偿, 使影像获得更加丰富的位置信息。本研究于 2021 年 2 月底至 3 月底拍摄园区花期荔枝冠层, 飞行高度约 45 m, 飞行速度约 5 m/s, 结合地面站软件 DJI GS PRO 进行航线规划。园区占地面积约 20 hm<sup>2</sup>, 拍摄园区荔枝共 141 棵, 通过大疆制图软件对获取图像进行拼接。拼接后图像分辨率为 10863 像素×10974 像素, 试验基地荔枝冠层俯拍图如图 1b 所示。

为获得单棵荔枝冠层图像, 将整张园区冠层图像首先进行分块处理, 再运用 YOLACT 实例分割模型对园区内的冠层进行分割, 网络训练优化器为随机梯度下降 (Stochastic gradient descent, SGD), 学习率为 0.001, 权重衰减为  $5\times10^{-4}$ , 动量因子为 0.9, 分割最佳精确度 (Average precision, AP) 达到 96.25%, 模型推理结束后对图像进行合并处理, 去除冗余重复的部分, 并结合图片中每棵树的位置信息, 拼接后最终获得单棵荔枝树的冠层图像<sup>[22]</sup>, 冠层分割效果如图 2 所示。综合地面调查, 结合园艺专

家的综合判断, 对每棵冠层图像标记开花率, 标注的开花率分别为 0、10%~20%、50%~60%、80% 及以上, 对应荔枝花期的未开花、分化、初花、盛花期: 将开花率为 0% 的冠层图像定为第 0 类即未开花; 开花率 10%~20% 的冠层图像定为第 1 类, 即分化; 开花率 50%~60% 的冠层图像定为第 2 类, 即初花期; 开花率 80% 及以上的冠层图像定为第 3 类, 即盛花期。得到 565 张荔枝原始冠层图像, 按照 6:2:2 比例随机划分训练集、验证集和测试集。遥感图像开花率示例如图 3 所示。




图 2 冠层分割示例  
Fig. 2 Samples of canopy segmentation

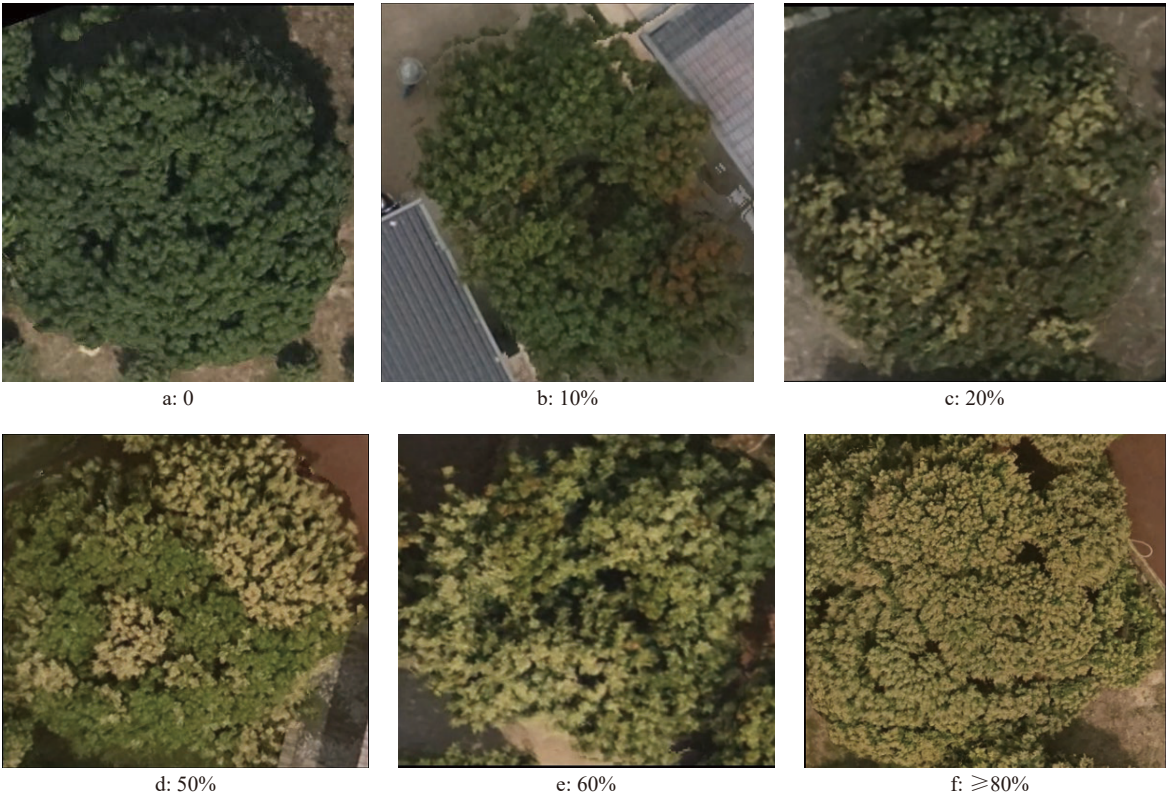


图 3 不同开花率示例  
Fig. 3 Samples of different flowering rates



1.3 数据集增强

在已有训练集的基础上, 在训练过程中利用 PyTorch 框架进行多项数据增强, 包括随机裁剪、垂直翻转、水平翻转、随机旋转一定角度, 可以在训练过程中扩充数据集, 增加数据的多样性, 提升深度学习的鲁棒性, 使得模型学习更加全面。数据增强效果如图 4 所示。

1.4 开花率评估模型构建

1.4.1 深度卷积神经网络 ResNet 网络<sup>[23]</sup> 参考了 VGG19 网络, 在其基础上进行了修改, 并通过短路机制加入了残差单元解决退化问题, 根据研究得出, 随着层数的增加, ResNet 的精度随之增加, 同时计算复杂度也随之增加。后续提出的多维残差网络 (Next dimension resNet, ResNeXt)<sup>[24]</sup> 在网络结构上对 ResNet 进行了改进, 借鉴了 Inception 分组<sup>[25]</sup> 的思想, 区别于 Inception 需要人工设计每个分支, ResNeXt 的每个分支拓扑结构是相同的, 通过多分支卷积网络 (Multi-branch convolutional networks)、分组卷积 (Group convolution) 结构在不明显增加参数量级的情况下提升模型的准确率, 同时由于拓扑结构相同, 超参数减少, 便于模型移植。

ShuffleNetv1<sup>[26]</sup> 是一个可用于移动设备的轻量

级卷积神经网络, 在 ResNet 的基础上改进, 其中 Channel shuffle 解决了多个分组卷积 (Group convolution) 叠加出现的边界效应, 借鉴了 MobileNet 的深度可分离卷积、逐点组卷积 (Pointwise group convolution) 和深度可分离卷积 (Depthwise separable convolution), 主要减少了计算量, 可以在有限的算力之下实现最优精度, 更加适用于高时效、低延迟的场景。ShuffleNetv2<sup>[27]</sup> 中提出了 FLOPs 不能作为衡量目标检测模型运行速度的标准, ShuffleNetv1 大量使用 1×1 组卷积增加了内存访问成本 (Memory access cost), 同时使用过多的组会造成网络碎片化, 减少模型的并行度。为了弥补 ShuffleNetv1 的缺陷引入了通道分割 (Channel split), 将 1×1 组卷积修改为 1×1 卷积, 将 2 个分支的输出连接在一起, 紧接着将 2 个分支连接的结果进行 Channle shuffle, 以保证 2 个分支信息交流, 模型基本单元结构如图 5a 所示。下采样模块不再用 Channel split, 2 个分支都直接复制 1 份输入, 分支均采用步长为 2 的卷积层进行下采样, 接着增加 1 个 1×1 卷积进行通道数的调整, 最后将 2 个分支进行合并, 特征图空间大小减半、通道数翻倍, 空间下采样单元结果如图 5b 所示。




图 4 数据集图像增强示例  
Fig. 4 Samples of dataset image enhancement

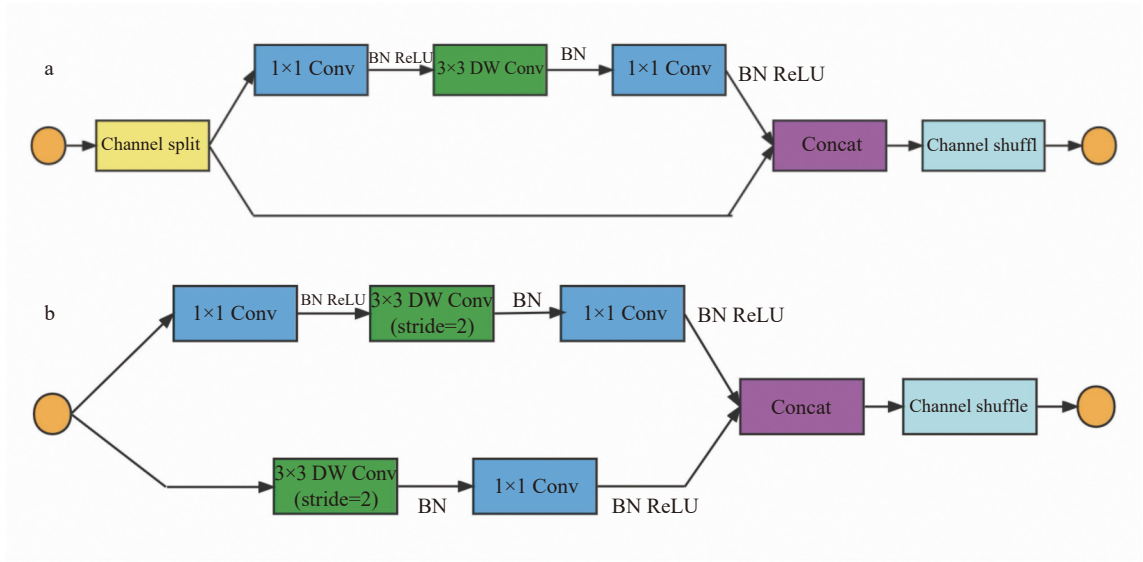


图 5 ShuffleNetv2 的基本单元 (a) 和下采样单元 (b)  
Fig. 5 Basic unit (a) and down sampling unit (b) of ShuffleNetv2

1.4.2 基于 ShuffleNetv2 的改进模型 作为轻量级网络, ShuffleNetv2 复杂度比 ResNet 和 ResNeXt 都低, 且适用场景更广, 所以选取 ShuffleNetv2 作为本研究的基础网络模型。ShuffleNetv2 的整体结构如图 6 所示。

本研究在 ShuffleNetv2 基础上, 对尾部结构进行了修改, 即将网络最后全连接层 1 000 个类别改为 4 类, 剔除不需要的参数, 减少参数量, 选取较大的学习率, 能够更好地学习拟合本研究的数据, 达到更好的效果。训练过程中运用迁移学习的方法, 即以在 ImageNet 数据集训练得到的权重作为本研

究的预训练权重, 该项操作有助于新模型的训练, 避免随机初始化权重导致训练的效果不好、训练时间过长, 通过预训练能够使得网络更好地拟合。

此外, CBAM(Convolutional block attention module) 是一种轻量型的模块, 作为即插即用的模块能够集成到现有的网络中, 且能够节约参数和算力, 在 ResNet 和 MobileNet 中均取得了不错的效果, 其中的空间注意力模块 (Spatial attention module, SAM)<sup>[28]</sup> 使得网络主要集中学习特征图中的位置信息。因此, 本研究在 ShuffleNetv2 网络结构中加入 SAM。SAM 的运行流程是将输入的特征

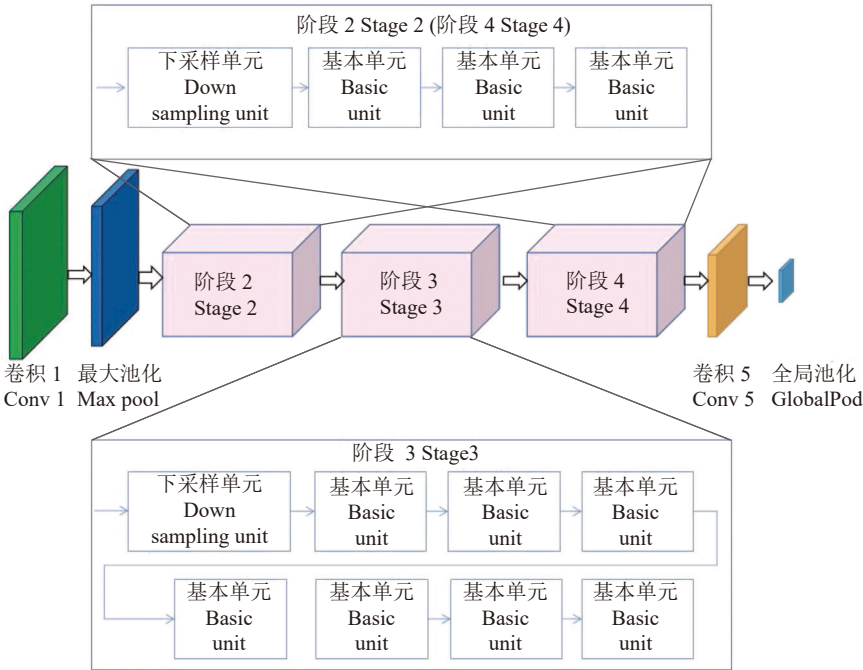


图 6 ShuffleNetv2 模型的整体结构  
Fig. 6 Overall structure of ShuffleNetv2 model



图进行基于通道的全局最大池化 (Global max pooling) 和全局平均池化 (Global average pooling), 然后将得到的 2 个结果进行基于通道的连接 (Concat) 操作。基于通道的操作可以有效地突出信息区域, 经过 1 个卷积操作, 降维后得到 1 个通道的特征图, 再经过 Sigmoid 函数生成空间特征图 (Spatial attention feature), 最后将得到的特征图和该模块的输入特征图进行相乘, 得到最终生成的特征, 如图 7 所示。

本研究加入的 SAM 的计算公式如下:




图 7 空间注意力模块  
Fig. 7 Spatial attention module




图 8 改进后的 ShuffleNetv2 结构图  
Fig. 8 Structure diagram of improved shufflenetv2

## 2 结果与分析

### 2.1 试验环境

本试验使用的服务器处理器为 Intel Core i7-10700 CPU @ 2.90GHZx 16, 内存 16 GB, 显卡为 GeForce GTX 3070。软件方面, 系统为 Ubuntu16.04, CUDA 版本为 11.3。基于 Python 编程语言使用 PyTorch 框架进行深度学习模型的搭建。

### 2.2 评价指标

本研究所用的测试指标主要为准确率和损失值。准确率广泛地应用于分类的评估中, 准确率是指预测正确的样本数占全部总样本数的比例, 针对的是所有样本的统计量, 计算较为简单, 在分类问题中是最直观的评价指标。

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}}, \quad (2)$$

式中, Acc 表示准确率, TP 表示判断正确的正例

$$\begin{aligned} \text{Ms}(F) &= \sigma \{ f^{7 \times 7} [\text{AvgPool}(F); \text{MaxPool}(F)] \} \\ &= \sigma [f^{7 \times 7} (F_{\text{avg}}^s; F_{\text{max}}^s)] \end{aligned} \quad (1)$$

式中:  $\text{Ms}(F)$  为计算得到的特征;  $\sigma$  为 Sigmoid 的函数;  $f^{7 \times 7}$  表示卷积核尺寸是  $7 \times 7$ ;  $F_{\text{avg}}^s$ 、 $F_{\text{max}}^s$  表示最大池化和平均池化操作。

在 ShuffleNetv2 网络结构中加入 SAM, 本研究进行多次试验得到加入 SAM 的最佳位置, 即在阶段 2 后加入 SAM。改进后的网络模块如图 8 所示。

数, TN 表示判断正确的负例数, FP 表示判断错误的正例数, FN 表示判断错误的负例数。

训练模型时使用交叉熵损失函数来训练优化本研究模型参数, 损失函数的公式如下:

$$\text{Loss} = - \sum_{i=0}^{F_c} y_i \log y_{\text{pre}_i}, \quad (3)$$

式中, Loss 表示损失值,  $y_{\text{pre}_i}$  表示输入数据的类是第  $i$  类的概率,  $i$  表示样本标签即真实值,  $F_c$  表示类的总数量。

### 2.3 模型训练

针对荔枝冠层花期遥感图像, 进行花期评估, 本研究进行多项对比试验, 将改进后的 ShuffleNetv2 与深度学习卷积神经网络 ResNet18、ResNet34、ResNet50 和 ResNeXt50 进行多方面的对比。均采用迁移学习的方法, 加载预训练的权重, 模型训练迭代次数为 50 次, 批处理尺寸为 32, 损失函数为对

数交叉熵损失 (Cross entropy loss), 优化算法为随机梯度下降 (Stochastic gradient descent, SGD)。动态调整学习率, 动量因子为 0.9, 其中 ShuffleNetv2 属于轻量型网络, 相对本研究其他网络较小, ShuffleNetv2 和改进后的 ShuffleNetv2 初始学习率设定为 0.1, 能够更快地拟合本研究数据, 拟合效果更好, 其余对比模型较大, 学习率过大会造成网络无法收敛, 在最优值附近振荡, 初始学习率设定为 0.001。

2.4 对比分析

图 9 为本文改进的 ShuffleNet v2 模型与其他 5 种主流深度学习卷积神经网络模型的损失值变化曲线的比较。由图 9a 可以看出, ShuffleNetv2 在训练集上损失值降低得较快。损失值可以很好地反映模型的拟合能力, 损失越低表示模型拟合能力越强, 其中, ResNet18 层数过浅导致学习特征不够, 模型拟合效果欠佳, 而 ShuffleNetv2 和改进后的 ShuffleNetv2 最终达到较小的损失值, 表明 ShuffleNetv2 对荔枝花期冠层的特征提取能力强, 模型表征充分, 和 ResNet50、ResNeXt50 相比, 损失值相差很小。由图 9b 可以看出, ResNet50 损失值最终在 0.55 左右, ResNeXt50 损失值维持在 0.51 左右, 改进后的 ShuffleNetv2 在验证集上损失值波动很小且达到最低, 维持在 0.49 左右, 证明相比其他模型该模型泛化能力强。

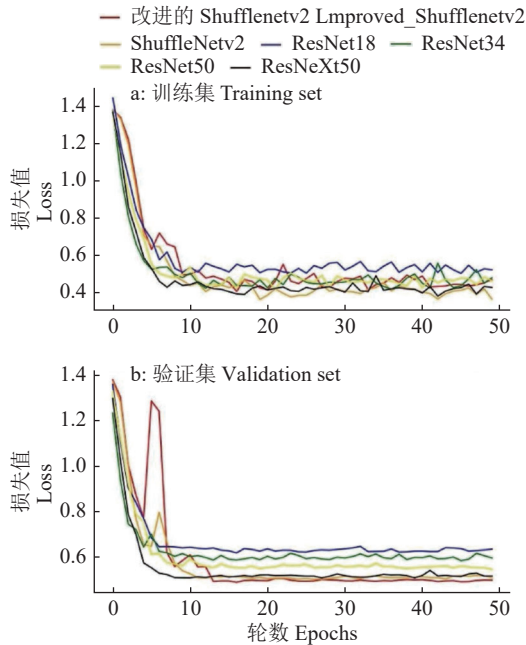


图 9 不同数据集的损失值变化曲线  
Fig. 9 Loss curves of different datasets

由图 10a 可以看出, 在训练集上, ShuffleNetv2 和改进后的 ShuffleNetv2 准确率均高于 ResNet, 与 ResNeXt 准确率十分接近。由图 10b 可以看出, 在

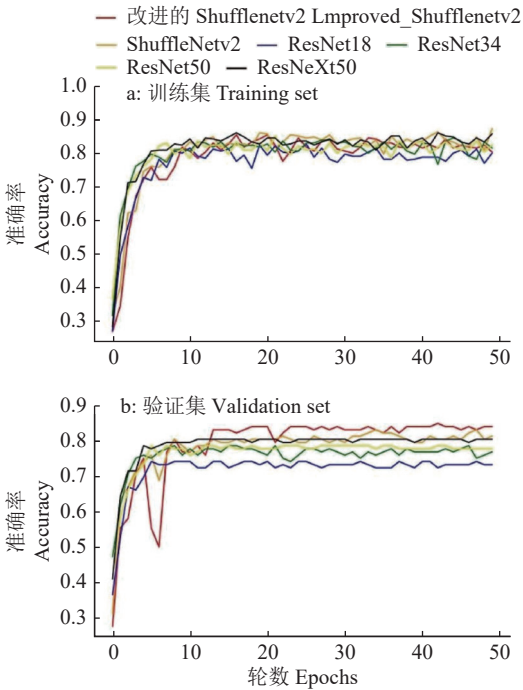


图 10 不同数据集的准确率变化曲线

Fig. 10 Accuracy change curve of different datasets

验证集上, ResNet50 的准确率达到 0.78 左右, ResNeXt50 的准确率达到 0.80 左右, ShuffleNetv2 和改进后的 ShuffleNetv2 准确率分别达到 0.83 和 0.84 左右, 效果比 ResNet、ResNeXt 好, 表明模型学习效果较好。

表 1 为不同模型对荔枝开花率评估的性能对比。由表 1 可知, 随着层数的增加, ResNet 训练时间延长; ShuffleNetv2 的训练时间相比于 ResNet18 较少。与 ResNet、ResNeXt 网络相比, ShuffleNetv2 的训练速度大幅提高, 将有利于后期补充新的数据集, 更加迅速地拟合。在单张验证的时间上, ShuffleNetv2和改进的 ShuffleNetv2 都要比 ResNet34 短, 体现出一个轻量型网络在验证速

表 1 不同模型的性能对比

Table 1 Performance comparison of different models				
模型 Model	$t_{\text{训练/s}}$ Training time	$t_{\text{验证/ms}}$ Validation time	分类准 准确率/% Classification accuracy	2类准 准确率/% Category 2 accuracy
ResNet18	120.4	7.352	83.33	60.0
ResNet34	135.8	7.812	83.33	52.0
ResNet50	175.6	8.802	85.96	60.0
ResNeXt50	199.2	9.116	87.01	60.0
ShuffleNetv2	114.4	7.529	86.84	64.0
改进的 ShuffleNetv2 Improved ShuffleNetv2	109.0	7.507	88.60	68.0



度上的优势。在测试集上, 改进后的 ShuffleNetv2 模型能够准确地分类出不同花期的冠层, 可以准确分析出所处花期为哪一类, 尤其是第 1 类 (开花率 10%~20%) 和第 2 类 (开花率 50%~60%) 识别效果相比 ResNet、ResNeXt 有大幅提升。ResNet、ResNeXt 模型效果不如改进后的 ShuffleNetv2, 主要识别错误集中在第 2 类上, 第 2 类上 ResNet34 识别准确率只能达到 52%, 误判率较高, 因为第 1 类和第 2 类荔枝冠层的花期特征十分接近, 所以模型识别困难, 本研究关键难点也在于此, 改进后的 ShuffleNetv2 在保持第 0 类 (开花率 0%) 和第 3 类 (开花率 80% 及以上) 高准确率的基础上, 大大提升了第 2 类的准确率, 第 2 类识别准确率可以达到 68%, 相比于 ResNet、ResNeXt 高出约 8 个百分点, 模型整体的识别准确率提升, 可以为后期果园精准管控提供参考。

图 11 为不同网络模型用于评估荔枝开花率的参数量比较。由图 11 可知, 随着层数的增加, ResNet 参数量成正比增加, 数量级都很大; ResNeXt50 相对于 ResNet50, 参数量有所减少, 因为 ResNeXt50 引入了分组卷积, 使得参数减少的情况下效果更好, 减少了超参数的数量。ShuffleNetv2

的参数量相对 ResNet 和 ResNeXt 要少很多, 比最少的 ResNet18 的参数少 10 866 148, 而识别效果要好很多。ShuffleNetv2 和 ResNeXt50 相比, 参数量相差达到 23 167 106, 效果略差一点, 改进后的 ShuffleNetv2 参数量与 ShuffleNetv2 几乎没有区别, 但是识别效果有了较大的提升。荔枝冠层模型分类的最终效果如图 12 所示。

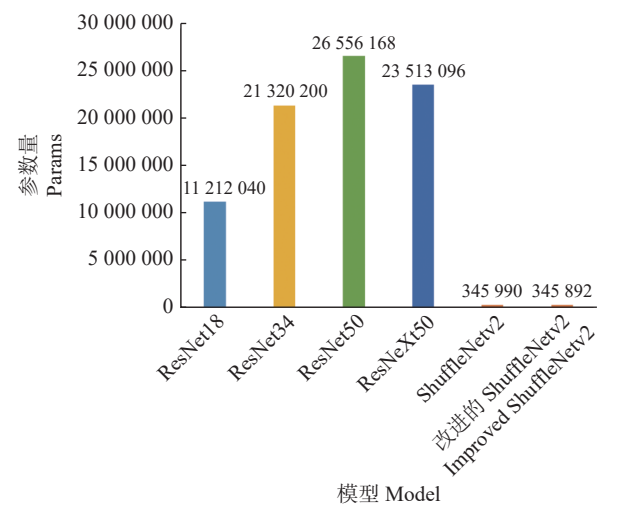


图 11 不同网络模型的参数量

Fig. 11 Parameters of different networks model




图 12 改进的 ShuffleNetv2 模型荔枝冠层分类效果

Fig. 12 Effect of improved shufflenetv2 model on litchi canopy classification

## 3 讨论与结论

### 3.1 讨论

本研究的荔枝花期遥感图像数据中,单棵荔枝冠层图像分辨率均较低,经过与 ResNet、ResNeXt 大量的对比试验发现,较深的卷积神经网络应用于本试验,会出现冠层特征消失、过拟合等问题,网络层数过多且没有明显地提升准确率,训练和识别速度比较慢,所以 ResNet、ResNeXt 网络不适用于本研究。在同样的参数设定下,轻量级网络 ShuffleNetv2 对本研究数据有着较好的拟合效果,未优化时准确率已达到 86.84%,与 ResNeXt50 相差 0.17 个百分点,且 ShuffleNetv2 的训练时间、验证时间有着绝对的优势,参数量最少。试验过程中发现,荔枝冠层花期第 2 类(开花率 50%~60%)误判率最高,识别精度难以有效提升,相比于 ResNet、ResNeXt 一贯地依靠增加网络层数来提升精度,ShuffleNetv2 的基础单元中加入了 Channel split,能够巧妙地有效学习第 2 类花期冠层的特征,且能够保持冠层特征不会消失。

将 ShuffleNetv2 进行主体结构优化,在阶段 2 后加入 SAM 模块,使得网络学习过程中注意面增宽,更加注意输入图像的位置信息,能够对荔枝冠层遥感图像进行更加精准的学习,更加关注荔枝冠层花的位置信息,从而能够更好地判断和识别花期所属的类别,进一步提升网络的泛化性和识别准确率,改进后的 ShuffleNetv2 分类准确率相比未优化的 ShuffleNetv2 提升 1.76 个百分点,相比 ResNeXt50 提升 1.59 个百分点,最终能达到 88.60%,且参数量和未优化的 ShuffleNetv2 相差甚微。在增加空间注意力模块和优化主干网络以后,训练时间反而会降低,因为模型更加关注荔枝花的部分,重点学习荔枝冠层的各项特征,有效剔除掉与花期无关的信息,所以训练速度会变快。本研究可以应用于大型荔枝园的花期评估,可以在很大程度上节省人力、物力和财力。方法上充分运用了迁移学习,节省了训练时间,能够充分地学习到冠层花期的特征。

### 3.2 结论

本文使用无人机采集荔枝冠层的可见光遥感图像,将遥感图像以实例分割的方法进行有效的冠层分割,得到单独每棵荔枝冠层的图像,将图像预处理后送入分类网络中。由于荔枝花期特征较为接近,识别较为困难,通过无人机获取遥感图像,在独特的视角下进行花期的分类。加入空间注意力模块,改进后的 ShuffleNetv2 能够挖掘学习更为细节

的荔枝冠层花期信息,不仅具有较高的识别精度,而且有着很快的训练和识别速度,对荔枝花期的评估有很大的优势。

本研究对荔枝冠层的遥感图像进行处理,实现了大型荔枝园的花期评估,同时降低了计算成本,具有很强的实时性,为荔枝花期的花量提供数据支撑,在荔枝研究领域有着很高的实用价值。同时本研究结果可以更好地被应用与推广,可以在不显著要求算力的情况下进行模型的推理,本研究的方法为其他种类果树的花期评估提供了一个新思路,利用轻量级网络对无人机拍摄的冠层图像进行花期的研究与评估。未来可以加入不同地区的果树冠层数据,提升数据的多样性,并结合地面摄像头数据,进一步提升模型识别效果。将模型精简后部署到边缘智能终端,节约算力资源,可以在无人机拍摄过程中,更快地实现花期的判断。

### 参考文献:

- [1] 李建国. 荔枝学[M]. 北京: 中国农业出版社, 2008.
- [2] 侯延杰, 秦献泉, 邱宏业, 等. 疏花对无核荔枝果实和树体营养的影响[J]. 中国南方果树, 2019, 48(5): 52-55.
- [3] 陈艳艳, 陈国帅, 罗红卫, 等. 不同时期修剪花穗对桂味荔枝花果发育的影响[J]. 中国南方果树, 2017, 46(4): 47-48.
- [4] 罗剑斌, 何凤, 王祥和, 等. 一疏二控三割控穗疏花技术提高“妃子笑”荔枝产量的生理原因分析[J]. 中国南方果树, 2019, 48(1): 20-24.
- [5] 胡福初, 何舒, 范鸿雁, 等. 不同留花量对 A4 无核荔枝开花坐果的影响[J]. 中国热带农业, 2014(6): 54-58.
- [6] 胡慧敏, 杨云, 肖秋生, 等. 疏花处理对晚熟荔枝开花坐果的影响[J]. 中国热带农业, 2020(4): 54-59.
- [7] WANG Z L, VERMA B, WALSH K B, et al. Automated mango flowering assessment via refinement segmentation[C]//International Conference on Image and Vision Computing New Zealand. Palmerston North, New Zealand: IEEE, 2016: 66-71.
- [8] YOUSEFI D B M, MOHD RAFIE A S, ABD AZIZ S, et al. Classification of oil palm female inflorescences anthesis stages using machine learning approaches[J]. Information Processing in Agriculture, 2021, 8(4): 537-549.
- [9] LU J, LIN W, CHEN P, et al. Research on lightweight Citrus flowering rate statistical model combined with anchor frame clustering optimization[J]. Sensors, 2021, 21(23): 7929. doi: 10.3390/s21237929.
- [10] 朱永宁, 周望, 杨洋, 等. 基于 Faster R-CNN 的枸杞开花期与果实成熟期识别技术[J]. 中国农业气象, 2020, 41(10): 668-677.
- [11] 杨其晟, 李文宽, 杨晓峰, 等. 改进 YOLOv5 的苹果花生长状态检测方法[J]. 计算机工程与应用, 2022, 58(4): 237-246.
- [12] 熊俊涛, 刘柏林, 钟灼, 等. 基于深度语义分割网络的荔



枝花叶分割与识别[J]. *农业机械学报*, 2021, 52(6): 252-258.

[13] 邓颖, 吴华瑞, 朱华吉. 基于实例分割的柑橘花朵识别及花量统计[J]. *农业工程学报*, 2020, 36(7): 200-207.

[14] 邓继忠, 任高生, 兰玉彬, 等. 基于可见光波段的无人机超低空遥感图像处理[J]. *华南农业大学学报*, 2016, 37(6): 16-22.

[15] PATHAK R, BARZIN R, BORA G C. Data-driven precision agricultural applications using field sensors and unmanned aerial vehicle[J]. *International Journal of Precision Agricultural Aviation*, 2018, 1(1): 19-23.

[16] YANG H B, ZHAO J, LAN Y B, et al. Fraction vegetation cover extraction of winter wheat based on spectral information and texture features obtained by UAV[J]. *International Journal of Precision Agricultural Aviation*, 2019, 2(2): 54-61.

[17] TAHIR M N, LAN Y B, ZHANG Y L, et al. Real time estimation of leaf area index and groundnut yield using multispectral UAV[J]. *International Journal of Precision Agricultural Aviation*, 2020, 3(1): 1-6.

[18] 杜蒙蒙, ROSHANIANFARD A, 刘颖超. 可见光波段无人机遥感图像的小麦茎蘖密度定量反演[J]. *光谱学与光谱分析*, 2021, 41(12): 3828-3836.

[19] 朱圣, 邓继忠, 张亚莉, 等. 基于无人机低空遥感的水稻田杂草分布图研究[J]. *华南农业大学学报*, 2020, 41(6): 67-74.

[20] 杨蜀秦, 刘江川, 徐可可, 等. 基于改进 CenterNet 的玉米雄蕊无人机遥感图像识别[J]. *农业机械学报*, 2021, 52(9): 206-212.

[21] MO J W, LAN Y B, YANG D Z, et al. Deep learning-based instance segmentation method of Litchi canopy from UAV-acquired images[J]. *Remote Sensing*, 2021, 13(19): 3919. doi: 10.3390/rs13193919.

[22] 李继宇, 胡潇丹, 兰玉彬, 等. 基于文献计量学的 2001-2020 全球农用无人机研究进展与展望[J]. *农业工程学报*, 2021, 37(9): 328-339.

[23] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, NV, USA: IEEE, 2016: 770-778.

[24] XIE S N, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, Hawaii, HI, USA: IEEE, 2017: 5987-5995.

[25] 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*. Las Vegas, NV, USA: IEEE, 2016: 2818-2826.

[26] ZHANG X Y, ZHOU X Y, LIN M X, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City, Utah, USA: IEEE, 2018: 6848-6856.

[27] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNet v2: Practical guidelines for efficient cnn architecture design[C]//*Proceedings of the European Conference on Computer Vision (ECCV)*. Cham: Springer, 2018: 122-138.

[28] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]//*Proceedings of the European Conference on Computer Vision (ECCV)*. Cham: Springer, 2018: 3-19.

【责任编辑 李晓卉】