doi:10.6041/j.issn.1000-1298.2025.11.047

基于 BMR－YOLO 11n－Pose 的蕖头关键点识别与分类方法

刘浩蓬[1,2]　杨云潇[1]　康启新[1]　张国忠[1,2]　张乐妍[1]　卫　佳[1,2]

（1. 华中农业大学工学院，武汉 430070；2. 农业农村部长江中下游农业装备重点实验室，武汉 430070）

摘要：针对蕖头形态不规则，在检测过程中存在特征表达失真、外形难以提取等问题，本文提出基于深度学习的多尺度关键点识别与分类方法，可通过识别蕖头顶点及横径的两端点提取其外形特征，同时基于决策树算法对蕖头尺寸和外形等特征进行准确分类。首先以 YOLO 11n－Pose 为基线模型，在颈部引入双层路由注意力机制（BRA）、特征增强层（MobileNet Variants）和通道混洗的重参数化卷积（RCS），构建了 BMR－YOLO 11n－Pose 模型。相较于基线模型，本文模型的关键点识别精确率（Pose－P）和检测框识别精确率（Box－P）分别提升 0.9、1.9 个百分点，其平均精度 $mAP_{0.5-0.95}$ 提升 1.9 个百分点。进而基于决策树算法对蕖头的外形特征分别进行尺寸分类和弯曲程度分类，其分类模型精确率分别为 92.87% 和 84.72%，相比原基线模型分别增加 11.19、8.39 个百分点，有效提升了蕖头外形特征的分类精度。本研究可为蕖头位姿识别和分类作业等应用场景提供理论参考和技术支撑。

关键词：蕖头识别；目标关键点检测；BMR－YOLO 11n－Pose；深度学习

中图分类号：S24　　**文献标识码**：A　　**文章编号**：1000-1298(2025)11-0490-09　　**OSID**：

Key Point Recognition and Classification Methods of *Allium chinense* Based on BMR－YOLO 11n－Pose

LIU Haopeng[1,2]　YANG Yunxiao[1]　KANG Qixin[1]　ZHANG Guozhong[1,2]　ZHANG Leyan[1]　WEI Jia[1,2]

(1. *College of Engineering*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*
2. *Key Laboratory of Agricultural Equipment in the Middle and Lower Reaches of the Yangtze River*, *Ministry of Agriculture and Rural Affairs*, *Wuhan* 430070, *China*)

Abstract: In response to the irregular morphology of *Allium chinense*, which led to the problems such as distorted feature representation and difficulty in extracting external contours during detection, a multi-scale keypoint recognition and classification method based on deep learning was proposed. By identifying the apex and the two endpoints of the transverse diameter of *Allium chinense*, its external contour features were extracted. Simultaneously, a decision tree algorithm was employed to classify the size and shape characteristics of *Allium chinense*. Initially, using YOLO 11n－Pose as the baseline model, a BMR－YOLO 11n－Pose model was constructed by introducing a bi-level routing attention (BRA) mechanism in the neck, a feature enhancement layer (MobileNet Variants), and a reparameterized convolution with channel shuffle (RCS). Compared with the baseline model, improvements of 0.9 and 1.9 percentage points in key point recognition accuracy (Pose－P) and bounding box recognition accuracy (Box－P) in the proposed model were achieved respectively, with an average precision ($mAP_{0.5-0.95}$) increase of 1.9 percentage points. Furthermore, based on the contour features, a decision tree algorithm was applied to classify the size of *Allium chinense*, the classification model accuracies were 92.87% and 84.72% respectively, representing improvements of 11.19 and 8.39 percentage points over the original baseline model, effectively enhancing the classification accuracy of *Allium chinense* appearance characteristics. The research result can provide theoretical references and technical support for application scenarios such as *Allium chinense* pose recognition and classification.

Key words: *Allium chinense* identification; target key point detection; BMR－YOLO 11n－Pose; deep learning

收稿日期：2025－03－17　修回日期：2025－05－28

基金项目：国家特色蔬菜产业技术体系专项（CARS－24－D－02）和湖北省高等学校优秀中青年科技创新团队计划项目（T201934）

作者简介：刘浩蓬（1989—），男，工程师，博士生，主要从事现代农业装备设计与测控研究，E-mail：liuhaopeng@mail.hzau.edu.cn

通信作者：卫佳（1983—），女，讲师，博士，主要从事智能农业装备检测与控制研究，E-mail：weijia@mail.hzau.edu.cn

0　引言

藠头(*Allium chinense* G. Don.)又名薤、荞头,为百合科葱属植物,具有清除亚硝酸盐、改善脂质代谢、抗血小板凝聚等多种药用功效,市场前景广阔[1-3]。中国部分地区藠头种植面积大、产量高,具有显著的经济效益和民生价值。然而,藠头形状不规则、尺寸一致性差[4-5],对藠头后期初加工的品质有较大影响,制约了藠头产业链的智能化发展。研究藠头自动识别技术可减少人工因重复作业疏忽、疲劳等出现作业精度和产品品质下降的问题,具有重要价值和实际意义。

藠头自动识别涉及目标关键点识别和精确分类 2 个方面。目标关键点识别方面,YOLO 系列算法在保证模型检测速度下可实现高精度目标识别,在精细农业研究中得到了广泛应用[6-7]。为提高作物识别准确度和对环境的适应性,研究学者对基础 YOLO 系列方法进行了改进,在有效保留识别目标的形状特征基础上,实现对目标关键点的识别。如结合轻量化目标检测方法,将多种自适应注意力机制加入 YOLO 基础模型,对草莓、三七、红花、苹果、柑橘等农作物进行了目标检测研究[8-16],有效提高了复杂环境下作物关键点的识别和定位精度[17]。目前,YOLO 11n－Pose[18]为 YOLO 系列对象检测小型化、轻量级模型的最新版本,相较之前版本最大的优势在于特征的增强提取,能提高关键点识别的平均精度和计算效率。

目标经过关键点识别后,可进行目标的精确分类。目标分类算法是机器学习中用于将数据划分到不同类别的核心方法,其中,决策树算法[19-21]为具有监督学习功能的基础分类方法之一。该方法通过树状结构的分裂规则(如信息增益或基尼系数)进行分类,直观易解释,被广泛应用于医疗诊断、商业决策中。

为进一步提升识别和分类精度,本文以藠头为研究对象,将藠头的横径两端点及顶点作为关键点信息,在 YOLO 11n－Pose 模型中通过引入颈部的双层路由注意力机制(BRA)[22]、颈部网络中添加 MobileNet Variants(Mobivari)[23]特征提取层,同时增加基于通道混洗的重参数化卷积(RCS)[24]优化 C3k2 模块,构建 BMR－YOLO 11n－Pose 模型,对藠头检测框和其外形特征分别进行精准定位与精确识别。而后,依据决策树分类方法对藠头的形状和尺寸进行准确分类。

1　材料与方法

1.1　试验环境和材料准备

本文中所涉及的藠头均选自湖北省咸宁市崇阳县等地广泛种植的大叶藠,数据集图像均采用分辨率为 1 920 像素 × 1 080 像素的无畸变相机进行拍摄。由于土壤不同情况导致传送带背景出现差异,会对藠头的识别产生一定影响,故考虑无土壤、有较大土块、灰色细颗粒土壤、黄色干土壤、棕色高含水率土壤等 5 种情况对分拣传送带上的藠头图像进行采集。拍摄时相机与传送带位置相对固定,拍摄高度为 520 mm,在藠头拍摄平面,图像坐标系中 0.58 个像素为世界坐标系中的 1 mm。

1.2　图像采集和数据集制作

经过裁剪无用部分后,得到分辨率为 750 像素 × 680 像素的藠头图像 710 幅,使用 Labelme 软件对图像中藠头位置以及每个藠头的顶点和藠头横径两端点进行标注,并按照比例 8∶1∶1将图像随机划分为训练集、验证集和测试集。为了提高模型的泛化能力且防止模型在训练过程中过拟合,经过添加高斯噪声、颜色抖动、亮度调节等方法对数据集进行增强,增强后训练集、验证集、测试集分别包含 2 840、355、355 幅图像,增强后的图像如图 1 所示。

1.3　YOLO 11n－Pose 算法改进

YOLO 11n－Pose 网络主要由检测头(Head)、颈部连接网络(Neck)以及主干网络(Backbone)3 部分组成。为了提高模型对藠头的关键点检测性能,将颈部的 C2PSA(Convolutional block with parallel spatial attention)模块替换为基于视觉 Transformer 的双层路由注意力机制(Bi-level routing attention,BRA),有利于捕捉图像长距离依赖关系;并将主干网络中的 C3k2(Cross stage partial with kernel size 2)模块和基于通道混洗的重参数化卷积(Reparameterized convolution based on channel shuffle,RCS)融合为 C3k2_RepVGG,在降低推理计算复杂度的同时提高通道间信息交换能力,而在训练时能够学习更丰富的特征信息;而在检测头的下采样后插入 MobileNet Variants 模块,以深度可分离卷积为核心层,在增加少量计算复杂度的情况下能够进一步增强模型的特征学习能力。图 2 为 BMR－YOLO 11n－Pose 网络结构图。

1.3.1　基于视觉 Transformer 的 BRA 注意力机制

针对藠头形状不规则、关键点分布分散的特点,本研究在 YOLO 11n－Pose 的颈部网络引入双层路由注意力机制(BRA)。作为视觉转换器的核心构建块,注意力机制是捕捉长距离依赖关系的强大工具[22]。BRA 通过动态筛选图像中与关键点相关的区域(如横径端点、顶点),增强模型对长距离特征的感知能力。具体而言,BRA 首先将特征图划分为若干区域,在粗粒度层级筛选出与藠头关键点相关

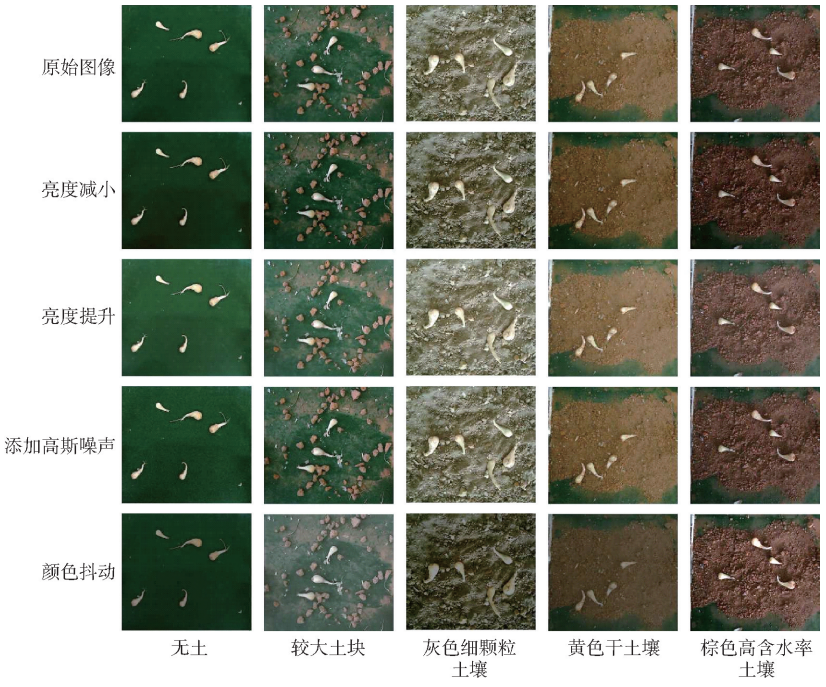


图 1 数据集增强效果对比图

Fig. 1 Comparison diagram of dataset enhancement effects

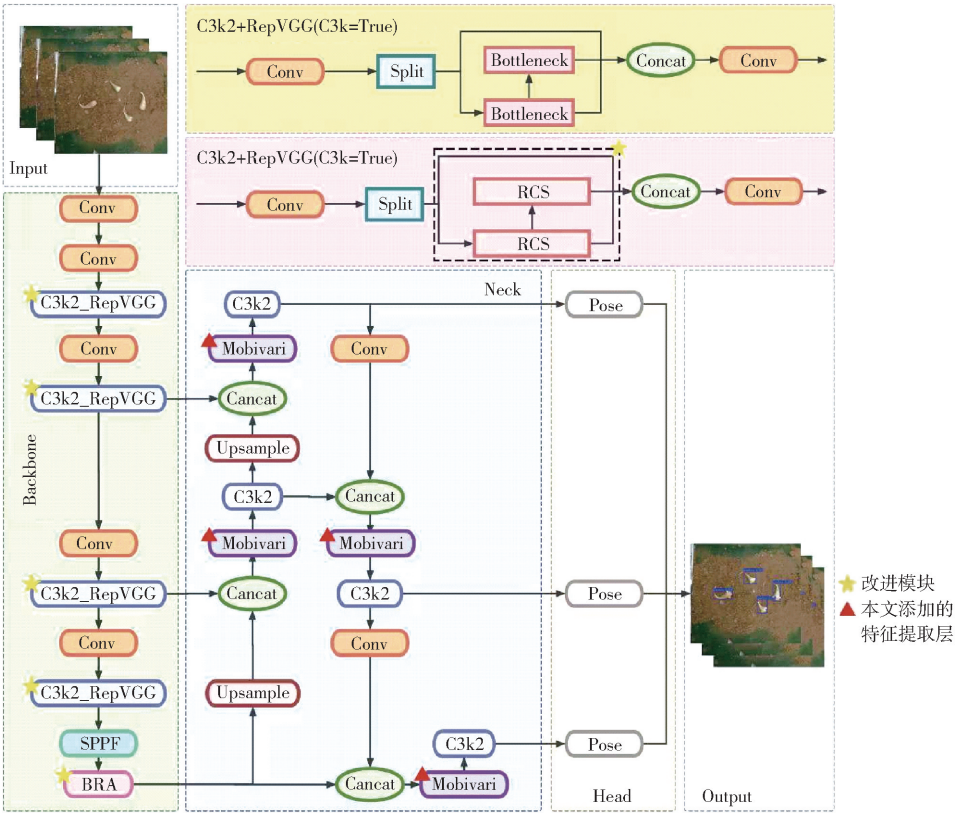


图 2 BMR－YOLO 11n－Pose 网络结构图

Fig. 2 Network architecture diagram of BMR－YOLO 11n－Pose

性高的区域,并在细粒度层级通过局部注意力机制聚焦于关键点的细节特征。这一设计有效解决了因菌头外形复杂、背景干扰(如土壤、光照变化)导致的特征提取不完整问题,显著提升了关键点定位精度。BRA 的结构图如图 3 所示,图中 mm 为矩阵乘法运算,gather 为从路由索引矩阵中的收集操作。

1.3.2 MobileNet Variants 特征增强层

MobileNet 以深度可分离卷积(Depthwise separable convolution)为核心层,包含深度卷积(Depthwise convolution)和逐点卷积(Pointwise convolution)两部分,深度卷积能够分别对每个通道的特征进行学习,捕捉到不同通道的局部特征,而逐

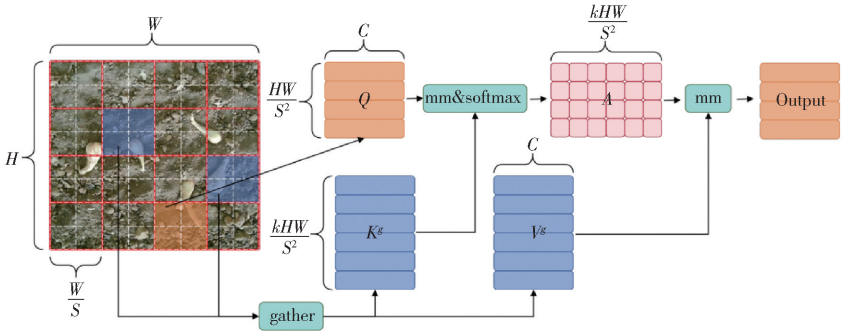


图 3　双层路由注意力机制结构图

Fig. 3　Structure diagram of double-layer routing attention mechanism

点卷积则可以实现通道间的信息融合，增强特征的表达能力[21]。首先经过深度卷积和激活函数对不同通道的输入特征进行提取，再使用逐点卷积和激活函数实现通道间信息交流，并用残差连接将原始输入的特征图分别和两次卷积结果相融合，使模型在一定程度上保留输入特征信息。

1.4　蒜头特征提取方法

根据改进的 YOLO 11n－Pose 模型识别出的蒜头检测框位置以及蒜头顶点、两横径端点坐标对拍摄蒜头进行特征提取，并建立蒜头外形特征空间，便于使用决策树算法对蒜头进行尺寸和形状分级，蒜头识别关键点的示意图如图 4 所示。

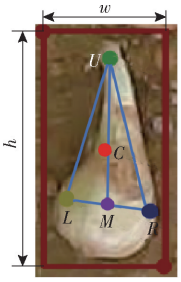


图 4　蒜头关键点模型示意图

Fig. 4　Schematic of key point model for *Allium chinense*

在图 4 中，h 表示检测框高度，w 表示检测框宽度，点 U 表示识别到的蒜头顶点，点 L、R 分别表示蒜头横径的左右端点，点 C 表示检测框的对角线交点，点 M 表示点 L、R 连线的中点，通过识别以及计算出的点位，提取出蒜头的 18 个外形特征，如表 1 所示。

表 1　蒜头外形特征

Tab. 1　Classification of external features of *Allium chinense*

特征类型	特征描述
关键点坐标	U、C、R、M、L 5 个点的像素坐标
线段长度(距离)	h、w、UL 连线、UR 连线、LR 连线
角度正切值	$\tan(\angle URL)$、$\tan(\angle ULR)$、$\tan(\angle RUL)$、UM 和 LR 连线的锐角夹角的正切值
其他	$h\times w$、h/w、输入图像的分辨率($x\times y$)

1.5　决策树分类算法

决策树(Decision tree)算法是一种基于机器学习的分类算法，利用基于递归分割特征的方法，对输入蒜头特征进行分类。其中，决策树的叶节点是蒜头分类种类，除叶节点外的节点为特征属性，本文使用基于基尼系数(Gini index)衡量节点纯度以表征特征重要性的 CART(Classification and regression trees)算法构建蒜头特征分类的决策树模型，基尼纯度计算公式为

$$\mathrm{Gini}(D)=1-\sum_{k=1}^{K}p_k^2 \tag{1}$$

式中　p_k——类别 k 在数据集 D 中的概率

对于每个蒜头特征 A，在分类问题中其基尼系数的计算公式为

$$\mathrm{Gini}_A(D)=\frac{|D_1|}{|D|}\mathrm{Gini}(D_1)+\frac{|D_2|}{|D|}\mathrm{Gini}(D_2) \tag{2}$$

式中　D_1、D_2——通过 A 进行划分后 2 个子节点的样本量

$\mathrm{Gini}(D_1)$、$\mathrm{Gini}(D_2)$——两类各自的基尼系数

本文利用提取出的 18 个蒜头外形特征将对应蒜头按照标准 QB/T 1400—2024 分为大果、中果、小果 3 类。设蒜头横径为大于等于 21 mm、16 ~ 21 mm、10 ~ 16 mm，分别对应大果、中果和小果。并人工标注了按照尺寸分类的蒜头特征数据以及对应标签共 547 组，按照比例 7∶3 划分为训练集和测试集，经过训练后的决策树模型在测试集上分类准确率达到 99%，并使用该模型对 YOLO 11n－Pose 模型和 BMR－YOLO 11n－Pose 模型识别出的蒜头进行尺寸分类。此外，本文根据蒜头的果柄的弯曲程度和尺寸分为大果弯柄、大果直柄、中果弯柄、中果直柄 4 类，人工标注综合弯曲程度和尺寸的蒜头特征数据以及对应标签共 517 组，按照比例 7∶3 划分为训练集和测试集，经过训练后的决策树模型在测试集上对该任务的分类准确率达

到 94%,并基于决策树模型对 YOLO 11n - Pose 模型和 BMR - YOLO 11n - Pose 模型识别出的蕞头进行形状分类。

2 试验结果与分析

2.1 训练环境与模型超参数设置

针对 YOLO 11n - Pose 模型及其改进模型的算法设计、试验过程所用环境均相同,操作系统为 Windows 10,Python 解释器版本为 3.9,所用 GPU 为 NVIDIA GTX 3060,显存为 12 GB,CPU 为 Intel Xeon Gold 6146,计算频率为 3.20 GHz。设置学习率为 0.01,每次迭代的批量大小为 8,训练轮数为 100,输入图像尺寸为 640 像素 ×640 像素。模型训练与调试均在此基础上进行。

2.2 评价指标

本文中使用在关键点检测任务中广泛应用的检测框识别精确率 Box - P、关键点识别精确率 Pose - P、关键点预测平均精度 $mAP_{0.5-0.95}$、检测帧率以及模型内存占用量作为评价指标,能够反映出模型的检测框、关键点的识别准确率以及模型的检测速度、内存占用量。

2.3 结果分析

模型改进前后检测效果如图 5 所示,改进后模型相比于基线模型,能更好地识别蕞头的外形特征,一定程度上避免了由于颜色与土壤相似导致的漏识别以及因蕞头外皮形状相似导致的误识别,改进后模型受环境因素影响更小,且重复检测、存在关键点偏差等问题也得到了一定改善。

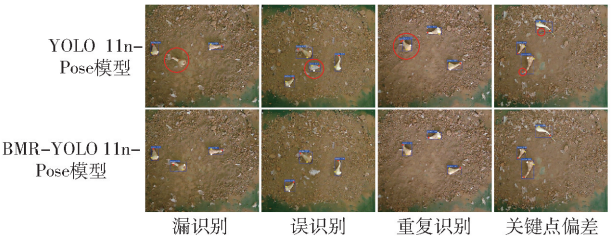


图 5 改进前后检测效果对比

Fig. 5 Comparison of detection effects before and after improvement

对测试集中无土、较大土块、灰色细颗粒土壤、黄色干土壤、棕色高含水率土壤 5 种土壤背景的图像(每种背景图像数量均为 71 幅)。使用改进前后的 YOLO 11n - Pose 模型进行关键点识别试验验证,模型对比结果如表 2 所示。

表 2 不同土壤背景下的改进前后模型对比

Tab. 2 Comparison of models before and after improvement under different soil backgrounds

参数	无土		较大土块		灰色细颗粒土壤		黄色干土壤		棕色高含水率土壤	
	模型 1	模型 2	模型 1	模型 2	模型 1	模型 2	模型 1	模型 2	模型 1	模型 2
检测框识别精确率/%	86.3	86.8	88.0	89.7	87.2	87.4	89.6	90.7	87.9	88.9
关键点识别精确率/%	87.5	88.7	87.4	90.2	87.0	88.6	89.0	89.8	86.6	89.7
预测平均精度/%	96.85	96.92	97.52	97.98	97.65	97.93	98.61	98.63	97.62	97.74

注:表中模型“1”为原 YOLO 11n - Pose 模型,“2”为本文提出的 BMR - YOLO 11n - Pose 模型。

从表 2 可知,在无土、较大土块、灰色细颗粒土壤、黄色干土壤、棕色高含水率土壤 5 种土壤背景情况下,BMR - YOLO 11n - Pose 模型相较于原 YOLO 11n - Pose 模型检测关键点 $mAP_{0.5-0.95}$ 分别提升 0.07、0.46、0.28、0.02、0.12 个百分点,其中较大土块背景和灰色细颗粒土壤背景下的平均精确率提升幅度较大。

为了探究不同光照影响下改进前后模型对蕞头关键点识别的影响,对于在强光照射、自然光以及昏暗环境下拍摄的蕞头图像进行识别试验,得到识别结果如图 6 所示。

从图 6 可知,YOLO 11n - Pose 模型在强光环境和自然光环境下均出现了不同程度的误识别情况,在昏暗环境中出现了严重漏识别情况。而 BMR - YOLO 11n - Pose 模型在上述 3 种环境下的表现均优于基线模型。由于本文模型在训练集中并未加入不同光照强度的图像,而是通过使用数据增强技术

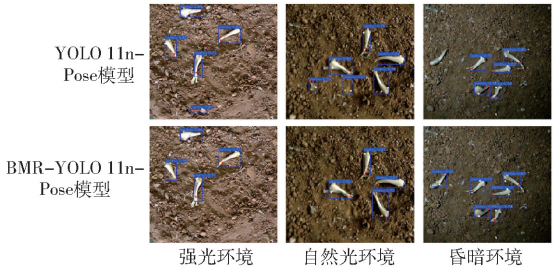


图 6 不同光照情况下 YOLO 11n - Pose 模型和 BMR - YOLO 11n - Pose 模型识别结果

Fig. 6 YOLO 11n - Pose and BMR - YOLO 11n - Pose recognition results under varying lighting conditions

来提高模型在不同光照条件下的适应能力,因此在识别以外部环境光照为变量的蕞头图像时,会出现性能下降及少数关键点识别不准的情况。

2.4 模型消融试验

为进一步验证 BMR - YOLO 11n - Pose 模型性能提升效果,对 3 个改进模块进行消融试验,为确保结果准确、有效,所使用的数据集、模型超参数以及

运行环境均一致，消融试验结果如表 3 所示。

表 3　消融试验结果

Tab. 3　Results of ablation experiment

BRA	RCS	Mobivari	检测框识别精确率/%	关键点识别精确率/%	预测平均精度/%	帧率/(f·s^{-1})	模型内存占用量/MB
－	－	－	87.8	87.5	97.65	60.95	5.38
√	－	－	84.9	87.2	97.57	60.16	5.40
－	√	－	82.3	86.5	97.80	63.49	5.38
－	－	√	85.5	88.8	97.74	61.44	6.17
√	√	－	90.2	89.0	97.78	61.28	5.41
√	－	√	89.4	89.5	97.63	58.12	6.20
－	√	√	83.3	86.6	97.81	58.84	6.18
√	√	√	88.7	89.4	97.84	58.95	5.91

注：“√”表示选择融合该模块，“－”表示不选择融合该模块。

由表 3 可知，仅加入 C3k2_RepVGG 模块时，在 Box－P 和 Pose－P 分别下降 5.5、1.0 个百分点的情况下，模型帧率提高 2.54 f/s，而同时引入 C3k2_RepVGG 模块和 Mobivari 特征提取模块时，模型精度下降的情况有所缓解，且模型检测速度仍有提高。在同时引入 C3k2_RepVGG 模块和 BRA 注意力机制时，模型的 Box－P、Pose－P 和预测平均精度 $mAP_{0.5-0.95}$ 分别提高 2.4、1.5、0.13 个百分点，且帧率提高 0.33 f/s。同时引入 BRA 注意力机制和 Mobivari 特征增强层时，虽然 Box－P 和 Pose－P 提高至 89.4% 和 89.5%，但是模型检测速度降至 58.12 f/s 且模型内存占用量增大至 6.20 MB。经过综合考量，选择同时引入 BRA、C3k2_RepVGG 和 Mobivari 3 种改进模块，在牺牲较少的模型检测速度下，使得模型具有更精确的检测能力。改进后模型相比于基线模型，检测框精确率提高 0.9 个百分点，关键点精确率提高 1.9 个百分点，$mAP_{0.5-0.95}$ 提高 0.19 个百分点。BMR 模型识别速度下降 2 f/s，然而模型仍满足菖头实时检测要求。虽然本文所提的 BMR 模型性能指标相比基线模型改进提高较小，但却对本文后续用于分类的决策树算法在分类性能的提升发挥了重要基础作用。该模型将 BRA 注意力机制、MobileNet Variants 特征增强层、RCS 模块共同引入 YOLO 11n－Pose 模型中。3 个模块中任一单独模块侧重点不同，各自保留了算法优点，而单独一种模块达不到保留特征的效果，因此本文将 3 个模块结合，通过 3 个模块间的相互作用使菖头重要特征能被准确提取。

2.5　不同 YOLO 模型的横向对比实验

为了客观比较 BMR－YOLO 11n－Pose 模型的性能，将改进后模型与常用于关键点识别任务的 YOLO v8－Pose 和 YOLO v8－Pose－p6 相比较，对比分析结果如表 4 所示。

表 4　YOLO 系列模型对比试验结果

Tab. 4　Comparative experimental results of YOLO series models

模型	检测框识别精确率/%	关键点识别精确率/%	预测平均精度/%	帧率/(f·s^{-1})	模型内存占用量/MB
YOLO v8－Pose	85.2	80.8	97.80	68.00	5.52
YOLO v8－Pose－p6	88.6	87.4	98.60	56.90	8.78
YOLO 11n－Pose	87.8	87.5	97.65	60.95	5.38
BMR－YOLO 11n－Pose	88.7	89.4	97.84	58.95	5.91

由表 4 可见，BMR－YOLO 11n－Pose 模型相比于 YOLO v8－Pose，虽然帧率降低 7.05 f/s，改进后模型的 Box－P 上升 3.5 个百分点，Pose－P 上升 8.6 个百分点。而与 YOLO v8－Pose－p6 相比，BMR－YOLO 11n－Pose 模型虽然 $mAP_{0.5-0.95}$ 下降 0.76 个百分点，但是检测帧率达到 58.95 f/s 且模型内存占用量下降 32.69%。

2.6　模型注意力热图可视化

为了分析注意力机制的变化，检验改进算法后注意力机制的有效性是否提高，采用 Grad－CAM＋＋算法[27]进行分析，针对黄色干燥土壤、较大土块、灰色细颗粒土壤的菖头识别结果，得到模型注意力热图，如图 7 所示。

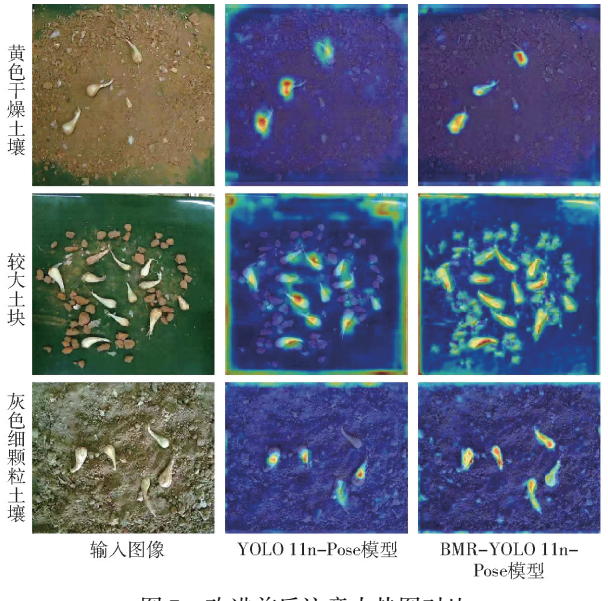


图 7　改进前后注意力热图对比

Fig. 7　Comparison of attention heatmaps before and after improvement

热力图通过颜色的深浅或强度来表示数据值的大小，颜色渐变通常从冷色调（如蓝色）过渡到暖色调（如红色），其中暖色部位代表数据值较高的区域，冷色部位代表数据值较低的区域，数据值越高，

表明模型对该区域的特征信息关注度越高。通过对比可发现,在土块环境下,改进前后的模型均表现良好,但原有的 YOLO 11n－Pose 模型注意力较分散,有部分分布在识别目标之外。而在沙质土壤和干燥土壤中,YOLO 11n－Pose 模型对各蕞头的注意力面积较小,甚至有一处漏识别,而 BMR－YOLO 11n－Pose 模型对目标均有较强且均匀的注意力分布。研究表明,BMR－YOLO 11n－Pose 模型在不同环境下,均表现出良好的性能,相比于原模型能够更加关注图像重要部分的特征信息。

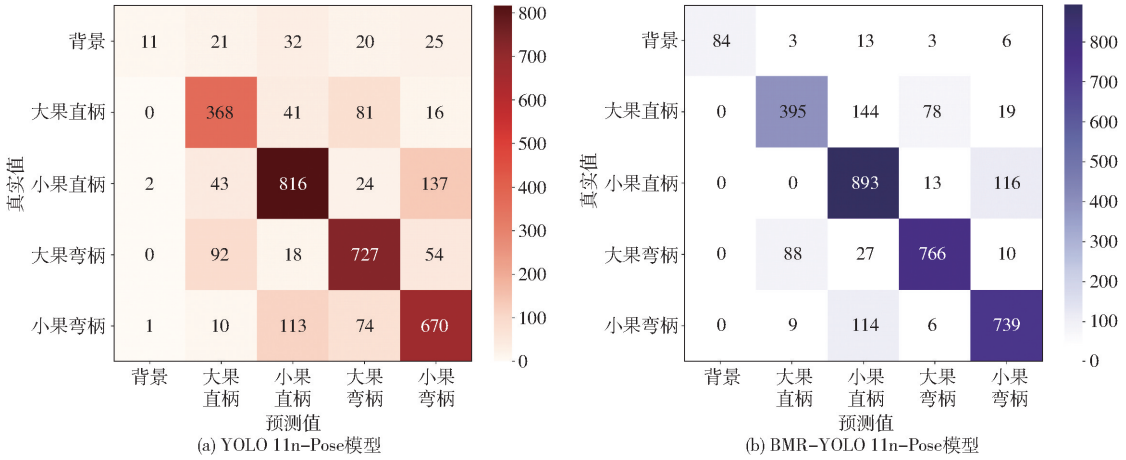
2.7 改进前后决策树分类算法比较

为了验证 BMR－YOLO 11n－Pose 对决策树分类性能的影响,使用 YOLO 11n－Pose 和 BMR－YOLO 11n－Pose 识别相同的 171 幅多蕞头图像,分别输出 573 和 547 组蕞头特征数据,并输入预训练的按照蕞头尺寸进行分类决策树模型中,得到分类结果如表 5 所示,并绘制出混淆矩阵,如图 8 所示。2 种模型输出数据存在差异,是由于在识别过程中存在漏识别和多识别问题,在训练决策树模型时考虑到该问题并将这种情况下的标签设置为

表 5 决策树尺寸分类结果

Tab. 5 Three-class classification results of decision tree

模型	准确率/%	精确率/%	召回率/%	F1 值/%	大果分类精确率/%	中果分类精确率/%	小果分类精确率/%	帧率/($f \cdot s^{-1}$)
YOLO 11n－Pose＋决策树	81.68	69.45	73.26	70.84	85.50	65.85	50	60.55
BMR－YOLO 11n－Pose＋决策树	92.87	93.34	82.36	85.70	93.75	90.24	50	58.53



(a) YOLO 11n-Pose模型 (b) BMR-YOLO 11n-Pose模型

图 8 改进前后决策树按尺寸分类结果的混淆矩阵

Fig. 8 Confusion matrix for size-based classification results between original and improved decision tree

“background”,以避免特殊情况数据干扰数据准确性。

由于选用蕞头品类为大叶蕞,其平均果径为 18.28 mm,且播种时蕞头种子样本经过初步筛选,导致在构建的样本集中,小果类别数据表现出明显的稀疏性,因此,表 5 中的蕞头尺寸分类不考虑小果直柄和小果弯柄的分类情况。

由表 5 结果分析可知,使用改进后模型的分类准确率和 F1 值较改进前的指标均有显著提升,基于决策树模型对 YOLO 11n－Pose 和 BMR－YOLO 11n－Pose 模型输出信息进行分类,蕞头尺寸分类准确率分别为 81.68% 和 92.87%,分类准确率提高 11.19 个百分点,F1 值提高 14.86 个百分点。同时改进后算法对大果和中果的分类精确率也明显提升,均达到 90% 以上,尤其对于蕞头中果识别精确率相比基线模型提高 24.39 个百分点。分类的性能数据表明,BMR－YOLO 11n－Pose 和决策树模型两者的结合对蕞头分类性能提升发挥了关键作用。其中,基于 BMR－YOLO 11n－Pose 的关键点检测性能的微小提升对下游任务(如分类任务等)分类效果增强起到了明显放大作用,同时该分类模型也能保持良好的实时性,满足实时分类要求。

为进一步研究多分类因素交叉情况下 BMR－YOLO 11n－Pose 模型关键点识别的准确性,分别采用 YOLO 11n－Pose 和 BMR－YOLO 11n－Pose 识别同一组 1 078 幅多蕞头图像,分别输出蕞头外形特征数据 3 396 组和 3 325 组。同理,将误识别的标签设置为“background”,避免少量数据干扰测试准确性。决策树曲柄-直柄分类结果如表 6 所示。

由表 6 可知,在综合了蕞头尺寸和蕞头弯曲程度的决策树分类任务中,BMR－YOLO 11n－Pose 模型分类精确率为 84.72%,相比于原模型提升

表 6　决策树曲柄-直柄分类结果

Tab. 6　Three－class classification results of decision tree

模型	准确率/%	精确率/%	召回率/%	F1 值/%	大果直柄分类精确率/%	中果直柄分类精确率/%	大果曲柄分类精确率/%	中果曲柄分类精确率/%	帧率/(f·s^{-1})
YOLO 11n－Pose＋决策树	76.33	76.05	64.29	64.86	68.91	80.00	78.51	74.28	60.55
BMR－YOLO 11n－Pose＋决策树	84.72	87.09	82.72	84.60	79.80	84.17	88.45	83.03	58.53

8.39 个百分点，且 F1 值提升 19.74 个百分点，显著优于 YOLO 11n－Pose 模型，大果曲柄、中果直柄和中果曲柄的分类精确率也均在 80% 以上，其中大果直柄精确率接近 80%。

综上所述，本文提出的模型为决策树算法提供的特征信息，在多种分类任务中的性能指标均优于原基线模型，这说明改进后的算法能更加精确地识别图像中蒜头的关键点，更大程度上保留了蒜头的外形特征信息。由于蒜头的识别和分类数据均为二维图像，较难从三维尺度上对蒜头特征进行提取，在一定程度对蒜头分类精度会产生负面影响。

3　结论

（1）本文针对蒜头形态不规则、特征提取困难等问题，提出了一种基于改进 YOLO 11n－Pose 算法的多尺度关键点识别与分类方法，并结合决策树算法实现了蒜头外形特征的精确分类。

（2）通过在 YOLO 11n－Pose 模型中引入 BRA、MobileNet Variants 特征增强层和 RCS 三模块，构建了 BMR－YOLO 11n－Pose 模型。试验结果表明，改进后模型的关键点识别精确率和检测框识别精度分别提升 0.9、1.9 个百分点，平均精度 $mAP_{0.5-0.95}$ 提升 0.19 个百分点。同时，模型在复杂背景（如不同土壤类型和光照条件）下表现出更强的鲁棒性。

（3）基于提取的 18 个蒜头外形特征，采用决策树算法对蒜头尺寸和弯曲程度进行分类，分类效果明显提升。在测试集上，尺寸分类准确率达到 92.87%，较原模型提升 11.19 个百分点；弯曲程度分类准确率达到 84.72%，提升 8.39 个百分点。研究表明 BMR－YOLO 11n－Pose 模型在关键点识别和特征提取上具有优越性。

（4）本研究为蒜头的自动化分拣、夹持等作业提供了一种高效、准确的解决方案和可靠的技术支持，具有重要的理论意义和应用价值。改进后的模型在保持较高检测速度（帧率 58.94 f/s）的同时，提升了蒜头外形特征的识别和分类精度，满足蒜头实时作业需求。

参　考　文　献

[1] 杨定宽，季香青，曾承，等. 泡蒜头中挥发性风味物质分析[J]. 食品安全质量检测学报，2021，12(12)：4978－4983.
YANG Dingkuan, JI Xiangqing, ZENG Cheng, et al. Analysis of volatile flavor compounds in soaked *Allium chinense*[J]. Journal of Food Safety and Quality Inspection, 2021, 12(12): 4978－4983. (in Chinese)

[2] 杨敏，梅馨月，廖静静，等. 三种葱属作物挥发物和提取液对植物病原真菌和卵菌的抑菌活性[J]. 植物保护，2013，39(3)：36－44.
YANG Min, MEI Xinyue, LIAO Jingjing, et al. Antibacterial activity of three volatile compounds and extracts from *Allium* crops against plant pathogenic fungi and oomycetes[J]. Plant Protection, 2013, 39(3): 36－44. (in Chinese)

[3] THEJANUO R, R S, M S R, et al. Chemical constituents, antioxidant, and antimicrobial activity of *Allium chinense* G. Don [J]. Future Journal of Pharmaceutical Sciences, 2020, 6(1－2): 1－9.

[4] 康启新，张国忠，郑侃，等. 勺夹式蒜头排种器设计与试验[J]. 农业工程学报，2023，39(5)：15－25.
KANG Qixin, ZHANG Guozhong, ZHENG Kan, et al. Design and test of spoon-clamped scallion seed dispenser[J]. Transactions of the CSAE, 2023, 39(5): 15－25. (in Chinese)

[5] 曲永波，方志超，柳亚峰，等. 振动和拨辊推送式蒜头收获机研制[J]. 农业工程学报，2022，38(19)：51－59.
QU Yongbo, FANG Zhichao, LIU Yafeng, et al. Development of vibrating and dial roller push scallion harvester[J]. Transactions of the CSAE, 2022, 38(19): 51－59. (in Chinese)

[6] 周中猛，王伟，沈士哲. 基于机器视觉的圆茄果实大小分类研究[J]. 林业机械与木工设备，2024，52(11)：62－65，71.
ZHOU Zhongmeng, WANG Wei, SHEN Shizhe. Research on machine vision based classification of round eggplant fruit size [J]. Forestry Machinery and Woodworking Equipment, 2024, 52(11): 62－65, 71. (in Chinese)

[7] 翟肇裕，张梓涵，徐焕良，等. YOLO 算法在动植物表型研究中应用综述[J]. 农业机械学报，2024，55(11)：1－20.
ZHAI Zhaoyu, ZHANG Zihan, XU Huanliang, et al. Review of applying YOLO family algorithms to analyze animal and plant phenotype[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 1－20. (in Chinese)

[8] 刘莫尘，褚镇源，崔明诗，等. 基于改进 YOLO v8－Pose 的红熟期草莓识别和果柄检测[J]. 农业机械学报，2023，54(增

刊2):244 - 251.
LIU Mochen, CHU Zhenyuan, CUI Mingshi, et al. Red ripe strawberry recognition and stem detection based on improved YOLO v8 Pose[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 2): 244 - 251. (in Chinese)
[9] 王法安,何忠平,张兆国,等. 基于 PN - YOLO v8s - Pruned 的轻量化三七收获目标检测方法[J]. 农业机械学报,2024,55(11):171 - 183.
WANG Fa'an, HE Zhongping, ZHANG Zhaoguo, et al. Lightweight object detection method for *Panax notoginseng* based on PN - YOLO v8s - Pruned[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 171 - 183. (in Chinese)
[10] 郭辉,陈海洋,高国民,等. 基于 YOLO v5m 的红花花冠目标检测与空间定位方法[J]. 农业机械学报,2023,54(7):272 - 281.
GUO Hui, CHEN Haiyang, GAO Guomin, et al. Red flower crown object detection and spatial localization method based on YOLO v5m[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 272 - 281. (in Chinese)
[11] 莫恒辉,魏霖静. 基于改进 YOLOv7 的复杂环境下苹果目标检测[J]. 浙江大学学报(工学版),2024,58(12):2447 - 2458.
MO Henghui, WEI Linjing. Apple object detection in complex environments based on improved YOLOv7[J]. Journal of Zhejiang University(Engineering Edition), 2024, 58(12): 2447 - 2458. (in Chinese)
[12] 李丽,梁继元,张云峰,等. 基于改进 YOLO v5 的复杂环境下柑橘目标精准检测与定位方法[J]. 农业机械学报,2024,55(8):280 - 290.
LI Li, LIANG Jiyuan, ZHANG Yunfeng, et al. Accurate detection and localization method of citrus targets in complex environments based on improved YOLO v5[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 280 - 290. (in Chinese)
[13] 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)
[14] 张惠莉,代晨龙,任景龙,等. 基于 YOLO v8 - GSGF 模型的葡萄病害识别方法研究[J]. 农业机械学报,2024,55(11): 75 - 83.
ZHANG Huili, DAI Chenlong, REN Jinglong, et al. Grape disease identification method based on YOLO v8 - GSGF model [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 75 - 83. (in Chinese)
[15] 张传栋,高鹏,亓璐,等. 基于 SAW - YOLO v8n 的葡萄幼果轻量化检测方法[J]. 农业机械学报,2024,55(10):286 - 294.
ZHANG Chuandong, GAO Peng, QI Lu, et al. Lightweight detection method for young grape cluster fruits based on SAW - YOLO v8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 286 - 294. (in Chinese)
[16] 肖伸平,赵倩颖,曾甲元,等. 基于 YOLO - DCL 的复杂环境油茶果遮挡检测与计数研究[J]. 农业机械学报,2024,55(10):318 - 326,480.
XIAO Shenping, ZHAO Qianying, ZENG Jiayuan, et al. Research on complex environment oil tea fruit occlusion detection and counting based on YOLO - DLC[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 318 - 326,480. (in Chinese)
[17] XIA C. Rapid strawberry ripeness detection and 3D localization of picking point based on improved YOLO V8 - Pose with RGB camera[J]. Journal of Electrical Systems, 2024, 20(3s): 2171 - 2187.
[18] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements[J]. arXiv preprint arXiv:2410.17725, 2024.
[19] QUINLAN J R. Decision trees and decision-making[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1990, 20(2): 339 - 346.
[20] PODGORELEC V, KOKOL P, STIGLIC B, et al. Decision trees: an overview and their use in medicine[J]. Journal of Medical Systems, 2002, 26: 445 - 463.
[21] BELL K, REED M. The tree of participation: a new model for inclusive decision-making[J]. Community Development Journal, 2022, 57(4): 595 - 614.
[22] ZHU L, WANG X, KE Z, et al. Biformer: vision transformer with bi-level routing attention[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 10323 - 10333.
[23] CHOI H, NA C, OH J, et al. Ramit: reciprocal attention mixing transformer for lightweight image restoration[C]// 2024 IEEE/CVF Conference on Computer Vison and Pattern Recognition Workshops (CVPRW), 2024.
[24] KANG M, TING C M, TING F F, et al. RCS - YOLO: a fast and high-accuracy object detector for brain tumor detection[C] // International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer Nature Switzerland, 2023: 600 - 610.