

基于改进YOLOv11的野外中草药目标检测

李江东¹, 于海峰¹, 田立茹², 刘怡涵¹

¹华北理工大学电气工程学院, 河北 唐山

²华北理工大学中医学院, 河北 唐山

收稿日期: 2026年3月26日; 录用日期: 2026年4月30日; 发布日期: 2026年5月14日

摘要

为解决野外复杂场景下中草药检测存在的小目标漏检、背景干扰大、模型计算冗余等问题, 提升检测精度与效率, 本文以YOLOv11为基础开展针对性改进研究。方法上, 将SPPF模块替换为AIFI模块降低计算复杂度并整合全局信息; 采用Dysample模块替代传统上采样, 增强遮挡模糊目标的细节恢复能力; 新增小目标检测层扩大尺度覆盖, 同时嵌入CBAM双注意力模块抑制背景干扰、聚焦关键特征。实验表明, 改进模型mAP@0.5为81.2%, 较基线YOLOv11n提升2.9个百分点, GPU端FPS为266, 参数量仅2.80 M, 大幅提升了复杂场景下的检测精度与运行效率, 为野外中草药资源的智能化识别、调查与保护提供了可靠技术支撑。

关键词

YOLOv11改进, 野外中草药检测, 小目标检测, 注意力机制, 实时目标检测2.9

Object Detection of Wild Chinese Herbal Medicines Based on Improved YOLOv11

Jiangdong Li¹, Haifeng Yu¹, Liru Tian², Yihan Liu¹

¹College of Electrical Engineering, North China University of Science and Technology, Tangshan Hebei

²Traditional Chinese Medical College, North China University of Science and Technology, Tangshan Hebei

Received: March 26, 2026; accepted: April 30, 2026; published: May 14, 2026

Abstract

To address the issues of small target missed detection, severe background interference, and redundant model computation in Chinese herbal medicine detection under complex field scenarios, and to improve detection accuracy and efficiency, this paper conducts targeted improvement research based on YOLOv11. Methodologically, the SPPF module is replaced with the AIFI module to reduce

computational complexity and integrate global information; the Dysample module is adopted to replace the traditional upsampling layer, enhancing the detail recovery capability for occluded and blurred targets; a small object detection layer is added to expand scale coverage, and the CBAM dual attention module is embedded to suppress background interference and focus on key features. Experimental results show that the improved model achieves an mAP@0.5 of 81.2%, which is 2.9 percentage points higher than the baseline YOLOv11n model, with a GPU inference speed of 266 FPS and only 2.80 million parameters. It significantly improves the detection accuracy and operational efficiency in complex scenarios, providing reliable technical support for the intelligent identification, investigation, and protection of wild Chinese herbal medicine resources.

Keywords

Improved YOLOv11, Wild Chinese Herbal Medicine Detection, Small Object Detection, Attention Mechanism, Real-Time Object Detection 2.9

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

中草药作为我国传统医药的核心载体，是中医药产业发展的重要物质基础，在疾病防治、健康养生等领域具有不可替代的价值。随着中医药现代化进程加快，野外中草药资源的精准识别与检测成为资源保护、合理开发及质量管控的关键环节。然而，野外环境复杂多变，中草药多呈现密集排列、尺度差异显著、易受枯叶、土壤等背景干扰的特点，且部分药用部位(如种子、小花)体积微小，导致传统人工检测效率低下、漏检误检率高，难以满足大规模资源调查与智能化检测的需求。

目标检测技术的快速发展为野外中草药识别提供了新路径，其中 YOLO 系列模型因检测速度快、实时性强，被广泛应用于各类目标检测任务。YOLOv11 作为该系列的最新版本，在检测精度与运行效率上均有提升，但应用于野外中草药检测时，仍存在明显不足：SPPF 模块计算冗余较高，难以高效处理大规模中草药图像；多尺度特征融合效果不佳，无法充分捕捉花与叶、叶片纹理与背景的关联特征；传统上采样模块对遮挡、模糊目标的细节恢复能力有限，针对密集小目标的检测性能有待提升。

针对上述问题，本文以 YOLOv11 模型为基础，结合野外中草药检测的实际需求，对其网络结构进行针对性改进。通过引入新型模块与注意力机制，优化特征提取、多尺度融合及目标检测流程，旨在解决传统模型计算冗余、小目标漏检、背景干扰抑制不足等痛点，提升模型在野外复杂场景下的检测精度与运行效率，为野外中草药资源的智能化识别、调查与保护提供可靠的技术支撑，推动中医药资源利用与现代化发展。

2. 相关研究

2.1. 研究区别

为了实现中草药的快速高精度识别检测，国内外众多学者都做了许多富有成效、价值和成果巨大的研究与创新。中草药识别检测技术按使用场景可以分为药材识别检测(如市场流通的干燥药材)和原药识别检测(如原植物或新鲜采集) [1]。其中药材识别检测通常采用形态学检测、光谱检测、色谱检测、分子生物学等多种方法对处理后的中草药进行检测[2]。

而本研究主要针对于中草药原药识别检测,即尚未进行处理加工的中草药识别检测,相对于药材识别检测,中草药原药识别检测尤其是野外的中草药识别检测存在光照变化(阴晴/昼夜)、背景杂乱(其他植被、土壤)、天气影响(雨雾)、同一物种因生长阶段(花期/果期)或生境(海拔、土壤)导致形态差异(如叶片大小、花色)等挑战,以及设备便携性、处理实时性等现实问题[3]。

2.2. 国内研究现状

为解决野外复杂环境中中草药快速准确识别检测问题,国内学者开展了诸多方法创新。目前主流技术分为两类:一是基于便携式光谱与传感器的传统检测方法创新,二是结合注意力机制的深度学习检测技术[4],后者随计算机技术发展认可度日益提升。

中科院团队开发手持 NIR 设备(波长 900~1700 nm),5 秒内可完成野生中草药识别检测[5];郭灿璨等提出 HMRNet 架构,基于 VGGNet 改进,结合多层卷积、全连接层及 Flatten、Dropout 层优化,自建数据集上平均识别准确率达 97.3%,显著优于 VGGNet、AlexNet 等模型[6];朱思博采用 VGG16 结合 Adam 优化算法,引入 Dropout 层减少过拟合,在 5 种中草药、902 张图像的小规模数据集上验证准确率达 75.83%,并拓展至中药材质量检测与病虫害辨识[7];刘子涵等将百度 EasyDL 平台 AutoDL Transfer 算法应用于该领域,结合自动化网络搜索与迁移学习优化模型,分类精度达 88.0% [8];王艳等针对数据量不足问题,提出迁移学习结合数据增强方案,采用蚁群优化图像分割方法分离叶片,15 种中草药、3752 张图像测试集上平均识别准确率达 99.38%,优于传统方法[9];齐保峰等提出基于可分离卷积的轻量 VGG16 改进模型,以原始图像与 Sobel 梯度图为输入,优化后总参数量降至 121,271,588,较原模型减少约 10%,适配移动端需求[10]。

而国外在中草药识别检测研究中,更注重数据集构建与注意力机制应用。Sun X 构建含复杂背景的中药公共数据库,5523 张图像、95 个类别,结合 softmax 与 Triplet 损失优化网络,有效提升了识别与检索精度[11]。Yingxue Xu 构建标准中药数据集,提出注意力金字塔网络 APN,引入空间协同注意力与竞争机制,形成新识别框架[12]。W Dai 建立含 4485 张图像、20 个类别的数据集,提出 MSPyraNet 架构,通过多尺度与空洞卷积提升特征提取效果[13]。

3. 方法

3.1. 改进 YOLOv11 模型

针对野外中草药检测场景,对 YOLOv11 网络结构开展针对性改进。如图 1,将 SPPF 模块替换为 AIFI 模块,通过同尺度特征间的注意力机制实现特征交互与全局信息整合,在保留叶片纹理与背景关联等长距离依赖的同时,显著降低计算复杂度与参数规模;在上采样环节,采用 DySample 模块替代传统上采样结构,增强密集排列中草药在遮挡与模糊场景下的细节特征恢复能力,提升多尺度特征融合与处理效果。针对种子、小花等密集小目标,新增小目标检测层并配置高分辨率检测头,扩大模型对不同尺度中草药的检测覆盖范围。在检测层嵌入 CBAM 双注意力模块,借助通道注意力和空间注意力聚焦关键特征并抑制枯叶、土壤等复杂背景干扰,进一步提升复杂野外环境下的目标检测精度。

3.2. AIFI 模块替换 SPPF 模块

野外中草药场景背景复杂,小目标易受光照、遮挡干扰,传统 SPPF 模块依赖局部信息,难以捕捉目标与上下文关联,且易受噪声影响。而 AIFI 模块作为基于 Transformer 的轻量级全局特征提取模块,成为替代 SPPF 的最优选择,相比于 ASPP、PSA、Transformer-Block 等经典深度学习模块,AIFI 具有全局信息整合,计算轻量化,噪声抑制,参数量增幅小,提升局部特征的多尺度表达等多项优势。

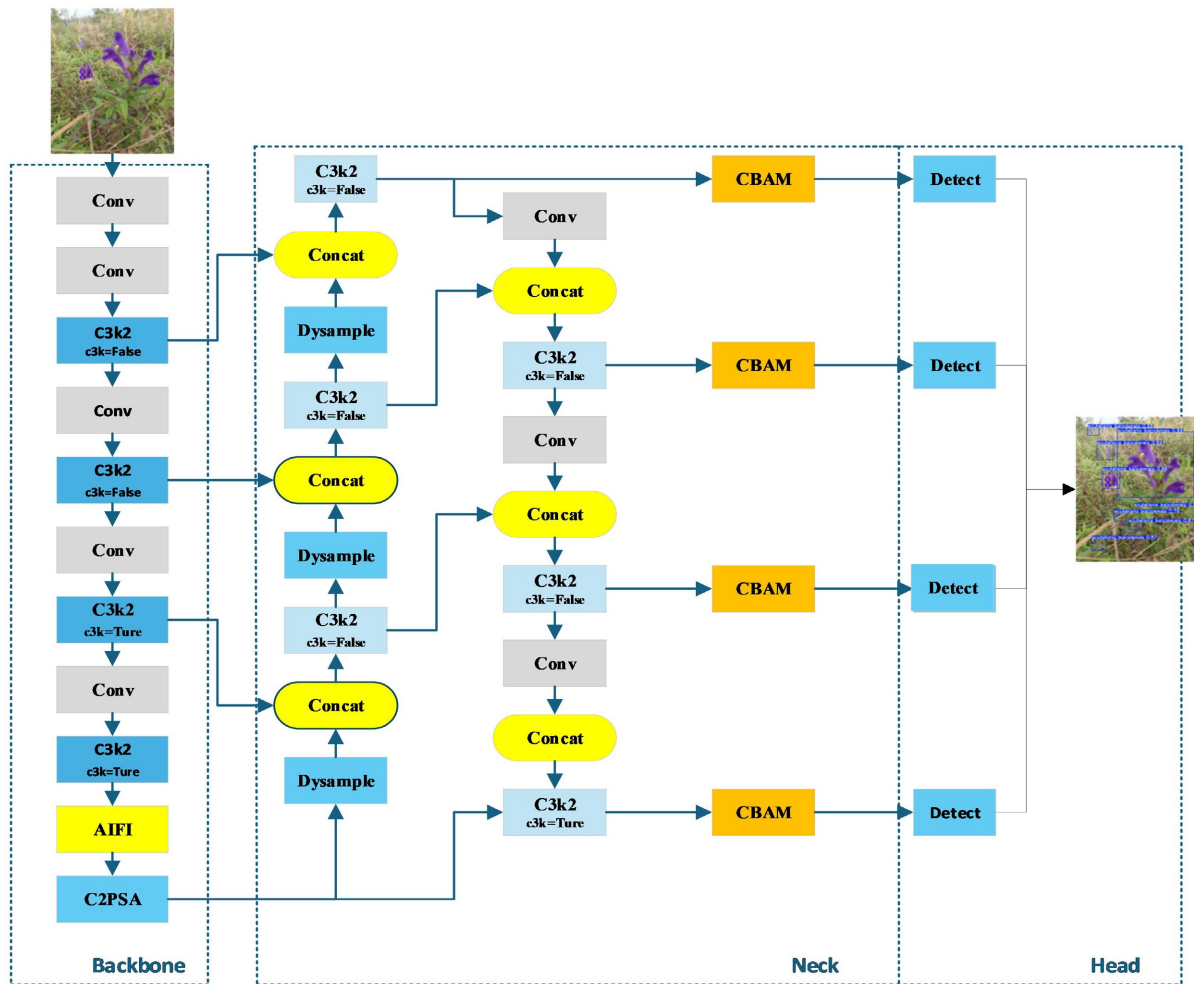


Figure 1. Structure diagram of the improved YOLOv11

图 1. 改进的 YOLOv11 结构图

因此基于 YOLOv11，在骨干网络末端以 AIFI 模块替换 SPPF 模块。而 AIFI 模块借鉴 RT-DETR 的 Transformer 编码器，通过全局信息建模提取更全面的特征与上下文细节，利用同尺度特征间的注意力机制促进特征融合，在捕获长距离依赖的同时抑制无关特征，减少噪声干扰。

AIFI 模块作为基于 Transformer 的轻量级全局特征提取模块，成为替代 SPPF 的最优选择 AIFI 由多头注意力机制与前馈网络(FFN)构成，结构图如图 2，其中层归一化与丢弃模块用于促进网络收敛并防止过拟合。对输入特征图进行展平重塑，通过线性投影得到各值，然后自注意力机制编码全局上下文信息，模块中使用了多个自注意力机制，以级联输出并使用可学习权重矩阵实现的线性投影来转换维度，上述过程可用公式表示为：

$$Q_i = X \cdot W_i^q \cdot K_i = X \cdot W_i^k \cdot V_i = X \cdot W_i^v \quad (1)$$

$$Attention_i(Q_i, K_i, V_i) = \text{softmax}\left(\frac{Q_i^T \cdot K_i}{\sqrt{d_k}}\right) \cdot V_i \quad (2)$$

$$MHSA(X) = \text{Concat} \times (Attention_1, \dots, Attention_h) W^o \quad (3)$$

其中 W_i 、 W_{j^k} 、 W_{j^v} 表示 Q_i 、 K_i 、 V_i 、 q 的权重矩阵， i 表示多头注意力中头部索引， d_k 表示 K 向量的

特征通道维度， softmax 表示激活函数 $W^O \in R^{C \times C}$ 。

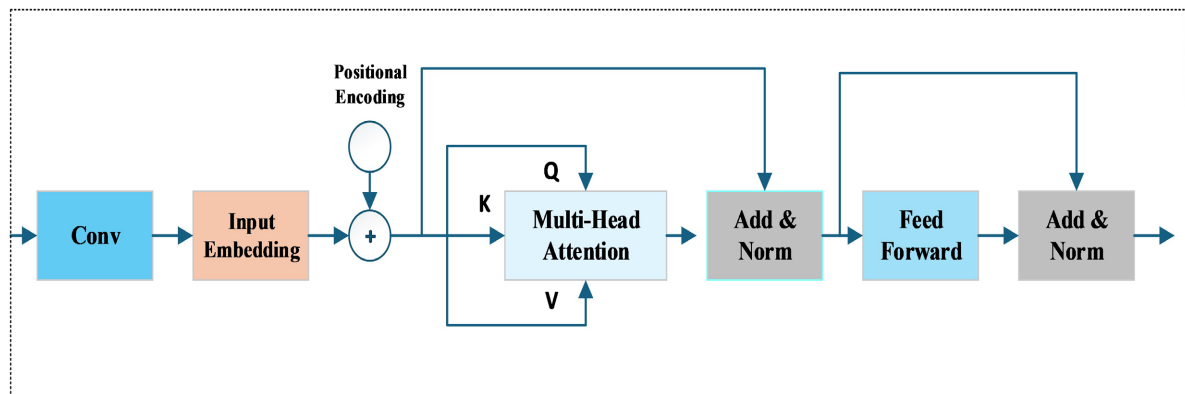


Figure 2. Network structure of the AIFI module

图 2. AIFI 模块的网络结构

3.3. DySample 取代传统上采样模块

DySample 是一种动态上采样机制，包含三个主要部分：采样点生成、静态作用域因子和动态作用域因子。首先，通过采样点生成器确定关键的采样位置，并使用网格采样方法提升特征图分辨率；接着利用线性变换结合固定或可变缩放因子进行 Pixel Shuffle 操作以获得高分辨输出，其中静态因素提供稳定性而动态因素增强灵活性与适应能力。DySample 主要采用点重采样的方法，而非传统的基于内核的方法，不仅提高了资源效率，而且简化了 PyTorch 中的实现。通过避免耗时的动态卷积和额外的子网络生成动态内核，DySample 显著减少了计算工作量和延迟。它的轻量特性，以及更少的参数和较低的 GPU 内存需求，使其十分高效。

DySample 通过生成动态偏移量和范围因子来调整采样点的位置和范围，这些参数能够根据输入特征图的内容和上下文进行自适应调整，以适应不同场景和目标。基于 DySample 的动态上采样如图 3 所示，具体步骤：输入特征 x 通过采样点生成器生成采样集，再通过网络采样函数 $grid_sample$ 对输入特征进行重采样，最后得到采样后的特征 x' ，具体公式为

$$x' = grid_sample(x, s) \quad (4)$$

$$o = linear(x) \quad (5)$$

$$s = g + o \quad (6)$$

其中： s 表示采样集； $grid_sample$ 表示网络采样函数； $linear$ 表示线性层； o 为偏移量； g 为原始采样网络位置。

3.4. 添加小目标检测层

在 YOLO11 框架中，颈部层(Neck)是骨干网络与检测头的关键连接模块，核心功能是通过两次上采样与 C3k2 模块级联实现特征融合，生成适配多尺度目标检测的特征图。但深层网络固有特性会导致特征退化，最突出的是特征图分辨率显著下降，随着网络加深，特征图空间尺寸缩小，单像素对应原始图像区域扩大，感受野持续增加。

这种分辨率下降不仅影响整体检测性能，更严重制约小目标检测精度，且存在递进式缺陷：网络越深，分辨率越低，小目标在特征图中像素占比极低，模型难以捕捉其有效特征。尤其在中草药检测场景

中,花蕊、叶脉等细粒度小目标特征易在传递中丢失,导致漏检、定位偏差,严重影响检测精度。

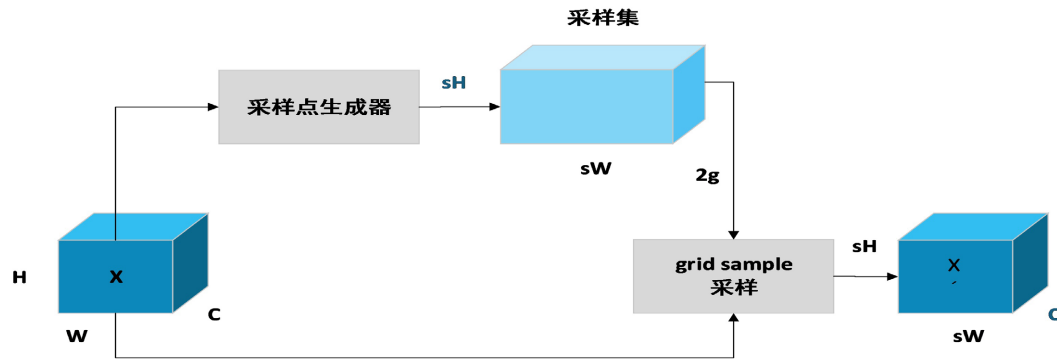


Figure 3. Network structure of the DySample module
图 3. DySample 模块的网络结构

为解决该问题,专门添加小目标检测层,构建四尺度检测层架构,覆盖不同尺寸目标(具体结构如图 4 所示)。其核心思路是与骨干网络第一个 C3k2 模块融合,借助浅层特征高分辨率优势,弥补深层细粒度信息不足的短板。

具体来说,小目标检测层提取颈部层深层特征,经三次连续上采样提升分辨率,与第一个 C3k2 模块的浅层特征(保留丰富细粒度信息)对齐,再通过通道拼接或加权融合,整合深层语义信息与浅层空间特征,最终输出兼顾高分辨率与强语义的融合特征图。

该融合特征图能有效保留小目标细节,提升模型对中草药花蕊、叶脉等小目标的感知能力,配合其他三个尺度检测层形成全尺度检测体系,缓解深层网络分辨率下降的影响,提升模型在细粒度小目标检测中的适用性与精度。

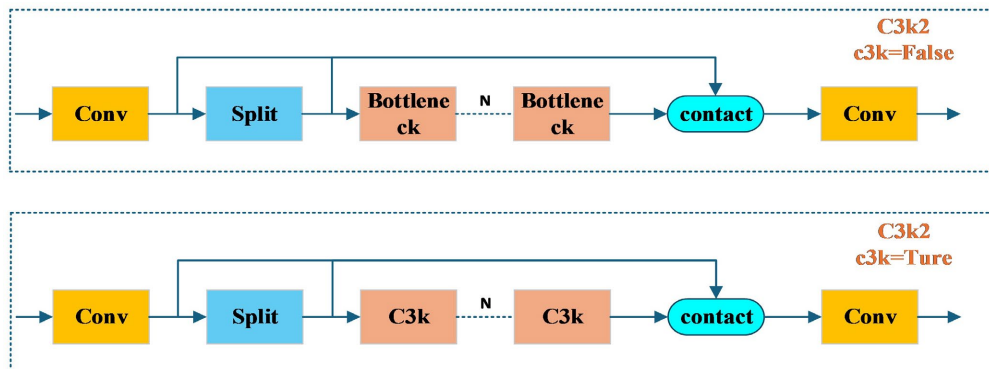


Figure 4. Network structure of the C3k2 module
图 4. C3k2 模块的网络结构

3.5. 添加 CBAM 注意力机制

为提升野外中草药识别检测的准确性,本研究在 YOLOv11 架构中嵌入 CBAM 注意力机制,强化关键特征提取能力,以此提高模型在复杂自然环境下的检测精度。CBAM 机制的核心是聚焦重要特征、抑制无关特征,可显著增强网络对中草药特征的表征能力。作为轻量级高效注意力模块,CBAM 能无缝集成于各类 CNN 架构,几乎不增加额外计算开销,且可与基础 CNN 架构实现端到端联合训练,在野外中

草药识别检测任务中表现出优异性能。

CBAM 由通道注意力模块与空间注意力模块协同构成，二者相互配合，有效提升模型对中草药特征的捕捉与识别能力。其中通道注意力模块针对特征图不同通道实施重要性加权，野外中草药图像包含叶片纹理、花朵颜色、茎秆形态等多元特征信息，不同通道的特征贡献度存在差异，CBAM 可自主学习并判定各通道重要性，通过为关键通道分配更高权重，使模型聚焦中草药的判别性特征，强化叶片纹理、花朵特征等关键信息的提取，降低无关通道的干扰；空间注意力模块则聚焦特征图的空间维度，精准定位图像中需重点关注的区域，针对野外中草药位置、角度多变及遮挡等问题，通过分析空间像素点特征，突出中草药关键部位区域特征，有效抑制背景、遮挡物等区域的干扰。

而 CBAM 与同类注意力备选模块的适配性差异显著：相较于 SE、ECA 等单通道注意力模块仅能筛选特征通道、无法定位目标空间位置，对野外随机分布的中草药目标聚焦能力弱的缺陷，CBAM 以通道 + 空间双通道串行注意力实现双重特征筛选，先为叶片纹理、花朵颜色等关键特征通道分配高权重，再精准定位中草药目标的空间区域，大幅抑制枯叶、杂草、土壤等复杂背景的干扰，完美解决野外背景与目标的特征混淆问题；对比 CoordAtt 模块虽能实现坐标空间定位、小目标检测精度稍优，但背景整体抑制能力不足、结构更复杂的问题，CBAM 在保证目标空间聚焦的同时，对大范围背景噪声的过滤效果更贴合野外场景，且模块轻量化程度更高，嵌入后对模型参数数量的增幅可忽略不计；相较于 SimAM 无参数细粒度注意力仅能强化局部细微特征、对全局背景抑制能力有限的特点，CBAM 实现了全局背景抑制 + 局部关键特征聚焦的双重效果，更适配中草药叶脉、花蕊等细粒度特征提取与复杂背景共存的野外检测场景。CBAM 模块在背景抑制效果、特征聚焦能力、轻量化程度、架构兼容性四个维度的综合表现最优，是兼顾野外中草药检测场景痛点与模型工程化部署需求的注意力机制最优选择。

4. 实验

4.1. 数据集准备

构建完备且分布均衡的图像数据集，是保障野外中草药检测模型性能稳定可靠的关键前提。本研究选取黄芩、金银花(忍冬)、板蓝根(菘蓝)三种典型中草药作为研究对象，分别针对其发芽期、生长期、开花成熟期三个阶段，在复杂背景与密集生长场景下开展图像采集。实验采用尼康 D7200 相机进行拍摄，以获取满足深度学习训练所需的高分辨率图像。为提升模型泛化能力与鲁棒性，对原始图像采用翻转、缩放、裁剪、平移等几何操作进行数据增强，最终构建包含 6039 张图像的数据集(部分样本见图 5)。为保证模型训练与评估的科学性，数据集按照 8:1:1 比例随机划分为训练集 4831 张、验证集 604 张与测试集 604 张，全部图像均使用 LabelImg 工具完成标注，标注格式统一采用 YOLO 标准格式。



Figure 5. Sample data set diagram
图 5. 数据集样图

4.2. 数据集实验环境与参数配置

为保证实验的公平性、严谨性与可比性，本研究对所有对比模型采用统一的超参数设置，消除训练条件对结果的影响。实验将输入图像分辨率统一调整为 640 像素，并保持原始长宽比不变，防止图像变形造成特征损失。训练过程中，批次大小设为 16，迭代轮次为 300 轮；采用 SGD 优化器，初始学习率设置为 0.01，确保模型稳定收敛。本实验所用硬件环境与软件配置详情如表 1 所示。

Table 1. Experimental environment and version configuration

表 1. 实验环境及版本配置

实验环境	版本型号
GPU	Nvidia Geforce RTX 3090 (24 G)
CUDA	12.1
PyTorch	2.1.2
Python	3.11

4.3. 评估指标

为全面客观评估野外中草药检测模型的精度、轻量化程度及实时性能，本研究选取多项常用评价指标进行综合分析：**mAP** (平均精度均值)衡量复杂场景整体检测精度；**GFLOPs** 表征模型计算量，数值越低计算开销越小；**Param** (参数量)关联模型存储占用与部署难度；**FPS** (每秒检测帧数)评价实时推理速度，数值越高实时性越好。具体计算公式如下：

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$AP = \int_0^1 P(R) dR \quad (8)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (9)$$

4.4. 消融实验

Table 2. Ablation experiment

表 2. 消融实验

实验	AIFI	Params/M	CBAM	Map@0.5
1				78.3
2	√			79.2
3		√		79.4
4			√	79.3
5	√	√		80.1
6		√	√	80.3
7	√		√	80.5
8	√	√	√	81.2

为验证各改进模块在野外环境中草药目标检测任务中的有效性, 本文以 YOLOv11n 为基准模型开展消融实验。由表 2 可知, 基线模型 mAP@0.5 为 78.3%, 单独引入 AIFI、Dysample、CBAM 任一模块后, mAP@0.5 分别提升至 79.2%、79.4%、79.3%, 证明各模块均可有效增强特征提取能力; 两两组合后性能进一步提升, 其中 Dysample 与 CBAM 组合使 mAP@0.5 达 80.5%; 当三者同时引入时, mAP@0.5 最终提升至 81.2%, 较基线模型提升 2.9%, 同时参数量仅小幅增加, 保持了高效的实时推理性能, 充分验证了 AIFI 模块、Dysample 模块、新增小目标检测层及 CBAM 双注意力机制的协同改进有效性。各模块在降低计算冗余、强化小目标与遮挡目标细节提取、抑制复杂背景干扰等方面形成互补, 显著缓解漏检误检问题, 使模型在野外中草药检测场景下的适配性与检测性能得到全面提升, 满足野外中草药识别检测的实际应用需求。

4.5. 对比实验

为进一步验证所提模型在野外中草药检测任务中的优越性, 本文选取 YOLOv5n、YOLOv7-tiny、YOLOv8n、YOLOv9-t、YOLOv10n 及 YOLOv11n 等主流轻量化目标检测模型开展对比试验。由表 3 可知, 原始 YOLOv11n 模型在参数量(2.60 M)、计算量(6.8 GFLOPs)与推理速度(263 FPS)上已具备轻量化优势, mAP@0.5 为 78.3%。本文改进模型(Ours)在仅小幅增加参数量(2.80 M)与计算量(7.3 GFLOPs)的前提下, mAP@0.5 提升至 81.2%, 较 YOLOv11n 基线模型提升 2.9%, 同时推理速度达 266 FPS, 略优于原始模型, 实现了精度与效率的同步优化。

与其他模型相比, 改进模型 mAP@0.5 分别较 YOLOv5n、YOLOv7-tiny、YOLOv8n、YOLOv9-t、YOLOv10n 提升 3.3%、2.4%、3.3%、3.3%、3.0%, 且在推理速度上显著优于 YOLOv5n(64 FPS)、YOLOv7-tiny(141 FPS)等早期模型, 参数量与计算量仍保持在轻量化水平。结果表明, 所提改进模型在野外中草药检测任务中, 兼顾了更高的检测精度与更优的实时推理性能, 综合表现优于当前主流轻量化 YOLO 系列模型, 更适配野外巡检等实际工程场景需求。

Table 3. Comparison experiment

表 3. 对比试验

模型	mAP@0.5	Params/M	GFLOPs	FPS
YOLOv5n	77.9	1.9	4.2	64
YOLOv7-tiny	78.8	6.0	13.3	141
YOLOv8n	77.9	3.1	8.1	232
YOLOv9-t	77.9	1.97	7.6	237
YOLOv10n	78.2	2.7	8.3	241
YOLOv11n	78.3	2.60	6.8	263
Ours	81.2	2.80	7.3	266

5. 结论

本文面向野外中草药目标检测任务, 基于 YOLOv11 模型构建改进方案。首先, 将 SPPF 替换为 AIFI 模块, 在降低计算冗余的同时强化全局特征关联; 其次, 采用 Dysample 上采样并新增小目标检测层, 提升遮挡与微小目标的细节恢复能力; 最后, 嵌入 CBAM 双注意力模块, 抑制复杂背景干扰。消融实验表明, 单独引入各模块即可使 mAP@0.5 提升至 79.2%~79.4%, 三者协同后 mAP@0.5 达 81.2%, 较基线提升 2.9%, 参数量与计算量仅小幅增加。对比试验显示, 改进模型 mAP@0.5 为 81.2%, 较 YOLOv5n/YOLOv8n/

YOLOv9-t 等主流模型提升 3.0%~3.3%，推理速度达 266 FPS，优于所有对比模型。兼顾精度与效率，满足野外巡检实时需求。

6. 局限性与未来工作

本研究仍存在一定局限性：数据集仅包含 3 种典型中草药，物种与场景覆盖偏少，跨地域、跨生境泛化能力有限；模型不具备小样本/零样本学习能力，对未训练过的新物种无法快速自适应识别；在高度密集、多重遮挡的复杂野外环境中，部分微小目标仍存在漏检现象；同时模型未针对嵌入式与移动端进行深度轻量化优化，实地部署的便捷性与通用性有待提升。

未来将从多方面持续优化：构建覆盖更多物种、全生长周期与复杂野外环境的大规模标准数据集，增强模型泛化与鲁棒性；引入元学习、迁移学习实现新物种小样本快速适配，降低数据标注成本；进一步优化多尺度特征融合与小目标检测结构，提升遮挡与模糊目标的检测精度；通过模型量化、剪枝与知识蒸馏实现深度轻量化，推进模型在嵌入式设备与手机端的部署应用；最终拓展生长状态评估、病虫害识别等功能，构建一体化野外中草药智能监测与识别系统。

基金项目

河北省自然科学基金资助(D2024209006)；河北省教育厅科学研究项目资助(QN2024147)；河北省大学生创新创业计划项目资助(S202510081014)。

参考文献

- [1] 罗厚蔚, 刘姿荣, 郭金凤. 草药及其制剂中常见成分的早期识别[J]. 中国药学杂志, 1979(2): 82.
- [2] 张红侠, 王宇, 朱正安, 等. 相似中草药植物鉴定技术的研究进展与展望[J]. 世界科学技术-中医药现代化, 2018, 20(12): 2202-2207.
- [3] 王丽君, 淮永建, 彭月橙. 基于叶片图像多特征融合的观叶植物种类识别[J]. 北京林业大学学报, 2015, 37(1): 55-61.
- [4] 刘伟, 肖致, 刘波. 基于深度学习的中草药植物图像识别研究与应用[J]. 信息与电脑 (理论版), 2022, 34(12): 32-34.
- [5] 王丹, 李亦, 张丰益, 等. 便携式近红外光谱仪在野生中药材质量评价中的应用[J]. 光谱学与光谱分析, 2023, 43(2): 456-462.
- [6] 郭灿璨, 朱玉祥, 张俊明, 等. 基于卷积神经网络的中草药识别算法研究[J]. 中医药信息, 2024, 41(11): 29-34.
- [7] 朱思博. 基于 VGG16 深度学习模型的中草药图像识别技术与应用[J]. 大众标准化, 2025(3): 76-78.
- [8] 刘子涵, 魏书伟, 王新娇, 等. 基于 AutoDL Transfer 的中草药识别系统的设计与实现[J]. 电脑科技与技术, 2023, 19(28): 18-20.
- [9] 王艳, 孙薇, 周小平. 基于深度学习的中草药植物图像识别方法研究[J]. 中医药信息, 2020, 37(6): 21-25.
- [10] 齐保峰, 刘华明, 王先传, 等. 基于轻量神经网络的中草药识别研究[J]. 洛阳理工学院学报: 自然科学版, 2023, 33(1): 73-78.
- [11] Sun, X. and Qian, H. (2016) Chinese Herbal Medicine Image Recognition and Retrieval by Convolutional Neural Network. *PLOS ONE*, **11**, e0156327. <https://doi.org/10.1371/journal.pone.0156327>
- [12] Xu, Y., Wen, G., Hu, Y., Luo, M., Dai, D., Zhuang, Y., et al. (2021) Multiple Attentional Pyramid Networks for Chinese Herbal Recognition. *Pattern Recognition*, **110**, Article 107558. <https://doi.org/10.1016/j.patcog.2020.107558>
- [13] Dai, W., Ma, Y., Fan, Y. and Ma, J. (2025) A Multi-Scale Feature Extraction Algorithm for Chinese Herbal Medicine Image Classification. *Applied Sciences*, **15**, Article 4271. <https://doi.org/10.3390/app15084271>