

# 基于改进 YOLOv11 的茶叶病害检测研究

肖佳彤<sup>1</sup> 董晓宇<sup>1</sup> 程 硕<sup>1</sup>

XIAO Jiatong DONG Xiaoyu CHENG Shuo

## 摘要

茶叶病害给我国茶产业安全造成重大威胁,其病害特征存在差异,依靠人力及传统手段识别时,效率低且容易出现漏判情况。基于此,文章提出一种基于深度学习的茶叶病害检测算法,在 YOLOv11 网络模型中加入 CA 坐标注意力机制,减少背景信息带来的干扰。并采用动态蛇形卷积,自动调节卷积核采样点,以此来适应茶叶病害不规则的形态特点。此外,引入 EVCBlock 轻量化模块,实现多尺度特征的高效融合。实验表明,该算法在复杂环境背景下,对茶叶典型病害的检出率达到 90% 以上,实现了茶叶病害的自动化、高精度检测。

## 关键词

茶叶病害;深度学习;YOLOv11;动态蛇形卷积

doi: 10.3969/j.issn.1672-9528.2026.07.001

## 0 引言

茶叶作为我国特色经济作物,是推进乡村振兴的关键支柱产业,其种植规模大,经济价值高。然而,病害的频繁发生,已成为限制其高质量发展的主要因素。茶叶生长环境较为复杂,容易被真菌,细菌等病原体感染,从而引发茶藻斑病、茶轮斑病等多种常见病害。这些病害存在潜伏性强、传播速度较快的特性,一旦防治不及时,可能造成茶叶产量大幅下降、品质变差,给茶产业带来沉重的经济损失。

当下,我国茶叶病害检测大多依赖人工肉眼识别。同时会采用化学检测和显微镜观察方法,但这种检测模式同样依赖工作人员的操作经验,主观性较强,容易误判或者漏判,且检测效率低、人力成本高,不能适应大规模茶园快速检测的需求,难以实现病害的早期警报和精确防控,这成了阻碍茶产业向现代化转型的关键行业难题<sup>[1]</sup>。

人工智能和计算机视觉技术正在飞速发展,智能化检测技术如图像处理技术,深度学习以及机器学习技术给解决前面提到的难题带来了有效途径。依靠这些技术的茶叶病害检测方法,可以做到自动识别病害并精确分类,其检测速度快、准确率高、成本低、可现场实操,这些明显的优势能有效弥补传统检测模式存在的不足。

## 1 相关研究

目前图像处理技术和深度学习技术都已被广泛应用于

病害检测中。文献[2]采用拉曼光谱、光谱和成像以及高光谱成像等技术,建立作物病害不同侵染期快速检测方法和模型,能够实现病害的早期快速诊断和识别。文献[3]提出了一种融合卷积神经网络、迭代注意力模块和 Transformer 结构模型,可以高效提取茶叶叶片的多粒度特征,并在小样本和不同复杂场景表现出良好的鲁棒性。文献[4]提出基于机器学习的随机森林分类算法准确率最高,并利用 GWO 对随机森林模型进行优化,可以实现茶叶病害种类的准确识别。文献[5]分别建立基于单一形状特征和复杂性、伸长度、矩幅度、圆度及面积凹凸比 5 种组合形状特征、4 种不同核函数的 SVM,得到采用线性核函数的 SVM 的分类识别效果较优。文献[6]提出在 YOLOv8 模型中重构 BiFPN 颈部网络,利用廉价线性操作生成冗余特征图,通过参数复用与动态尺度调整策略实现轻量化的茶叶病害检测。文献[7]使用具有多个隐藏层的深度卷积神经网络 CNN 模型,能够准确检测常见茶叶病害,并与各种物联网设备配合使用。文献[8]利用茶叶病害区域与其红外图像灰度分布存在的规律,提取两个特征参数构建分类器实现茶叶病害快速检测,该方法与人工观测计数的相关系数达 0.97。文献[9]采用改进的支持向量机分类器进行病害识别,将比较的特征减少了 3 个,且未对分类器的成功率造成不利影响,加快了识别过程。文献[10]设计了一种轻量型目标检测网络 LiTLBNet,实现野外茶园无人机遥感图像中茶叶枯病的准确、实时监测,但缺点是检测精度偏低。

目前,国内外关于茶叶病害智能化检测的研究虽已取得一定进展,但仍存在明显短板:当前的检测模型在复杂

1. 信阳学院 河南信阳 464000

[基金项目] 2024 年度信阳学院校级科研项目(2024-XJLYB-027)

田间环境中的检测精度不够高,泛化能力不强;多数研究成果只停留于实验室阶段,很难实现大规模的实际应用。因此,开展茶叶病害智能化检测方面的研究,改进检测算法并加强技术的实用价值对推动茶产业朝着绿色可持续发展、落实乡村振兴战略有着重要的理论意义和现实应用价值。

## 2 实验过程

本文旨在检测由茶藻斑病、茶轮斑病以及茶云纹叶枯病等病害引起的不健康茶叶叶片。利用 YOLOv11 深度学习模型并加以改进,改进后的模型包含两个阶段,即训练阶段与测试阶段。在训练阶段,首先采集图像清晰的茶叶病害图像,包括正常样本图和病害样本图。将图像标注和预处理后,进行图像分析,最后放入神经网络模型中完成训练。测试阶段再次收集新的茶叶病害图像组成测试集,将其预处理后,放入分类训练好的神经网络模型中进行病害识别和分类验证。本研究的整体思路如图 1 所示。




图 1 整体思路图

研究共分为 4 个阶段,分别是图像获取、图像预处理、图像分析与训练以及图像测试与分类。

### 2.1 数据集

本文采用的茶叶病害数据集均是在自然环境下收集,使用 1 200 万像素的手机摄像头拍摄。拍摄时,图像的分辨率为 1 200 px×1 594 px。拍摄距离约为叶片上方 32 cm,为了避免拍摄环境杂乱造成叶片目标不突出的问题,在茶叶叶片下方铺垫白纸作为背景,使拍摄出的叶片轮廓更加清晰锐利。共 4 748 张图片,包含常见的 6 种病害症状,如茶藻斑病(由绿藻门的茶藻斑病菌引起)、茶轮斑病(由类拟盘多毛孢菌复合体引起)、茶云纹叶枯病(由炭疽菌引起)、茶角盲蝽(由茶角盲蝽引起)、红蜘蛛(由红蜘蛛引起)、绿盲蝽(由绿盲蝽引起),也包含健康正常的叶片。部分数据集样本如

图 2 所示。




图 2 数据集中茶叶样本图

### 2.2 数据集预处理

数据集预处理是提升模型检测精度的关键前提,核心目标是剔除无效数据、统一数据格式、增强数据多样性,解决病害样本分布不均、成像差异大等问题,为模型训练提供高质量输入。预处理流程围绕数据清洗、格式标准化、数据增强、划分与归一化展开,具体操作如下:

首先,执行数据清洗步骤,从数据集中移除模糊,曝光过度或者不足,背景杂乱以及存在标签错误或者缺失的无效样本。

其次,格式标准化方面,把全部图像的尺寸调整成 640 px×640 px,符合 YOLOv11 的输入需求,利用双线性插值法来保留图片的细节信息,并统一图片格式为 JPG。

再使用 LabelImg 数据标注工具对图片进行标注,对于茶藻斑病、茶轮斑病等目标样本,手动修正标注框出现的偏移情况,使得病害区域和标注框精确匹配。同时,剔除重复样本,防止模型产生过拟合现象。标注完毕之后,系统会自动形成 VOC 数据格式的数据集,其文件名以 xml 为后缀,通过 Python 可以把 VOC 格式的数据集转换成 YOLO 模型训练所必需的 YOLO 数据格式的数据集,该文件名以 txt 为后缀,且文件名和图片名相一致,从而保证模型能够正常解析输入的数据。

茶叶病害样本往往会出现类别不均衡的情况,所以要进行数据增强,采用轻量化而且不会影响病害特征的办法,比如随机水平翻转,轻微旋转(正负 15°),镜像,微调亮度和对比度,添加高斯噪声。并对病害区域做小幅裁剪,从而改善模型针对不同成像条件,不同病害形态的适配性,防止因为样本数量少而造成模型泛化能力不够。部分数据增强图像如图 3 所示。




图3 数据增强

最后，将数据集划分与归一化，训练集与测试集间的比例是 7:1，按照这样的比例来划分，其适配性较广，可以兼顾模型学习和评估需求。此外，测试数据集的 10% 子集被用于验证数据集。对图像像素值归一化至 [0,1]，消除像素尺度差异，加速模型收敛。茶叶病害数据集中每种病害类别的总图像数量，及其用于训练和测试的图像数量，如表 1 所示。

表 1 数据集样本数量表

| 种类    | 各种类总数量 | 训练数量  | 测试数量 |
|-------|--------|-------|------|
| 健康叶片  | 845    | 745   | 100  |
| 茶藻斑病  | 375    | 326   | 49   |
| 茶轮斑病  | 911    | 806   | 105  |
| 茶云纹叶枯 | 456    | 412   | 44   |
| 茶角盲蝽  | 551    | 497   | 54   |
| 红蜘蛛   | 454    | 401   | 53   |
| 绿盲蝽   | 1 156  | 1 033 | 123  |
| 总数量   | 4 748  | 4 220 | 528  |

### 2.3 YOLOv11 模型改进

针对茶叶病害检测场景中病害小目标、形态不规则、背景复杂易干扰的问题，对 YOLOv11 模型进行轻量化多模块融合改进，在保证模型推理速度的前提下，提升对茶叶茶藻斑病、茶轮斑病及健康叶片等的特征提取与分类检测能力。改进方案以 YOLOv11 基础架构为核心，在主干网络（Backbone）、颈部（Neck）、特征融合层嵌入轻量化注意力与卷积模块，结合通道优化策略，实现精度与速度的平衡，具体改进如下：

（1）在 Backbone 中嵌入 CA（coordinate attention）坐标注意力模块：在 YOLOv11 主干 C3k2 模块后面加上 CA 坐标注意力模块，主要解决了传统注意力（比如 SE、CBAM）对位置信息捕捉不够的问题，通过把通道注意力和坐标空间信息解耦并融合起来，以较小的计算量，准确捕捉到目标的

位置特征和通道特征，特别适合小目标、形变目标的特征提取。借助通道和空间维度的特征解耦，准确得到茶叶病害的位置信息和细粒度的纹理特征，从而加强模型对小尺度病害的特征提取能力，减少背景杂色，叶片重叠等无关信息的干扰，改善目标特征的表现能力。

（2）在 Neck 和 Backbone 中分别融合两层 DSConv 动态蛇形卷积：把原来的 C3k2 模块换成 DSConv 动态蛇形卷积。传统的卷积是通过固定核大小和扫描路径，而茶叶病害的形态通常是不规则的，如边缘卷曲、片状、点状等，且部分病害如茶藻斑病和茶角盲蝽，具有细粒度特征，所以很难捕捉到此类动态特征。

采用动态蛇形卷积可以进行动态路径搜索，通过模拟蛇形的运动轨迹，根据所检测病害的边缘和纹理特征，自动调整卷积核采样点，而不是机械的网格状扫描，从而适配茶叶病害不规则的形态特点，弥补传统卷积在提取形变目标特征时存在的不足。此外，DSConv 可以自适应核参数，在检测不同尺度的病害动态地调整感受野，对于较小的病害采用小核聚焦细节，而对于较大的病害采用大核覆盖区域。增强多尺度特征融合的针对性，使得不同病害形态的检测更为精准。形变与管状结构的特征相适配，示意图如图 4 所示。




图 4 蛇形卷积示意图

（3）特征输入层引入 EVCBlock 轻量化模块：在模型图像输入之后的初始特征提取层添加 EVCBlock 轻量化模块，这个模块利用高效通道压缩和融合的方法，既缩减了参数量和计算量，又保留了病害的关键特征，防止浅层特征的丢失，从而实现模型轻量化，适配茶叶病害现场算力较低的检测环境，还能兼顾检测的速度和实时性。

改进后的 YOLOv11 模型如图 5 所示，该模型保留了原模型轻量化，推理速度快的优势，又通过多模块的针对性融合，提升了小目标，形变目标的特征提取能力及抗干扰能力，在茶叶病害数据集上的检测精度能够得到显著提升，而且其参数量和计算量的增幅处于可控制范围之内，可以满足茶叶病害田间实时检测的实际需求。




图 5 改进后 YOLOv11 模型示意图

## 2.4 模型训练

在本研究中,实验的硬件环境是 Intel(R) Core(TM) i5-1140H (2.70 GHz) 和 NVIDIA GeForce RTX 3050 Laptop GPU。在 PyTorch 框架的基础上建立网络模型。所使用的 CUDA 版本为 12.1, Python 版本为 3.10.19, PyTorch 版本为 2.5.1。实验中 batch size 设置为 16, epoch 设置 100, 动量是 0.937, 初始学习率是 0.01, 衰减系数是 0.000 5。在训练结束后,通过设置不同的置信度阈值进行多次实验,综合考虑各种因素,在模型检测实验中采用的置信度阈值为 0.5。

## 2.5 评价指标

为了验证模型能否很好地分类茶叶病害来评估模型的性能,本文使用 Precision ( $P$ )、mAP 以及 FPS 这些指标去评估模型,具体计算公式为:

$$P = \frac{TP}{TP + FP} \times 100\% \quad (1)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

式中: TP 表示正样本预测出正样本的数量, FP 表示负样本预测出正样本的数量, FN 表示正样本预测出负样本数量。

$$AP = \int_0^1 P(R) dR \quad (3)$$

式中: AP 是对  $R$  值从 0 到 1 的积分,表示  $P$ - $R$  曲线下的连续面积。所有类别的 AP,即 mAP。

mAP 用公式为:

$$mAP = \frac{\sum_{i=1}^k AP_i}{k} \quad (4)$$

式中:  $k$  代表 AP 的数量, mAP 代表 AP 的平均值。

## 2.6 消融实验

为验证本文改进的每个模块的必要性,本文设置了四组实验。第一组实验是空白对照实验, Backbone 是 YOLOv11n; 第二组实验是在 YOLOv11 的 Backbone 和 Neck 中添加 DSCConv 模块,将这个实验项目命名为 S-YOLOv11; 第三组实验是在 S-YOLOv11 的 Backbone 中添加 CA 模块,将实验命名为 SC-YOLOv11; 第四组实验是在 SC-YOLOv11 中添加 EVCBlock 模块,将这项改进命名为 EVC,将实验命名为 SCE-YOLOv11。本研究中,为了排除无关变量对实验结果的干扰,四组实验所采用的数据集、软硬件实验环境相同,且阈值、初始学习率等关键参数均采用统一设置。四组实验的改进前后模型的实验结果如表 2 所示,改进前后模型对不同茶叶病害实验结果如表 3 所示,原模型与改进后模型训练的 mAP 结果对比图如图 6 所示。

表 2 改进前后的实验结果

| Models      | Precision/% | mAP/% | FPS/(帧·s <sup>-1</sup> ) |
|-------------|-------------|-------|--------------------------|
| YOLOv11     | 88.23       | 88.42 | 78.3                     |
| S-YOLOv11   | 90.02       | 89.73 | 61.8                     |
| SC-YOLOv11  | 91.83       | 90.25 | 58.3                     |
| SCE-YOLOv11 | 92.13       | 91.03 | 55.2                     |

表 3 改进前后各病害的检测精度

| Type of defects     | 单位: %                |                        |                         |                          |
|---------------------|----------------------|------------------------|-------------------------|--------------------------|
|                     | YOLOv11<br>Precision | S-YOLOv11<br>Precision | SC-YOLOv11<br>Precision | SCE-YOLOv11<br>Precision |
| healthy             | 88.5                 | 90.7                   | 92.6                    | 93.5                     |
| brown_blight        | 89.8                 | 89.3                   | 90.1                    | 92.9                     |
| gray_blight         | 85.1                 | 87.7                   | 89.5                    | 90.1                     |
| tea_algal_leaf_spot | 90.9                 | 91.1                   | 91.9                    | 92.0                     |
| green_mirid_bug     | 88.4                 | 90.3                   | 90.8                    | 91.3                     |
| red_spider          | 86.5                 | 89.8                   | 89.5                    | 90.4                     |
| Helopeltis          | 91.1                 | 92.7                   | 93.2                    | 93.2                     |

注: healthy 指健康的叶子; brown\_blight 指茶云纹叶枯病; gray\_blight 指茶轮斑病; tea\_algal\_leaf\_spot 指茶藻斑病; green\_mirid\_bug 指绿盲蝽; red\_spider 指红蜘蛛; Helopeltis 指茶角盲蝽。

实验结果显示, SCE-YOLOv11 模型在茶叶病害检测任务中有明显的性能优势。从整体指标角度来看,相对于基础 YOLOv11,依次加入 DSCConv, CA 注意力机制, EVC-Block 模块之后,模型的精度和 mAP 逐步得到改善, SCE-YOLOv11 的 Precision 达到 92.13%, mAP 为 91.03%, 较原

模型分别提升了 3.9 个百分点和 2.61 个百分点。这表明动态卷积（DSConv）较好地适应了病害形变特征，CA 注意力机制强化病害区域，EVCBlock 模块优化了特征融合情况，这些因素共同增强了模型识别复杂病害的能力。虽然 FPS 从 78.3 帧/s 降到 55.2 帧/s，但仍然符合实时监测的需求。




图 6 mAP 对比图

从单病害检测精度角度来看，SCE-YOLOv11 对各类病害的识别效果均有改善：其中“healthy”类的精度提升了 5 个百分点，“brown\_blight”以及“gray\_blight”这些病害类的精度平均提升了 2~3 个百分点，这表明改进后模型有效地降低了健康叶片和病害之间的混淆度，而且提升了对不同形态病害的区分能力。“tea\_algal\_leaf\_spot”的精度提升幅度比较小，只有 1.1 个百分点，大概是因为这种病害和健康叶片的纹理特征比较接近，后续需针对性优化特征提取策略。部分测试集检测结果如图 7 所示。




图 7 部分测试集检测结果图

综上所述，所提出的改进后模型在推理速度略有减慢的情况下，提升了茶叶病害检测的精度和泛化能力，验证了模型改进方向的有效性。

3 总结

本文针对茶叶病害检测存在病害形态复杂，背景信息干扰大的问题，以 YOLOv11 模型为基础，依次嵌入 DSConv，CA 注意力机制和 EVCBlock 模块，从而提出 SCE-YOLOv11 模型，该模型用于识别并区分 6 种茶叶病害，验证了蛇形动态卷积以及坐标注意力机制对于病害特征的适配及其强化效果。虽然推理速度有所下降，但仍然符合实时检测的需求。通过模块层级的改进实现了茶叶病害检测“精度—速度”的平衡，为茶园病害自动化监测提供了有效的技术途径，后续将会结合细粒度特征提取来进一步提升模型的泛化能力。

参考文献：

[1] 朱锐,张家瑜,黄继超,等.基于卷积神经网络的农作物叶片病害检测研究进展[J].农业工程学报,2025,41(17):15-28.

[2] 程术希.基于光谱和成像技术的作物病害不同侵染期快速检测方法研究[D].杭州:浙江大学,2014.

[3] 李明.茶叶采前病害图像检测及采后茶多酚光谱检测研究[D].南昌:华东交通大学,2024.

[4] 薛彦伟.茶叶病害图像特征提取与识别方法研究[D].晋中:山西农业大学,2022.

[5] 陈荣,李旺,周文玉.基于形状特征和支持向量机(SVM)的茶叶病害识别方法[J].贵州农业科学,2021,49(4):53-59.

[6] 贾瀛睿.改进YOLOv8的茶叶病害检测方法研究[D].荆州:长江大学,2025.

[7] Datta S, Gupta N.A novel approach for the detection of tea leaf disease using deep neural network[J]. Procedia Computer Science, 2023,218:2273-2286.

[8] Yang Ning, Yuan Minfeng, Wang Pan, et al. Tea diseases detection based on fast infrared thermal image processing technology[J].Journal of the Science of Food and Agriculture, 2019, 99(7): 3459-3466.

[9] Ahmed M, Mamun M S A. Distributional pattern and seasonal abundance of major pests of tea in bangladesh[J]. Tea Journal of Bangladesh, 2012, 41, 1-10.

[10] 胡根生,谢一帆,鲍文霞,等.面向无人机遥感图像中茶叶枯病检测的轻量型网络[J/OL].农业机械学报,1-18[2026-07-21].https://link.cnki.net/urlid/11.1964.S.20240228.1722.042.

【作者简介】

肖佳彤(1998—),女,河南南阳人,硕士研究生,助教、高校人工智能专任教师,研究方向:计算机视觉。

(收稿日期:2026-02-06 修回日期:2026-07-06)