

基于轻量化深度卷积神经网络的番茄叶片病害分类识别研究

崔鹏¹, 李杰¹, 汤岩春^{1, 2}, 许名扬³, 王晓松^{1*}

1. 山东工商学院 管理科学与工程学院, 山东 烟台 264005

2. 山东黄金矿业(玲珑)有限公司, 山东 招远 265400

3. 黑龙江省依安县信访局, 黑龙江 依安 161500

DOI:10.61369/ASDS.2026040006

摘 要 : 由于传统深度卷积神经网络(CNN)模型参数冗余高、计算资源消耗大,难以满足农业无人机及边缘计算设备的实时推理需求,本研究系统分析和验证 MobileNetV3、ShuffleNetV2、GhostNet 与 EfficientViT 等典型轻量化模型在番茄叶片病害细粒度分类任务中的性能表现。针对包含 10 类病害特征的番茄叶片统一数据集,从分类精度、计算复杂度(FLOPs)、推理延迟及模型可解释性等多维度进行量化评估。实验结果表明, EfficientViT 模型在综合性能上表现最优, F1-score 值达到 0.95, 展现出对复杂纹理病斑的卓越特征提取能力。而 ShuffleNetV2 则凭借最小的 FLOPs (0.15G) 与最高的推理吞吐量 (5625 images/s), 成为实时检测场景的首选方案。GhostNet 虽然参数量极致压缩,但在处理复杂病害特征时存在一定的精度瓶颈。Grad-CAM 可视化分析进一步证实, EfficientViT 能够更精准地聚焦于病灶区域, 具有更强的抗背景干扰能力。本研究为智慧农业装备中的边缘端模型选型提供了科学的理论依据与数据支撑。

关 键 词 : 番茄叶片病害; 轻量化模型; 细粒度分类; 复杂病害特征

Research on Classification and Recognition of Tomato Leaf Diseases Based on Lightweight Deep Convolutional Neural Networks

Cui Peng¹, Li Jie¹, Tang Yanchun^{1, 2}, Xu Mingyang³, Wang Xiaosong^{1*}

1. School of Management Science and Engineering, Shandong Technology and Business University, Yantai, Shandong 264005

2. Shandong Gold Mining (Linglong) Co., Ltd., Zhaoyuan, Shandong 265400

3. Yi'an Bureau of Letters and Visits, Yi'an, Heilongjiang 161500

Abstract : Because traditional deep convolutional neural network (CNN) models have high parameter redundancy and consume a large amount of computing resources, it is difficult to meet the real-time inference requirements of agricultural drones and edge computing devices. This study systematically analyzes and verifies the performance of typical lightweight models, including MobileNetV3, ShuffleNetV2, GhostNet, and EfficientViT, in the fine-grained classification task of tomato leaf diseases. Focusing on a unified tomato leaf dataset containing 10 types of disease characteristics, quantitative evaluations were conducted from multiple dimensions, such as classification accuracy, computational complexity (FLOPs), inference latency, and model interpretability. The experimental results show that the EfficientViT model achieves the best comprehensive performance, with an F1-score reaching 0.95, demonstrating superior feature extraction capabilities for complex texture lesions. Meanwhile, ShuffleNetV2, with the lowest FLOPs (0.15G) and the highest inference throughput (5625 images/s), emerges as the preferred solution for real-time detection scenarios. Although GhostNet highly compresses the number of parameters, it encounters certain accuracy bottlenecks when processing complex disease features. Grad-CAM visualization analysis further confirms that EfficientViT can more accurately focus on the lesion areas, possessing stronger resistance to background interference. This study provides a scientific theoretical basis and data support for edge model selection in smart agricultural equipment.

Keywords : tomato leaf diseases; lightweight models; fine-grained classification; complex disease feature

基金项目: 2025 省级大学生创新创业训练项目一视析果丰——基于 Vision Transformer 与数据增强的苹果叶片病害分类识别研究 (S202511688012)。

作者简介:

崔鹏 (2006-), 男, 汉族, 山东青岛人, 本科在读, 研究方向: 信息管理与信息系统;

李杰 (1997-), 男, 汉族, 山东泰安人, 研究生在读, 研究方向: 工业工程;

汤岩春 (1990-), 男, 汉族, 山东烟台人, 研究生在读, 山东黄金矿业(玲珑)有限公司地质工程师, 研究方向: 矿产地质勘查和矿山工程管理;

许名扬 (2001-), 女, 汉族, 黑龙江依安人, 本科, 研究方向: 信息管理与信息系统。

通讯作者: 王晓松, 山东工商学院管理科学与工程学院, 教授, 硕士生导师, 研究方向为大数据分析与应用。

引言

番茄作为全球重要的经济作物，其叶片病害的早期精准识别对保障产量与品质至关重要。传统人工诊断受主观经验与时效性的限制，难以适配现代化农业设施实现精准植保的目标。以 ResNet、DenseNet 为代表的深度卷积神经网络虽然在图像识别领域取得了显著成果，但受限于庞大的参数规模与高额的计算负载，在农业无人机和手持检测仪等资源有限的终端上进行部署是个难题，且难以实现实时推理。

近年来，以 MobileNet、ShuffleNet 为代表的轻量化网络架构，以及融合 Transformer 机制的 EfficientViT 等模型，通过深度可分离卷积、通道混洗及注意力机制等技术，在保证一定精度的前提下显著降低计算复杂度。然而，现有研究多聚焦于通用图像分类或单一模型的改进，缺乏针对番茄病害这一特定细粒度分类任务的系统性横向对比研究，尤其是不同轻量化架构对局部病斑纹理与全局色彩特征的适配性还不明确。

因此，本研究通过构建统一的实验基准，从模型精度、运算效率、收敛特性及可解释性等维度，对四类主流轻量化模型进行全方位评估，以其为农业智能装备的算法选型提供客观、量化的参考依据。

一、相关研究

（一）农作物病害识别技术

1. 传统机器学习方法

早期病害识别主要依赖传统图像处理技术，通过人工设计的颜色、纹理及形状特征（如 LBP、GLCM）结合支持向量机（SVM）或 K 近邻（KNN）分类器进行判别^[1]。然而，该类方法严重依赖专家先验知识进行特征工程，特征鲁棒性较差，难以适应非结构化农业环境中的复杂光照变化与背景干扰^[2]。随着深度学习技术的发展，卷积神经网络（CNN）凭借端到端的特征自学习能力，显著提升了识别精度，逐渐成为当前研究的主流范式^[3, 4]。

2. 深度学习方法

深度学习技术在计算机视觉领域发展迅猛，基于深度神经网络的农作物病害识别方法取得突破性进展^[5, 6]。卷积神经网络通过多层非线性变换，能够从原始图像中自动学习具有强判别力的特征表示，显著减少对人工特征设计的依赖^[7]。大量研究表明，深度学习模型在多种作物叶片（如水稻、玉米、小麦、苹果、葡萄等）病害识别任务中均取得优于传统方法的识别性能^[8, 9]。通过端到端训练方式，模型能够有效捕获病斑的颜色变化、纹理结构及空间分布特征，大幅提高对细粒度病害类别的区分能力^[10]。然而，随着网络结构不断加深（如，ResNet、DenseNet 等），模型参数量和计算复杂度显著增加，模型在农业无人机、手持终端等资源受限场景中的部署面临巨大挑战^[11, 12]。

（二）轻量化深度学习模型

1. MobileNet 模型

MobileNet 系列模型通过引入深度可分离卷积，将标准卷积分解为深度卷积和逐点卷积，从而在保持精度的同时显著减少计算量和参数数量。MobileNetV3 在此基础上进一步引入注意力机制（SE 模块）和高效激活函数（h-swish），在模型精度、推理速度与计算复杂度之间实现较好的平衡^[5]。由于其结构紧凑、效率较高，MobileNet 系列已成为轻量化网络研究中的典型代表，被广泛应用于移动端病害识别任务中。

2. ShuffleNet 模型

针对组卷积中的信息流通不畅问题，ShuffleNet 系列模型

提出了通道分割和通道混洗机制，有效减少卷积运算中的冗余计算，同时降低内存访问成本。ShuffleNetV2 在结构设计过程中进一步考虑实际硬件加速特性，在相同 FLOPs 条件下实现更高的推理速度^[13]。该类模型在保证较低计算复杂度的同时，能够维持较强的特征表达能力，特别适用于对实时性要求较高的检测场景。

3. GhostNet（GhostModule）模型

GhostNet 通过提出 GhostModule 的概念，利用廉价的线性变换生成冗余特征图（Ghostfeatures），从而减少对传统卷积操作的依赖。该方法在保持模型基本性能的同时，实现参数量和计算复杂度的极致压缩。尽管 GhostNet 在极低算力条件下具有显著的应用优势，但在处理复杂背景下的细粒度病害特征时，特征表达能力可能受到一定限制^[14]。

4. EfficientNet/EfficientViT 模型

EfficientNet 系列模型通过复合缩放策略，在网络深度、宽度和输入分辨率之间实现统一优化，后续研究引入 Fused-MBConv 等结构以提升训练效率^[15, 16]。近年来，VisionTransformer（ViT）结构逐渐被引入轻量化模型设计中。EfficientViT 将卷积操作的局部感知能力与自注意力机制的全局建模能力相结合，在保持较低计算复杂度的同时增强模型对上下文信息的捕获能力，在复杂纹理和细粒度分类任务中表现出良好潜力^[17]。

（三）轻量化模型在农业中的应用现状

随着农业智能化与信息化水平的不断提升，轻量化深度学习模型在作物病害识别、生长监测和智能农业装备等领域得到广泛关注^[14, 18]。研究表明，轻量化模型在保证一定识别精度的前提下，能够有效满足农业现场对实时性、低功耗和易部署性的严苛要求^[4, 5]。在农作物病害识别任务中，轻量化模型已被成功应用于多种作物叶片图像分类研究，并在移动终端和嵌入式设备上取得初步应用成效。然而，现有研究多集中于单一模型的改进或应用，不同轻量化架构（如，纯卷积架构与混合架构）在番茄病害细粒度分类任务中的性能差异尚缺乏系统比较，各种轻量化模型网络结构特性与病斑特征识别效果之间的内在联系有待进一步研究。因此，本研究在相同实验条件下，对多种典型轻量化模型在番茄叶片病害分类任务中的性能进行系统对比分析，以期

智能系统中边缘端模型的选型提供科学的实验依据和参考^[19, 20]。

二、材料与方法

（一）数据集构建

1. 数据来源与分布

本研究数据集由公开植物病害图库与田间实采图像整合而成，涵盖10个类别，包括细菌性斑点、早期疫病、晚期疫病、叶霉病、黄化曲叶病毒及健康叶片等，样本总量约1.9万张，分辨率归一化为 224×224 ，各类别样本的具体数量及占比分布如图1所示。数据集呈现显著的不均衡性，其中样本量最高的番茄黄化曲叶病毒（约4000张）与最低的番茄花叶病毒（约500张）之间存在约8倍的极值差异。针对数据集的这种分布不均衡特征，实施标准化数据增强策略，包括随机旋转（ $\pm 30^\circ$ ）、镜像翻转、HSV色彩空间扰动及随机裁剪，以提升模型在不同光照与姿态下的泛化能力。同时，为减轻这一分布特征对模型训练的负面影响，在训练阶段引入加权损失函数（WeightedLoss）进行修正，最终将数据按8:1:1的比例划分为训练集、验证集和测试集。

Distribution of Tomato Leaf Disease Categories in Dataset




图1：番茄叶片病害数据集各类别样本数量分布

2. 数据增强

为提升模型泛化能力并抑制过拟合风险，本研究在训练阶段实施了标准化的数据增强策略，具体效果如图2所示。增强方法主要包括：(1) 旋转增强，随机旋转 $\pm 30^\circ$ 以模拟叶片的自然生长姿态；(2) 翻转增强，执行水平与垂直翻转，赋予模型对叶片方向的不变性；(3) 色彩扰动，随机调整图像亮度、饱和度与对比度，以模拟田间复杂多变的光照条件；(4) 随机裁剪，在0.8~1.0的比例范围内随机裁剪并重缩放至目标尺寸，增强模型对病灶尺度变化的鲁棒性。上述策略既严格保持图像语义一致性，又显著扩展训练样本多样性空间。




图2：数据增强策略可视化效果对比

（二）对比模型结构

本研究选取EfficientViT、GhostNet、ShuffleNetV2以及MobileNetV3四种具有代表性的轻量化网络架构进行对比。这四类模型在设计理念上各有侧重，分别代表当前轻量化设计的主流方向（如，CNN架构优化、混合架构设计等）。为了更直观地阐述各模型的结构特性与应用潜力，本研究从核心机制、设计优势及适用场景三个维度对上述模型进行总结对比，对比结果如表1所示。

表1：不同轻量化模型在测试集上的识别性能对比

模型	核心机制	设计机制	适用场景
MobileNetV3 ^[5]	深度可分离卷积；SE注意力模块 +h-swish激活	在模型大小、精度与速度之间实现良好的平衡	通用的移动设备设备及常规嵌入式应用
ShuffleNetV2 ^[13]	通道分割；通道混洗	有效降低计算冗余；推理速度显著快于同级模型	对实时性要求极高、需快速推理的检测任务
GhostNet ^[14]	Ghost模块；线性变换生成特征图	在保持精度前提下极大减少计算开销；实现极致的参数压缩	存储空间与算力极其有限的边缘设备
EfficientViT ^[17]	融合CNN与Transformer架构； 优化缩放策略	兼具局部特征提取与全局感知能力；在复杂纹理识别任务中表现优异	对识别精度要求较高、需处理复杂病斑纹理的场景

（三）实验环境与超参数设置

实验依托TensorFlow/Keras深度学习框架，硬件环境配备NVIDIA RTX4060 GPU。训练过程采用Adam优化器，初始学习率设定为0.001，Batchsize为32，迭代轮次（Epoch）为30。损失函数选用交叉熵损失（Cross-Entropy Loss）。为保证实验结果的可比性与可复现性，本文所有性能指标（Accuracy、

Precision、Recall、F1-score及Loss）均来源于同一轮实验配置下模型在测试集上的最终评估结果，全文数值统一保留两位小数。

（四）评价指标

为全面、客观地评价不同轻量化模型在番茄叶片病害识别任务中的分类性能，评价从整体准确性与类别判别能力两个层面出

发，选取准确率（Accuracy）、精确率（Precision）、召回率（Recall）和 F1-score 作为主要评价指标。其中，Accuracy 用于衡量模型整体分类正确程度，而 Precision、Recall 与 F1-score 则更关注模型在类别层面的判别性能，能够有效反映模型在类别不平衡条件下的综合表现。准确率（Accuracy）定义为模型预测正确的样本数占总样本数的比例，其计算公式为：

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

精确率（Precision）用于衡量模型预测为某一类别的样本中，实际属于该类别的比例，反映模型预测结果的可靠性，其计算公式为：

$$Precision = \frac{TP}{TP + FP}$$

召回率（Recall）用于衡量某一类别样本中被模型正确识别的比例，反映模型对目标类别的覆盖能力，其计算公式为：

$$Recall = \frac{TP}{TP + FN}$$

F1-score 是 Precision 与 Recall 的调和平均值，综合考虑模型的查准率与查全率，在类别分布不平衡的情况下具有更强的评价稳定性，其计算公式为：

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

其中，TP 表示被正确预测为正类的样本数量，TN 表示被正确预测为负类的样本数量，FP 表示被错误预测为正类的样本数

量，FN 表示被错误预测为负类的样本数量。在多分类任务中，本文对各类别分别计算 Precision、Recall 与 F1-score，并采用宏平均（Macro-average）方式对各类别指标进行综合统计，以保证不同病害类别在整体评价中的权重一致，从而更客观地反映模型

$$F1_{macro} = \frac{1}{C} \sum_{i=1}^C F1_i$$

其中，C 表示类别总数， $F1_i$ 表示第 i 类的 F1-score。

三、实验结果与分析

（一）性能分析

为全面评估各模型在番茄叶片病害分类任务中的识别性能，本文选取准确率（Accuracy）、精确率（Precision）、召回率（Recall）和 F1-score 作为主要评价指标。

实验结果如表 2 所示，四种轻量化模型在测试集上均表现出较好的识别能力。EfficientViT 在各项指标上均位居首位，其准确率达到 96.5%，F1-score 达到 0.95，显著高于其他卷积神经网络模型，证明其结构在复杂病斑纹理与细粒度特征建模方面的优越性。MobileNetV3 与 ShuffleNetV2 性能相近，准确率分别为 93.8% 和 92.1%，在计算复杂度较低的情况下维持了稳定的分类效果。GhostNet 尽管在模型规模上极具优势，但其准确率（90.6%）和召回率（88.6%）在四类模型中相对较低，表明其在极简结构下对复杂特征的捕获能力存在一定局限。

表 2：不同轻量化模型在测试集上的性能对比

模型	Accuracy(%)	Precision(%)	Recall(%)	Loss	F1-score
MobileNetV3	93.8	93.5	90.1	0.47	0.90
ShuffleNetV2	92.1	91.8	89.2	0.29	0.88
GhostNet	90.6	89.8	88.6	0.43	0.89
EfficientViT	96.5	95.8	95.2	0.14	0.95

（二）模型轻量化效率分析

在农业应用场景中，模型的推理效率和资源消耗同样具有重要意义。为分析不同模型在训练与测试过程中的稳定性与收敛特性，实验对各模型在测试集上的准确率与损失随训练轮次变化情况进行了对比，如图 3 和图 4 所示。

从测试集准确率变化曲线可以看出，EfficientViT 在训练初期即可快速达到较高准确率，并在后续训练过程中保持较小波动，显示出良好的收敛速度与稳定性。MobileNetV3 在前期训练阶段存在一定波动，但在训练中后期逐渐趋于稳定。

ShuffleNetV2 和 GhostNet 的收敛过程相对平缓，整体准确率略低于 EfficientViT。

损失曲线分析结果与准确率曲线趋势基本一致，EfficientViT 的测试集损失值整体最低，且变化幅度较小，进一步验证了其较强的泛化能力。

尽管 EfficientViT 在 FLOPs 上略高于其他轻量化模型，如表 3 所示，但其显著提升的分类性能和稳定性在高精度农业识别场景中具有更高综合价值。

表 3：不同轻量化模型在测试集上的效率对比

模型	F1-Score ↑	FLOPs(G) ↓	推理速度 (images/s) ↑	参数量 (M) ↓	训练时间 (s) ↓
MobileNetV3	0.92	0.23	2800.04	4.21	36.21
ShuffleNetV2	0.90	0.15	5625.89	1.26	19.82
GhostNet	0.89	0.15	2671.71	3.91	38.60
EfficientViT	0.95	0.41	1393.88	4.02	60.05




图3：不同模型测试集准确率随 Epoch 变化曲线




图4：不同模型测试集损失值随 Epoch 变化曲线

（三）混淆矩阵分析

为进一步分析模型在不同病害类别上的分类表现，本文对四种模型在测试集上的预测结果绘制了混淆矩阵。混淆矩阵能够直观反映各类别的正确分类情况及误分类分布特征。




图5：EfficientViT 模型混淆矩阵

混淆矩阵（图5-8）进一步揭示模型在细粒度病害区分上的性能差异。分析显示，所有模型在特征显著且样本量充足的类别（如“健康叶片”和“番茄黄化曲叶病毒”）上均保持极高的识别准确率。然而，在区分“早疫病”与“晚疫病”这一难点上，模型表现出现显著分化。由于这两类病害的病斑均呈现褐色坏死

状，且纹理特征极具相似性，MobileNetV3和 GhostNet 在这两类之间出现了较高的相互误判率。这表明，部分极度轻量化的网络结构在大幅压缩计算量的同时，牺牲对图像高频细节特征的捕获能力，导致其难以提取出区分相似病斑的关键细微纹理。

值得注意的是，在样本量最少的“番茄花叶病毒”类别上，EfficientViT 表现出更强的均衡性，误判数量明显少于其他模型，这说明融合自注意力机制的模型能够更好地学习到小样本类别的判别性特征，减弱了数据集分布不均衡带来的负面影响。




图6：MobileNetV3 模型混淆矩阵




图7：ShuffleNetV2 模型混淆矩阵




图8：GhostNet 模型混淆矩阵

（四）激活图 Grad-CAM 分析

为增强模型决策过程的可解释性，本文采用 Grad-CAM 方法

对不同模型的分类结果进行可视化分析。通过对网络最后一层卷积特征图进行梯度加权并映射至输入图像空间,生成类别相关的显著性热力图,从而观察模型在分类过程中关注的关键区域。

从 Grad-CAM 可视化结果可知, EfficientViT 模型能够较为准确地聚焦于叶片病斑区域和关键纹理结构,而对背景区域的响应较弱,表明其分类决策主要基于病害相关特征。相比而言, MobileNetV3、ShuffleNetV2 和 GhostNet 在部分样本中存在关注区域分散或背景干扰现象,这在一定程度上影响了其分类性能。

Grad-CAM 可视化是观察模型性能和特点的依据之一。如表 4 所示, EfficientViT 能够精准聚焦于叶片的病斑区域和关键边缘纹理,对背景噪声的响应极弱。相比之下, ShuffleNetV2 和 GhostNet 在处理部分复杂背景样本时,注意力区域存在一定程度的分散或偏移,这解释了其在细粒度分类精度上略逊于 EfficientViT 的原因。

表 4: 四种轻量化模型的 Grad-CAM 热力图可视化对比

MobileNetV3	GhostNet	ShuffleNetV2	EfficientViT
			

(五) 综合分析

综合实验结果分析可得, EfficientViT 适用于追求高精度识别的专业诊断设备, ShuffleNetV2 是农业无人机等实时检测终端的最佳选择, MobileNetV3 提供了性能与资源的良好折中, 而 GhostNet 则适用于对存储空间有极致要求的微型传感器节点。

四、结论与未来工作

(一) 结论

通过量化实验深刻揭示不同轻量化架构在番茄病害识别中的

性能差异及其适用边界。实验结果表明, EfficientViT 所采用的 CNN 与 Transformer 混合架构有效突破纯卷积网络在复杂背景下细粒度特征提取的瓶颈, 以 96.5% 的精度确立其在高标准诊断场景中的标杆地位。与此同时, 验证了 ShuffleNetV2 在极低算力约束下实现实时推理的不可替代性。研究不仅证明各模型在“精度-效率”权衡中的具体位置, 更为差异化的农业智能装备研发提供精准的算法选型策略与理论支撑。

(二) 未来工作展望

基于现有研究成果, 未来将从数据生态、多模态感知及系统集成等维度进行深入研究, 推动技术落地。

复杂田间环境下的鲁棒感知是未来研究需要攻克的难点之一。研究如何拓展采集光照剧变与叶片遮挡下的实景数据, 利用域自适应技术攻克“受控-实景”域偏移难题, 显著提升模型在非结构化巡检场景中的泛化边界。

多模态数据融合与早期预警则是研究的另一个重点问题。突破单一视觉局限, 融合 RGB、高光谱及环境传感数据, 构建“环境-表型”双驱动感知模型, 大幅提升对潜伏期微小病斑的检测灵敏度。

“诊-决-治”闭环系统集成是研究的最终目标。将识别模型嵌入农业 IoT 系统, 联动无人机变量施药平台; 基于病害热力图实现定点、定量的精准作业, 构建“监测-决策-执行”的智慧农业全流程闭环。

参考文献

[1] BILLAH M M, SULTANA A, AFTAB S R, et al. Leaf disease detection using convolutional neural networks: A proposed model using tomato plant leaves[J]. Neural Computing and Applications, 2024: 1-11.

[2] SHARMA R, NAAZ S, VAIDYA P. Harnessing deep learning with AlexNet for tomato leaf disease detection in the Indian Himalayan terrain[J]. Journal of Electrical and Computer Engineering, 2025, 2025(1): 2807347.

[3] GUHA S P, AMIN A B, ARPA S, et al. A real-time application-based convolutional neural network approach for tomato leaf disease classification[J]. Array, 2023, 19: 100313.

[4] 王晨. 基于轻量级卷积神经网络的番茄病虫害分类研究 [D]. 长春: 吉林农业大学, 2023.

[5] HE Z, TONG M. LT-YOLO: A lightweight network for detecting tomato leaf diseases[J]. Computers, Materials & Continua, 2025, 82(3): 4301-4317.

[6] ABDULLAH A, AMRAN A G, TAHMID A M S, et al. A deep-learning-based model for the detection of diseased tomato leaves[J]. Agronomy, 2024, 14(7): 1593.

[7] NI S, JIA Y, ZHU M, et al. An improved ShuffleNetV2 method based on ensemble self-distillation for tomato leaf diseases recognition[J]. Frontiers in Plant Science, 2025, 15: 1521008.

[8] 杨进进, 张文慧, 王哲. 基于改进的 ResNet18 模型识别番茄叶片多种病害 [J]. 现代计算机, 2024, 30(9): 30-34.

[9] 侯文慧, 龚昌智, 曹文昊, 等. 基于超分辨率增强与改进 YOLOv8 的番茄叶片病害检测 [J]. 农业工程学报, 2025, 41(16): 211-220.

[10] YAN C, LI H. CAPNet: Tomato leaf disease detection network based on adaptive feature fusion and convolutional enhancement[J]. Multimedia Systems, 2025, 31(2): 178.

- [11] JIAPING J, SHUFEI L, CHEN Q, et al. A tomato disease identification method based on leaf image automatic labeling algorithm and improved YOLOv5 model[J]. Journal of the Science of Food and Agriculture, 2023, 103(14): 7070–7082.
- [12] SUN Y, NING L, ZHAO B, et al. Tomato leaf disease classification by combining EfficientNetV2 and a Swin Transformer[J]. Applied Sciences, 2024, 14(17): 7472.
- [13] 宋国柱, 黄文静, 崔帅帅, 等. 基于改进 YOLOv8n 的轻量化番茄叶片小目标病害识别方法 [J]. 农业工程学报, 2025, 41(10): 232–242.
- [14] SLADOJEVIC S, ARSENOVIC M, ANDERLA A, et al. Deep neural networks based recognition of plant diseases by leaf image classification[J]. Computational Intelligence and Neuroscience, 2016(6): 1–11.
- [15] CHEN M, WANG C, LIU C, et al. Tomato leaf disease detection method based on improved YOLOv8n[J]. Scientific Reports, 2025, 15(1): 25837.
- [16] ZAHID U, NAJAH A, MONA J, et al. EffiMob-Net: A deep learning-based hybrid model for detection and identification of tomato diseases using leaf images[J]. Agriculture, 2023, 13(3): 737.
- [17] ALAMPALLY S, CHIRANJEEVI M. A smart solution for tomato leaf disease classification by modified recurrent neural network with severity computation[J]. Cybernetics and Systems, 2024, 55(2): 409–449.
- [18] PREETI B, SHARMA R J, KETAN K. TomConv: An improved CNN model for diagnosis of diseases in tomato plant leaves[J]. Procedia Computer Science, 2023, 218: 1825–1833.
- [19] KUMAR V, KAUR M, MITTAL V, et al. TLD-FDL: Tomato leaf disease classification using end-to-end fusion of deep learning models[J]. SN Computer Science, 2025, 6(8): 933.
- [20] 许悦, 陈琳. 基于改进 YOLO v8 的番茄叶片病害检测算法 [J]. 江苏农业科学, 2024, 52(17): 192–200.