

基于残差连接的轻量化番茄作物病害检测模型

邹强¹ 宋欣¹ 宋中越^{2,3} 田颖⁴ 朝博¹ 贾学勤¹

(1. 天津农学院工程技术学院, 天津 300392; 2. 天津北斗航电技术有限公司, 天津 300459;
3. 天津中德应用技术大学能源工程学院, 天津 300350; 4. 北京交通大学机械与电子控制工程学院, 北京 100044)

摘要: 番茄作物生长过程中容易受到多种病害的侵袭。基于深度学习模型的病害检测策略,其计算量通常较大。针对这个问题,本文提出了一种轻量化深度学习模型 ResDepSepNet。该模型基于残差模块构建,引入深度可分离卷积,并通过增加卷积运算步长实现下采样。同时引入 SE (Squeeze-and-excitation) 注意力模块,提升病害识别能力。采用 PlantVillage 番茄作物病害数据集对 ResDepSepNet 模型进行了测试,并将测试结果与 MobileNetV2 模型和 TrioConvTomatoNet 模型进行对比。测试结果显示,ResDepSepNet 模型的整体识别正确率分别比 MobileNetV2 模型和 TrioConvTomatoNet 模型高 4.8、1.1 个百分点,且其浮点运算次数仅为 3.5×10^7 , 约为 MobilenetV2 模型和 TrioConvTomatoNet 模型的 1/18 和 1/7。本研究为番茄作物病害检测提供了技术参考。

关键词: 番茄; 病害检测; 轻量化设计; 残差模块

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2026)01-0140-09

OSID:



Lightweight Tomato Crop Disease Detection Model Based on Residual Connections

ZOU Qiang¹ SONG Xin¹ SONG Zhongyue^{2,3} TIAN Ying⁴ CHAO Bo¹ JIA Xueqin¹

(1. College of Engineering and Technology, Tianjin Agricultural University, Tianjin 300392, China

2. Tianjin Beidou Navigation and Aviation Electronics Technology Co., Ltd., Tianjin 300459, China

3. School of Energy Engineering, Tianjin Sino-German University of Applied Sciences, Tianjin 300350, China

4. School of Mechanical, Electronic and Control Engineering, Beijing Jiaotong University, Beijing 100044, China)

Abstract: Tomato crops are prone to be attacked by various diseases during their growth process. The computational load of disease detection strategies based on deep learning models was usually substantial. To address this issue, a lightweight deep learning model called ResDepSepNet was proposed. This model was constructed based on residual modules to alleviate the gradient vanishing problem that may occur during model training, thereby improving the overall performance of the model. To reduce the model's computational load, depthwise separable convolutions were introduced, and downsampling was achieved by increasing the stride of the convolutional operations. Additionally, an squeeze-and-excitation (SE) attention module was introduced to enable the model to focus more on feature information crucial for disease identification, thereby enhancing its disease recognition capability. The ResDepSepNet model was tested by using the PlantVillage tomato disease dataset, and the test results were compared with the MobileNetV2 model and the TrioConvTomatoNet model. The test results showed that the overall accuracy of the ResDepSepNet model was 4.8 and 1.1 percentage points higher than that of the MobileNetV2 and TrioConvTomatoNet models, respectively. Moreover, its floating-point operations count was merely 3.5×10^7 , approximately 1/18 and 1/7 of those of the MobilenetV2 and TrioConvTomatoNet models, respectively. The research result can provide a technical reference for disease detection in tomato crops.

Key words: tomato; disease detection; lightweight design; residual module

收稿日期: 2025-10-08 修回日期: 2025-10-24
基金项目: 河北省重点研发计划项目(22347402D)和天津农学院科学研究发展基金计划项目(J01008)
作者简介: 邹强(1987—),男,讲师,博士,主要从事番茄作物病害识别策略研究,E-mail: qiangzou1@126.com
通信作者: 宋欣(1979—),女,教授,博士,主要从事智能农机装备研究,E-mail: 17116377@bjtu.edu.cn

0 引言

在我国,番茄产业已成为农民增收和出口创汇的重要途径^[1-2]。番茄种植受多种因素影响,包括气候变化、土壤类型、土壤肥力、土壤含水率、病害等。其中番茄作物病害的发生会对番茄产量造成严重影响^[1,3]。传统的人工检测方法耗时费力且易受主观因素影响^[4],因此,自动化、智能化的病害检测系统逐渐成为研究热点。早期智能化的番茄作物病害检测主要依赖于传统的机器学习方法^[5]。文献[6-8]均聚焦于基于机器学习的农作物病害检测研究,借助不同的特征提取与机器学习算法,为甜菜和番茄的病害识别提供了解决方案。虽然基于机器学习的方法在一定程度上是有效的,但其检测正确率往往取决于研究者所选择的图像预处理方法和用于病害检测的图像特征。因此,这些方法的泛化能力较差^[1,9]。

随着深度学习技术的兴起,特别是卷积神经网络的出现,农作物病害识别领域取得了突破性进展。卷积神经网络具有从原始图像中自动学习特征的能力,能够提高病害检测准确性。文献[1,5,10-14]均聚焦于利用深度学习技术对番茄作物病害进行识别,从不同角度和模型架构出发,在番茄作物病害智能诊断领域得到了丰富的研究成果。然而,深度学习模型往往结构复杂、参数众多,导致其计算量较大,难以在诸如移动电话、无人机、物联网设备等计算资源受限的设备上部署和运行^[15]。虽然目前已经有了一些轻量化的深度学习模型,例如经典的 MobileNetV2^[16] 和针对番茄作物病害识别的 TrioConvTomatoNet^[1],但如何在进一步减少计算量的同时保持较高的病害识别正确率,降低模型对高性能计算设备的依赖,使其能够应用于计算资源严重受限的农作物种植区域,仍然是一个需要解决的关键问题。

针对这些问题,本文提出一种轻量化的番茄作物病害识别模型 ResDepSepNet。在 ResDepSepNet 模型中,为了缓解梯度消散问题,构建了 3 级残差块组(16-32-64 通道),并通过增加卷积步长的方式,实现下采样,以降低数据空间维度,减少计算量。另外,在模型中引入注意力机制模块和深度可分离卷积,以增强重要特征通道的表达能力,并进一步降低模型的计算量。

1 ResDepSepNet 网络

ResDepSepNet 是一种用于识别番茄作物病害的深度卷积神经网络模型,它是参考文献[1]中提

出的用于番茄作物病害识别的 TrioConvTomatoNet 网络,通过一系列优化后得到的轻量化网络。ResDepSepNet 模型包含卷积层、深度可分离卷积层、批处理归一化层、ReLU 激活层、全局平均池化层、全连接层和 Softmax 分类器等。

1.1 卷积层

卷积层是用于构建特征图的基本模块,它通过滤波器核对输入图像进行卷积操作,以此来实现对输入图像中各类特征信息的提取。每一个滤波器核卷积操作的计算公式为^[17]

$$(I * K)(i, j) = \sum_{l=1}^c \sum_{m=0}^{k_w-1} \sum_{n=0}^{k_h-1} I(is + m, js + n, l) K(m, n, l) \tag{1}$$

式中 I ——输入图像或输入特征图
 K ——滤波器核
 (i, j) ——输出特征图中位置的横、纵坐标
 m, n ——滤波器核中的索引变量,遍历滤波器核的每一个元素
 l ——输入图像的通道索引序号
 k_w ——滤波器核宽度
 k_h ——滤波器核高度
 s ——步长
 c ——输入图像或输入特征图通道数

1.2 深度可分离卷积

深度可分离卷积是一种特殊类型的卷积方式,它将 1.1 节中常规卷积层操作分解为两个独立步骤:深度卷积(Depthwise convolution)层和逐点卷积(Pointwise convolution)层。在深度卷积阶段,卷积核只对单个通道进行操作,而不是像传统卷积那样跨通道混合;随后,在逐点卷积阶段,使用 1×1 的卷积核跨通道进行卷积,实现通道间的信息融合和维度的变化^[18]。深度学习模型中常规卷积与深度可分离卷积的参数数量计算公式分别为

$$P_c = k_w k_h c a \tag{2}$$

$$P_{dc} = k_w k_h c + c a \tag{3}$$

式中 P_c ——常规卷积层参数数量
 a ——滤波器核数量

P_{dc} ——深度可分离卷积层参数数量

从式(2)和式(3)可以得出,当 $k_w \geq 2, k_h \geq 2, a \geq 2$ 且 $c > 0$ 时, $P_c > P_{dc}$ 。由此可知,与常规卷积相比,深度可分离卷积的参数更少,所需的计算成本更低。

1.3 批处理归一化层

批处理归一化能够在数据进入激活函数前,对数据进行归一化操作。将每个小批量数据(batch)强制调整为均值为 0、方差为 1 的标准正态分布,使得激活函数的输入数据能够落在激活函数的非线性

敏感区域,提升梯度传播的有效性。

假设小批量数据 $B = \{x_1, x_2, \cdots, x_m\}$, 其均值和方差分别为 μ_B 和 σ_B^2 。对数据进行标准化,即^[19]

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \tag{4}$$

式中 $\hat{x}_i$ ——归一化后数据
 ε ——极小常数,防止分母为 0

1.4 ReLU 激活层

修正线性单元 (Rectified linear unit, ReLU) 激活层核心思想是通过简单的阈值操作引入非线性特性,对输入值进行非线性变换。假设 ReLU 激活层的输入量为 v , ReLU 激活层输出量的计算公式为^[20]

$$f(v) = \max(0, v) \tag{5}$$

式中 $f(v)$ ——激活层的输出量

通过式 (5) 可以看出,当 $v > 0$ 时,输出等于输入,梯度为 1;当 $v \leq 0$ 时,输出强制为 0。由于 ReLU 激活层只需判断其输入值是否大于 0,因此其计算速度非常快,远超 sigmoid 和 tanh 函数^[20]。

1.5 全局平均池化层

全局平均池化 (Global average pooling) 层的原理是将每个特征图的所有像素值进行平均,从而将每个特征图转换为单个数值^[21]。全局平均池化层针对各输入特征图的计算公式为

$$G(d) = \frac{1}{hw} \sum_{i=1}^h \sum_{j=1}^w d_{i,j} \tag{6}$$

式中 $G(d)$ ——全局平均池化输出值
 h ——输入特征图竖直方向的像素数量
 w ——输入特征图水平方向的像素数量
 $d_{i,j}$ ——输入特征图中第 i 行第 j 列的像素值

通过式 (6) 可以看出,全局平均池化层通过全局平均操作整合了特征图的空间信息,使模型能够更关注通道级的全局统计特征而非局部细节,在减少模型参数的同时,增强模型的鲁棒性。

1.6 全连接层与 Softmax 分类器

全连接层 (Fully connected layer, FC) 是深度神经网络中用于特征组合的核心组件,其原理为通过线性变换与非线性激活函数将输入特征映射到目标输出空间。全连接层输出量的计算公式为^[19-20]

$$y = F(Wq + b) \tag{7}$$

式中 q ——全连接层输入量
 W ——权重矩阵
 b ——偏置向量
 F ——激活函数
 y ——全连接层输出向量

为了能够对不同的番茄作物病害进行识别,采

用了 Softmax 分类器作为分类头中全连接层的激活函数。Softmax 分类器可以处理多分类问题,且能够输出数据样本属于不同类别的概率,具有较高的实际应用价值。Softmax 分类器的表达式为^[22]

$$Y = \frac{1}{\sum_{j=1}^t e^{\theta_j^T z}} [e^{\theta_1^T z} \quad e^{\theta_2^T z} \quad \cdots \quad e^{\theta_t^T z}]^T \tag{8}$$

式中 Y ——分类器的输出量
 z ——分类器的输入量
 t ——类别数量
 θ ——分类器参数

1.7 模型结构

在模型结构上, ResDepSepNet 结合了残差连接、深度可分离卷积和注意力机制等,使其在保持较高识别正确率的同时降低模型的计算量。ResDepSepNet 模型的结构如图 1 所示。

从图 1 可以看出, ResDepSepNet 模型中包含了 3 个残差模块组,分别为残差模块 1 和残差模块 2、残差模块 3 和残差模块 4、残差模块 5 和残差模块 6。通道数由 16 逐步增加至 64,以提取图像中的高级特征。模型的输入图像被设置为 128 像素 $\times$ 128 像素的 RGB 图像。图像输入模型后首先通过具有 3×3 卷积核、输出为 16 通道的卷积层,初步提取输入图像的不同特征,并通过 ReLU 激活函数引入非线性表达能力。而后将初步提取到的特征,输入由多个残差模块组成的残差模块组。残差连接是 HE 等^[23] 在 2016 年提出的,通过在网络中加入恒等映射,缓解了深层网络中梯度消失的问题,提升网络性能。残差模块的整体结构描述为^[24]

$$Z = X + g(\alpha, X) \tag{9}$$

式中 Z ——残差模块输出
 X ——残差模块输入
 $g(\alpha, X)$ ——残差函数
 α ——残差函数中的可学习参数

通过残差连接的方式,使特征和梯度的传递更加高效,进而提升网络的整体性能^[24]。

如图 1 所示, ResDepSepNet 中的残差模块主要使用深度可分离卷积提取图像特征。参考经典 MobileNetV2^[16] 的网络结构,在深度卷积层和逐点卷积层之间加入了批处理归一化层和 ReLU 激活函数,以加速训练过程,提高网络的泛化能力。另外,为了降低数据空间维度,减少计算量,在部分残差模块中通过将卷积步长设置为 2×2 ,代替传统的池化方法,实现下采样。采用增加卷积步长的方式进行下采样,可以减少特征图下采样导致的信息丢失问题,提高网络的整体性能^[24]。同时,参考经典




图 1 ResDepSepNet 网络结构图

Fig.1 Network structure diagram of ResDepSepNet

Resnet 网络的结构,在步长为 2×2 的残差模块后,加入了步长为 1×1 的残差模块,以进一步提取和细化特征。为了使模型在保持较低计算量的同时,抑制不相关或冗余的特征通道,提升后续层的训练效果,在残差模块2 后面加入了 SE (Squeeze-and-

excitation) 注意力机制模块 (SE_Block)。SE 注意力机制是 HU 等^[25] 在 2019 年提出的,主要用于动态调整特征图中不同通道的权重,在增强重要特征通道表达能力的同时,抑制不重要的特征通道,从而提升模型的性能。SE_Block 的结构如图 2 所示。




图 2 SE_Block 结构图

Fig. 2 SE_Block architecture diagram

从图 2 可以看出,在 SE_Block 中首先通过全局平均池化对每个通道的输入特征进行压缩。之后通过两个全连接层学习通道间的相关性,生成各通道的重要性权重。最后通过重塑确保模块输出与输入特征图的通道维度对齐,以便后续能将模块输出的通道权重与输入特征图逐通道相乘,提高网络对重要特征通道的敏感性。

在输出识别结果方面,如图 1 所示,残差模块 6 的输出结果经过 ReLU 激活函数后输入至全局平均池化层,并通过 Dropout 随机丢弃 30% 的特征,以防止模型过拟合,增强模型的鲁棒性。最后通过全连接层与 Softmax 分类器,输出病害识别结果。

2 测试与结果分析

2.1 测试环境

本文在 Kaggle Notebook 环境下,对不同模型针对番茄作物病害的识别正确率进行测试。Kaggle

Notebook 是 Kaggle 平台提供的在线交互式编程环境,专为数据科学和机器学习任务设计,支持 Python、R 等语言,内置强大的计算资源、丰富的数据集和工具库。在测试过程中,Kaggle Notebook 环境的内存容量为 29 GB,显卡型号为 Tesla P100,显存容量为 16 GB。

2.2 测试数据集

PlantVillage 数据集是一个被广泛认可的基准数据集,包含多种农作物的样本图像,普遍用于农作物病害检测模型的训练和测试。图 3 显示了来自 PlantVillage 数据集中番茄作物数据集的部分样本图像。该番茄作物数据集包括 18 160 幅番茄作物叶片图像,涵盖了 10 个类别,包括 9 种番茄作物病害叶片图像和健康番茄作物叶片图像。PlantVillage 数据集的全面性和多样性使其成为研究人员的宝贵资源,为评估病害检测模型的性能提供了测试基准^[26]。目前,PlantVillage 番茄作物数据集在许多番茄作物病害检测研究中被使用^[27-28]。因此,本文采用了 PlantVillage 番茄作物数据集对所提出 ResDepSepNet 模型的病害检测效果进行测试。

在测试过程中,采用各类别图像中 70% 的图像作为训练数据集,20% 的图像作为验证数据集,10% 的图像作为测试数据集。各类别用于训练、验证和测试的图像数量如图 4 所示。

2.3 测试结果分析

为了使所设计的深度学习模型能够在计算资源受限的环境下应用,本文将所提出的 ResDepSepNet 模型与两种轻量化模型 MobileNetV2^[16](各层参数值采用在 ImageNet 中的预训练结果,重新设置并训练分类头,以适应对番茄作物健康及不同病害的识别)和 TrioConvTomatoNet^[1]进行对比。MobileNetV2 是由谷歌公司于 2018 年设计的经典轻量级深度学习模型^[16],在保持较高性能的同时,极大地减少了模型的计算量,使其非常适合在计算资源受限的设备上进行图像识别任务。许多研究均通过



图 3 PlantVillage 番茄作物病害数据集部分样本图像

Fig. 3 Some sample images from PlantVillage tomato crop disease dataset



图 4 各类别用于训练、验证和测试的图像数量

Fig. 4 Number of images used for training, validation, and testing in each category

MobileNetV2 模型获取基线结果^[5,29-30]。TrioConvTomatoNet^[4] 是于 2024 年提出的针对番茄作物病害识别的轻量化深度学习模型,在保持较高识别正确率的同时,实现了比 MobileNetV2 更小的计算量。因此,在测试过程中将所提出的 ResDepSepNet 模型与这两种模型进行了对比。

由于不同模型的结构存在差异,难以预先确定最适合的训练参数,因此对模型训练的两个关键超参数——优化器和初始学习率,分别设置了不同备选项。在优化器方面,选择了被广泛使用的随机梯度下降 (Stochastic gradient descent, SGD) 和自适应矩估计 (Adaptive moment estimation, Adam) 作为备选项,其中 SGD 对学习率较为敏感,但在收敛时可能更稳定;Adam 则凭借其自适应学习率机制,对超参数的选择相对不敏感。此外,初始学习率作为影响训练过程的核心超参数,其取值大小直接关系到模型的收敛速度与稳定性:较大的初始学习率有助于加快模型在训练初期的收敛,但可能导致损失函数数值震荡;较小的学习率虽能提升训练的稳定性,但可能使模型收敛缓慢甚至陷入局部最优。因此,初始学习率设置了 0.1、0.01 和 0.001 不同量级作为备选。在对比过程中,针对每个模型,分别将不同的优化器与不同的初始学习率组合对模型进行训练,并从中选取在测试集上图像识别正确率最高的结果,用于后续不同模型间的对比。图像识别正确率的计算公式为^[31]

$$A = \frac{1}{p} \sum_k^p I(\hat{y}_k, \bar{y}_k) \times 100\%$$

(10)

其中

$$I(\hat{y}_k, \bar{y}_k) = \begin{cases} 1 & (\hat{y}_k = \bar{y}_k) \\ 0 & (\hat{y}_k \neq \bar{y}_k) \end{cases}$$

(11)

式中 $\hat{y}$ ——通过识别得到的图像标签
 $\bar{y}$ ——实际图像标签
 p ——被识别的图像数量

另外,由于在文献[1]中比较了不同优化器下 TrioConvTomatoNet 模型对番茄作物病害图像的识别效果,在 SGD 优化器下 TrioConvTomatoNet 模型的图

像识别正确率最高。因此在训练过程中, TrioConvTomatoNet 模型的优化器被直接设置为 SGD。经过对比,不同模型对测试集中图像识别正确率最高时的训练参数设置如表 1 所示。

表 1 不同模型训练参数


Tab. 1 Training parameters for different models

模型		MobileNetV2	TrioConv TomatoNet	ResDepSepNet
优化器	Adam	SGD	SGD	
学习率 设置	初始学习率	0. 01	0. 001	0. 1
	监控指标	验证集损失	验证集损失	验证集损失
	衰减系数	0. 2	0. 2	0. 2
	容忍步数	5	5	5
	最小学习率	1×10^{-6}	1×10^{-6}	1×10^{-6}
早停	监控指标	验证集损失	验证集损失	验证集损失
	容忍步数	30	30	30

在表 1 所示的训练参数下,不同模型对测试集中不同类别图像识别的混淆矩阵以及对测试集中不同类别图像的识别正确率,分别如图 5、6 所示。

结合图 5、6 可以看出,针对不同番茄作物病害类别,所提出的 ResDepSepNet 模型均能实现较高的识别正确率。其中,识别正确率相对较低的类别为早疫病,识别正确率为 89%。测试集中被 ResDepSepNet 模型识别错误的部分早疫病图像如图 7 所示。由于严重的早疫病和晚疫病都会导致番茄叶片出现大面积病变,这种整体形态的改变会掩盖病害的特异性症状,因此导致部分早疫病图像被错误识别为晚疫病。另外如图 7 所示,部分早疫病图像中叶片外形完好,与其他病害叶片相比,仅存在一些细微的差异未能被模型准确捕捉,因此被误判为其它类型病害。

在不同模型识别正确率方面,如图 6 所示,与 TrioConvTomatoNet 模型相比,除细菌性斑点病外,在其它类别下,ResDepSepNet 识别正确率提高 0 ~ 5 个百分点。与 MobileNetV2 模型相比,在不同类别下,ResDepSepNet 识别正确率提高 0.2 ~ 13 个百分点。在对测试集识别的整体正确率方面,MobileNetV2 模



型、TrioConvTomatoNet 模型和 ResDepSepNet 模型的整体识别正确率分别为 92.8%、96.5% 和 97.6%。与 MobileNetV2 模型和 TrioConvTomatoNet 模型相比,所提出 ResDepSepNet 模型的整体识别正确率分别提高了 4.8、1.1 个百分点。

另外,在部分应用场景中,由于环境资源受限,需要将用于病害检测的深度学习模型,部署在计算能力有限的移动设备或其他平台上。因此需要模型在具有较高识别正确率的同时具有较低的计算量。浮点运算次数能够表示模型计算的复杂性^[5],该指标目前被广泛应用于深度学习模型研究^[5,12,14]。较低的浮点运算次数表明模型更适合在计算资源受限的环境中部署,对于评估模型的实用性至关重要。本文 MobileNetV2、TrioConvTomatoNet 和 ResDepSepNet 模型的浮点运算次数分别为 6.13×10^8 、 2.35×10^8 和 3.5×10^7 。所提出 ResDepSepNet 模型的浮点运算次数显著低于 MobileNetV2 模型和 TrioConvTomatoNet 模型,分别仅约为 MobileNetV2 模型和 TrioConvTomatoNet 模型的 1/18 和 1/7。由此可见,在计算资源受限的环境下,所提出的 ResDepSepNet 模型具有更好的实用价值。

3 结论

(1)本文针对番茄作物病害识别问题,提出了一种轻量化深度学习模型 ResDepSepNet。该模型基于 3 个残差模块组构建,以缓解模型训练过程中可能出现的梯度消失问题,提高模型的整体性能。为了降低模型的计算量,引入了深度可分离卷积,并通过增加卷积运算步长,以实现下采样。同时,在模型中加入了 SE 注意力机制模块,使得模型可以更加聚焦于对病害识别具有关键作用的特征信息。

(2)采用 PlantVillage 番茄作物病害数据集对所提出的 ResDepSepNet 模型进行测试,并将测试结果与 MobileNetV2 模型和 TrioConvTomatoNet 模型的测试结果进行了对比。测试结果显示,与 MobileNetV2 模型和 TrioConvTomatoNet 模型相比,所提出 ResDepSepNet 模型针对番茄作物健康及不同病害的整体识别正确率分别提高了 4.8、1.1 个百分点。在计算量方面,ResDepSepNet 模型的浮点运算次数仅为 3.5×10^7 ,分别约为 MobileNetV2 模型和 TrioConvTomatoNet 模型的 1/18 和 1/7。由此可见,所提出的 ResDepSepNet 模型更容易在资源受限的环境下部署。

参 考 文 献

[1] VINI L S, RATHIKA P. TrioConvTomatoNet: a robust CNN architecture for fast and accurate tomato leaf disease classification for real time application[J]. Scientia Horticulturae, 2024, 330: 113079.

[2] 任晶秋, 万恩晗, 单蜜, 等. 基于改进 YOLO v8n 网络的番茄成熟度实时检测算法[J]. 农业机械学报, 2025, 56(3): 374 – 382, 450.

REN Jingqiu, WAN Enhao, SHAN Mi, et al. Improved YOLO v8n network for real-time detection of tomato maturity[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 374 – 382, 450. (in Chinese)

[3] 张领先, 景嘉平, 李淑菲, 等. 基于图像自动标注与改进 YOLO v5 的番茄病害识别系统[J]. 农业机械学报, 2023, 54(11): 198 – 207.

ZHANG Lingxian, JING Jiaping, LI Shufei, et al. Tomato disease recognition system based on image automatic labeling and improved YOLO v5[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 198 – 207. (in Chinese)

[4] 杨玮, 伏冬朔, 吴龙起, 等. 基于改进 YOLO v7 的番茄黄化曲叶病毒病分级检测方法[J]. 农业机械学报, 2025, 56(6): 527 – 534.

YANG Wei, FU Dongshuo, WU Longqi, et al. Tomato yellow leaf curl virus disease grading detection method based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(6): 527 – 534. (in Chinese)

[5] ZARBOUBI M, BELLOUT A, CHABAA S, et al. Custom Bottleneck – VGGNet: advanced tomato leaf disease identification for sustainable agriculture[J]. Computers and Electronics in Agriculture, 2025, 232: 110066.

[6] RUMPF T, MAHLEIN A, STEINER U, et al. Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance[J]. Computers and Electronics in Agriculture, 2010, 74(1): 91 – 99.

[7] USAMA M, MONA A S A, ABOUL E H, et al. Tomato leaves diseases detection approach based on support vector machines [C]// International Computer Engineering Conference, 2015: 246 – 250.

[8] XIE C, YANG C, HE Y. Hyperspectral imaging for classification of healthy and gray mold diseased tomato leaves with different infection severities[J]. Computers and Electronics in Agriculture, 2017, 135: 154 – 162.

[9] GONG Z, GAO C, FENG Z, et al. Integrating masked generative distillation and network compression to identify the severity of wheat fusarium head blight[J]. Computers and Electronics in Agriculture, 2024, 227: 109647.

[10] ALI M A, SŁOWIK A, HEZAM M I, et al. Sustainable smart system for vegetables plant disease detection: four vegetable case studies[J]. Computers and Electronics in Agriculture, 2024, 227: 109672.

[11] SUNIL C, JAIDHAR C, NAGAMMA P. Tomato plant disease classification using multilevel feature fusion with adaptive

channel spatial and pixel attention mechanism[J]. Expert Systems With Applications,2023,228:120381.

[12] WANG X, LIU J. An efficient deep learning model for tomato disease detection[J]. Plant Methods,2024,20(1):61.

[13] VÁSCONEZ J, VÁSCONEZ I, MOYA V, et al. Deep learning-based classification of visual symptoms of bacterial wilt disease caused by *Ralstonia solanacearum* in tomato plants[J]. Computers and Electronics in Agriculture,2024,227: 109617.

[14] AMITAVA N, PRIYA R C, SUKUMAR N. Mobile app-based tomato disease identification with fine-tuned convolutional neural networks[J]. Computers and Electronics in Agriculture,2023,112:108995.

[15] ANKITA G, VIJAYPAL S D, GEETA R, et al. Time and space efficient multi-model convolution vision transformer for tomato disease detection from leaf images with varied backgrounds[J]. Computers, Materials and Continua,2024,79(1):117 – 142.

[16] SANDLER M, HOWARD A, ZHU Menglong, et al. MobileNetV2: inverted residuals and linear bottlenecks[C] //IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 4510 – 4520.

[17] IAN G,YOSHUA B, AARON C. 深度学习[M]. 北京: 人民邮电出版社, 2017.

[18] FRANÇOIS C. Xception: deep learning with depthwise separable convolutions[C] //IEEE Conference on Computer Vision and Pattern Recognition, 2017:1800 – 1807.

[19] 王连众. 基于 FMCW 毫米波雷达的目标识别[D]. 西安: 西安电子科技大学, 2022.
WANG Lianzhong. Target recognition based on FMCW millimeter-wave radar [D]. Xi'an: Xidian University, 2022. (in Chinese)

[20] 刘玉良, 戴凤智, 张全. 深度学习[M]. 西安:西安电子科技大学出版社, 2020.

[21] 李佳欣. 基于深度学习的人脸图像疲劳检测算法研究[D]. 哈尔滨: 哈尔滨理工大学, 2024.
LI Jiaxin. Research on fatigue detection algorithm of face images on deep learning[D]. Harbin: Harbin University of Science and Technology, 2024. (in Chinese)

[22] 邹强. PEMFC 气体供给系统故障诊断及容错控制策略研究[D]. 北京: 北京交通大学, 2023.
ZOU Qiang. Research on fault diagnosis and fault-tolerant control strategy for PEMFC gas supply system[D]. Beijing: Beijing Jiaotong University, 2023. (in Chinese)

[23] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C] //IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 – 778.

[24] LI Mingxuan, ZHOU Guoxiong, CHEN Aibin, et al. Identification of tomato leaf diseases based on LMBRNet[J]. Engineering Applications of Artificial Intelligence,2023,123:106195.

[25] HU Jie, SHEN Li, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019,42(8):2011 – 2023.

[26] SHEHU A H, ACKLEY A, MARVELLOUS M, et al. Early detection of tomato leaf diseases using transformers and transfer learning[J]. European Journal of Agronomy,2025,168:127625.

[27] HAREEM K, RIMSHA R, WAKEEL A, et al. Tomato leaf disease detection using convolution neural network [C] // International Bhurban Conference on Applied Sciences and Technologies, 2016:346 – 351.

[28] ELFATIMI E, ERYİĞİT R, ELFATIMI L. Deep multi-scale convolutional neural networks for automated classification of multi-class leaf diseases in tomatoes[J]. Neural Computing & Applications,2024,36(2): 803 – 822.

[29] ZENG Weihui, LI Haidong, HU Gensheng, et al. Lightweight dense-scale network (LDSNet) for corn leaf disease identification[J]. Computers and Electronics in Agriculture,2022,197:106943.

[30] DENG Limiao, LI Juan, HAN Zhongzhi. Online defect detection and automatic grading of carrots using computer vision combined with deep learning methods[J]. LWT,2021,149:111832.

[31] ZHANG Zehan, LI Shuanghong, XIAO Yawen, et al. Intelligent simultaneous fault diagnosis for solid oxide fuel cell system based on deep learning[J]. Applied Energy, 2019, 233 – 234:930 – 942.