

王九玲,周会国,李文峰. 基于轻量化密集尺度网络的番茄叶片病害识别算法[J]. 江苏农业科学,2025,53(5):156-164.

doi:10.15889/j.issn.1002-1302.2025.05.019

基于轻量化密集尺度网络的番茄叶片病害识别算法

王九玲¹,周会国²,李文峰³

(1. 安阳职业技术学院,河南安阳 455000; 2. 郑州大学信息工程学院,河南郑州 450001;

3. 中国空间技术研究院西安分院,陕西西安 710100)

摘要:番茄叶片病害识别是农业智能化的重要应用之一,准确快速的病害识别对于番茄的健康生长和高产至关重要。然而,现有的模型在实际应用中常常由于背景复杂、病害尺度不一致等原因,难以实现高效准确的识别。因此,本研究提出了一种轻量化密集尺度网络,以提高番茄叶片病害识别的准确性和效率,并能够在低成本设备上实现快速识别。首先,网络通过使用不同扩张率卷积的密集连接结构,增强了对不同尺度病害的适应能力。具体来说,通过在网络中引入多种扩张率的卷积核,使得模型能够更好地捕捉到不同尺度病害的特征。其次,采用协调注意力尺度融合方法,替换了传统的拼接连接。此方法能够在不同尺度特征之间建立更加紧密的联系,提升特征提取的有效性,从而增强整体模型的识别能力。结果表明,优化后的模型在测试数据集上的准确率达到 0.968,优于现有的重量级网络(AlexNet、VGG16、VGG19 和 ResNet50)和轻量级网络(DenseNet121、GoogleNet、MobileNet、ShuffleNet v2 和 GhostNet)。本研究为实现低成本设备上的高效番茄叶片病害识别提供了新的方法和思路,具有重要的理论意义和实际应用价值。

关键词:密集尺度网络;轻量化;番茄叶片病害;多尺度变化

中图分类号:S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2025)05-0156-09

番茄是世界上最重要的蔬菜作物之一,具有丰富的营养价值和广泛的经济效益^[1-3]。全球番茄产量占据重要地位,我国更是世界上最大的番茄生产国之一。然而在生长过程中,番茄容易受到各种病原菌、害虫等的侵害,导致产量和品质严重下降,给农业生产带来重大损失^[4]。随着设施农业的发展和消费者对番茄品质的要求提高,番茄叶片病害的防控成为了一个亟待解决的问题。因此,准确及时地识别和诊断番茄叶片病害,是实现番茄病害防治

和智能化病害管理的关键技术。

长期以来,番茄叶片病害识别主要依赖于人工观察和经验判断,这种方法不仅耗时耗力,识别结果也容易受到人为因素的影响,导致判断存在不准确性和不稳定性^[5]。近些年,随着数字图像处理、计算机视觉以及机器学习等技术的快速发展,基于图像的番茄叶片病害自动识别技术逐渐成为研究热点^[6-8]。这种方法通过对采集的番茄叶片图像进行预处理、特征提取以及分类识别等过程,实现对常见番茄叶片病害的自动检测和识别,可有效提高识别效率和准确率^[9]。充分利用这些前沿技术,开发快速精准的番茄叶片病害识别系统,对促进番茄病害的防治与智能化管理意义重大。

陈智超等采用 Bi-LSTM(双向长短期记忆网络)和多尺度卷积神经网络相结合的模型,通过双

收稿日期:2024-07-01

基金项目:国家自然科学基金(编号:62002330)。

作者简介:王九玲(1988—),女,河南安阳人,硕士,讲师,主要从事计算机技术研究。E-mail:wangmin213a@163.com。

通信作者:周会国,博士,教授,主要从事计算机应用研究。E-mail:zhouhuiguo1979@163.com。

[21] Xie Y H, Yin B, Han X W, et al. Improved YOLO v7 - based steel surface defect detection algorithm [J]. Mathematical Biosciences and Engineering, 2024, 21(1): 346 - 368.

[22] Iqbal J, Munir M A, Mahmood A, et al. Leveraging orientation for weakly supervised object detection with application to firearm localization [J]. Neurocomputing, 2021, 440: 310 - 320.

[23] 刘毅君,何亚凯,吴晓媚,等. 基于改进 Faster R-CNN 的马铃薯发芽与表面损伤检测方法[J]. 农业机械学报, 2024, 55(1):

371 - 378.

[24] 舒振宇,秦昊. 基于 SKNet 注意力机制的飞机类型识别算法[J]. 中南民族大学学报(自然科学版), 2024, 43(1): 69 - 77.

[25] 麻斯亮,许勇. 最小点距离的边界框回归损失函数及其应用[J]. 小型微型计算机系统, 2024, 45(11): 2695 - 2701.

[26] 李云红,张蕾涛,李丽敏,等. 基于 CycleGAN-IA 方法和 M-ConvNext 网络的苹果叶片病害图像识别[J]. 农业机械学报, 2024, 55(4): 204 - 212.

向 LSTM 捕捉上下文信息,多尺度卷积网络融合全局和局部特征,并引入注意力机制聚焦病害区域,为番茄病害识别提供了有效解决方案^[10]。马丽等基于 MobileNet v3 进行改进,分析不同参数对模型准确率的影响,验证该模型对番茄常见叶片病害的识别准确率达 97.29%,性能优于其他模型^[11]。王志强等提出融合多尺度特征和坐标注意力机制的混合模型,通过多尺度特征融合和坐标注意力机制,识别准确率达 94.11%,参数量仅为原模型的 1/6,使模型在准确率与计算成本间取得平衡,为病害检测提供支撑^[12]。

然而,上述方法也存在一些问题和挑战,主要包括以下几个方面:番茄叶片图像在真实环境中拍摄时,往往会受到光照、遮挡、复杂背景等因素的干扰,导致图像质量的降低和病害特征的模糊^[13]。番茄叶片病害具有多样性和多尺度性,即不同种类的病害可能有相似的症状,同一种类的病害在不同发展阶段可能有不同的表现,以及同一张图像中可能存在多种尺度的病害区域。这些都增加了番茄叶片病害识别的难度和复杂度。番茄叶片病害识别需要在低成本、低功耗、低延迟的设备上运行,以满足实时性和可移动性的要求^[14]。因此,需要设计轻量化且高效的识别模型,以适应有限的计算资源和存储空间。

为提升番茄叶片病害识别模型准确率,本研究提出了一种基于轻量化密集尺度网络(lightweight dense scale network,简称 LDSN)的番茄叶片病害识别方法。该方法为通过不同扩张率卷积的密集连接,提高对番茄叶片病害尺度变化的适应性,并增强了特征之间的信息传递;提出了一种协调注意力尺度融合(coordinated attention scale fusion,简称 CASF)方法,替换了传统密集网络中的拼接连接,有效地降低了模型参数量,并增强了复杂背景下的番茄叶片特征提取能力;在公开数据集 PlantVillage 上进行试验验证,并与现有的重量级网络和轻量级网络进行对比分析,评估本研究提出的模型在番茄叶片病害识别任务上的性能和效率。

1 试验数据

1.1 病害图像

本研究采用了 PlantVillage 开源的植物叶片病害图像数据集作为试验数据源,该数据集包含了多个常见农作物的各类病害图像。为探究番茄叶片

病害识别问题,从数据集中筛选出了番茄的 8 个常见病害类别,包括早疫病、褐斑病、叶霉病等,每类包含 500 张图像,加上 500 张健康叶片,共计 4 500 张图像组成训练和测试数据集,部分样例见图 1。这些丰富的多类别病害图像,覆盖了番茄生长周期的各个阶段,病害发生的不同部位,可以很好地表征番茄病害的多样性。本研究基于此图像数据集,训练卷积神经网络模型,实现对番茄病害的准确识别和诊断,以期对番茄病害防治提供有力支撑。

1.2 数据预处理

首先,对训练集进行数据增强操作,以提高模型的泛化能力和鲁棒性。对研究数据增强操作包括:图像裁剪、缩放、旋转、翻转、颜色变换、噪声添加等,通过使用 OpenCV、PIL、scikit-image 等图像处理库或工具来实现,增强后的训练集共有 10 000 张图像,可以保证模型在不同的数据集上进行训练、验证和测试,进而确保评估模型的性能和效果。最后,将初始数据集按照 8:1:1 的比例划分为训练集、验证集和测试集,各自的数量分别为 8 000、1 000、1 000 张图像。

2 轻量化密集尺度网络

2.1 LDSN 架构概述

LDSNet 模型架构见图 2,由 1 个输入层、1 个卷积层、1 个最大池化层、3 个不同扩张率卷积的密集连接块、1 个平均池化层和 1 个全连接层组成。扩张卷积^[15]是指在卷积核中插入空洞来增加感受野,使用不同扩张率的扩张卷积来获取不同尺度的特征,并通过密集连接来融合这些特征。CASF 是由 2 个注意力机制组成:空间注意力机制(SA)和通道注意力机制(CA)。SA 是通过计算每个位置上不同通道之间的相关性来生成 1 个空间注意力图,用于突出特征图中重要的区域^[16]。CA 是通过计算每个通道上不同位置之间的相关性来生成 1 个通道注意力向量,用于突出特征图中重要的通道。LDSNet 使用 3 个不同扩张率卷积的密集连接块来提取番茄叶片病害图像的多尺度特征,每个块输出的特征图大小分别为 $48 \times 28 \times 28$ 、 $96 \times 14 \times 14$ 和 $192 \times 7 \times 7$,详细参数设置见表 1。

2.2 改进的密集扩张卷积

扩张卷积是一种在卷积核中插入空洞的卷积操作,可以用一个超参数 d 来控制空洞的大小。当 $d=1$ 时,它就是普通的卷积;当 $d>1$ 时,它就是扩

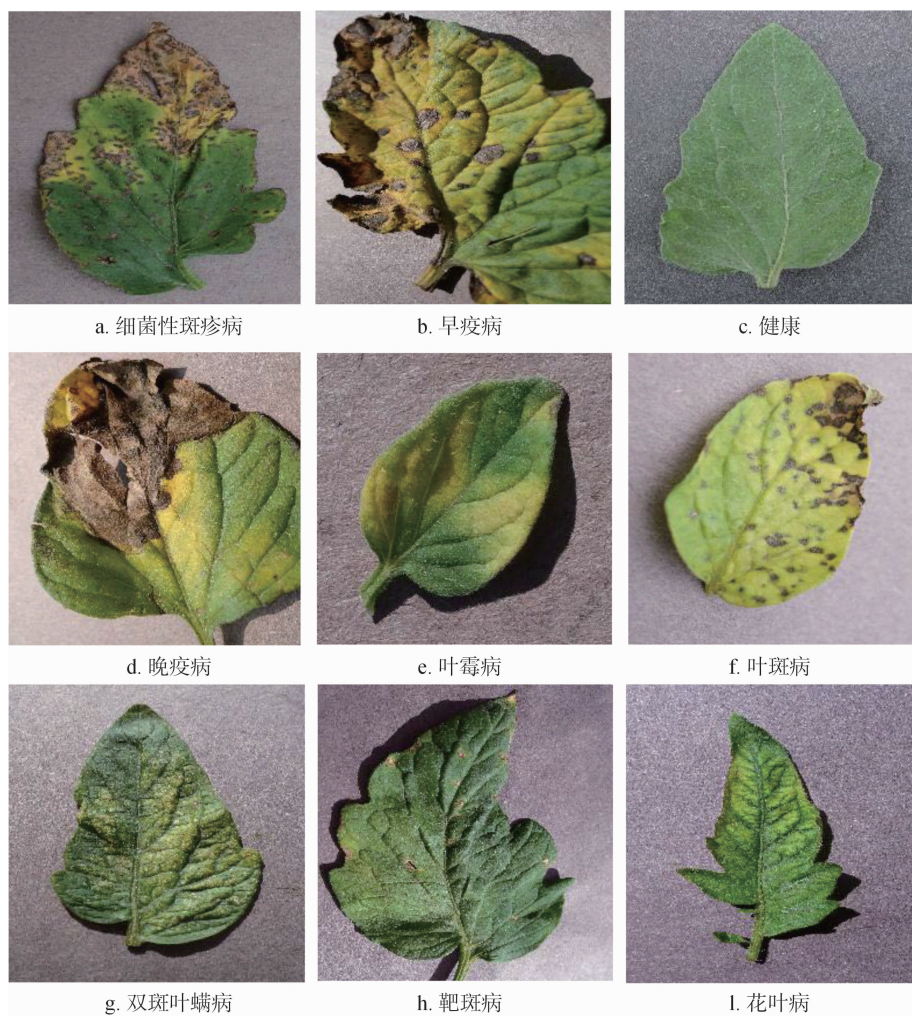


图1 番茄病害图像样本

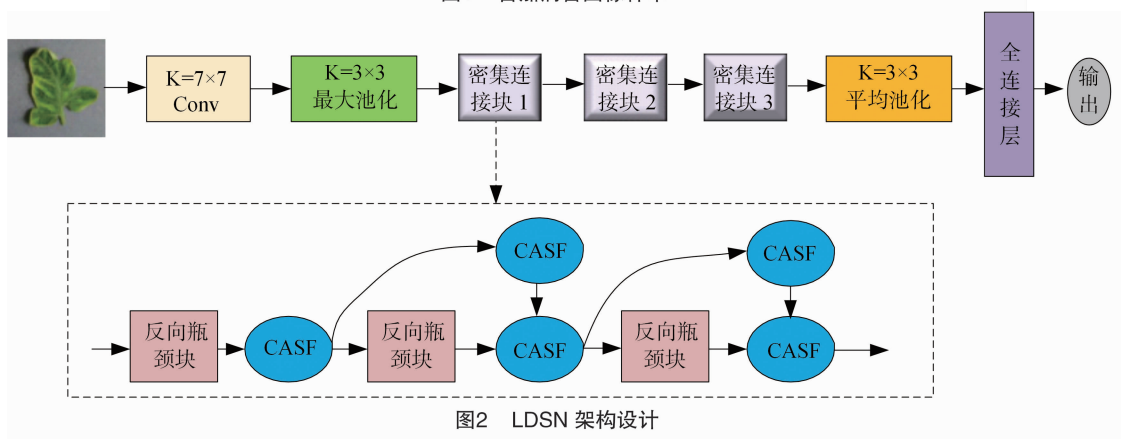


图2 LDSN 架构设计

张卷积。扩张卷积的优点是可以在不增加参数量和计算量的情况下,增大感受野,从而捕捉更大范围的上下文信息。扩张卷积的数学表达式如下:

$$y(i) = \sum_{k=0}^{K-1} x(i+r \cdot k) \cdot w(k)。 \quad (1)$$

式中: y 是输出特征图; x 是输入特征图; w 是卷积核; K 是卷积核的大小; r 是扩张率(或空洞数); i 是

特征图中的位置索引。可以看出,当 $r=1$ 时,这个公式就退化为普通的卷积;当 $r>1$ 时,这个公式就会跳过一些位置进行卷积。扩张卷积的感受野可以用以下公式计算:

$$RF_{i+1} = RF_i + (k' - 1) \cdot S_i。 \quad (2)$$

式中: RF_{i+1} 是当前层的感受野; RF_i 是上一层的感受野; k' 是等效卷积核的大小; S_i 是之前所有层的步

表 1 模型细节参数设置

名称	输出张量	配置	参数量(B)
输入	$1 \times 224 \times 224$	图像增强	0
7×7 Conv	$24 \times 112 \times 112$	Conv(步长=2), BN, ReLU	4 896
3×3 最大池化	$24 \times 56 \times 56$	步长=2	0
密集连接块 1	$48 \times 28 \times 28$	$\begin{bmatrix} 1 \times 1, 96 \\ 3 \times 3, 96 \\ 1 \times 1, 24 \end{bmatrix}$	30 462
密集连接块 2	$96 \times 14 \times 14$	$\begin{bmatrix} 1 \times 1, 192 \\ 3 \times 3, 192 \\ 1 \times 1, 48 \end{bmatrix}$	217 895
密集连接块 3	$192 \times 7 \times 7$	$\begin{bmatrix} 1 \times 1, 384 \\ 3 \times 3, 384 \\ 1 \times 1, 96 \end{bmatrix}$	345 972
7×7 平均池化	192		0
全连接层	9		1 864
总计			601 089

长的乘积。等效卷积核的大小可以用以下公式计算:

$$k' = k + (k - 1) \cdot (r - 1)。(3)$$

可以看出,当 $r = 1$ 时,等效卷积核的大小就等于原始卷积核的大小;当 $r > 1$ 时,等效卷积核的大小就会增大。

密集连接是一种将不同层之间的特征图进行拼接的操作,可以用以下公式表示:

$$x_{i+1} = H_i([x_0, x_1, \dots, x_i])。(4)$$

式中: x_{i+1} 是第 $i+1$ 层的特征图; H_i 是第 i 层的非线性变换函数(如卷积、激活等); $[x_0, x_1, \dots, x_i]$ 是将前面所有层的特征图沿着通道维度进行拼接。可以看出,每一层都可以获取到之前所有层的信息。

扩张卷积可以增大感受野,捕捉更大范围的上下文信息;密集连接可以增加特征图的多样性和冗余性,利用之前所有层的信息^[17-18]。利用两者优势就可以提高对番茄叶片病害尺度变化的适应性,不同大小和形状的病斑都可以被有效地分割出来。因此提出扩张卷积的密集连接,即利用不同扩张率的扩张卷积来构建空间金字塔池化(spatial pyramid pooling,简称 SPP)的方法。SPP 是一种将不同尺度或区域的特征图进行池化并拼接的方法,可以提高模型对尺度变化和物体位置变化的鲁棒性^[19]。扩张卷积的密集连接使用不同扩张率的扩张卷积来代替不同尺度或区域的特征图,并将它们进行密集连接,可以用以下公式表示:

$$y = [f(x), f_r^1(x), f_r^2(x), f_r^3(x), f_r^4(x)]。(5)$$

式中: y 是扩张卷积的密集连接的输出特征图; f 是一个 1×1 的卷积; f_r^i 是一个扩张率为 r_i 的 3×3 的扩张卷积; $[\dots]$ 表示沿着通道维度进行拼接。可以看出,扩张卷积的密集连接可以利用不同扩张率的扩张卷积来捕捉不同尺度的上下文信息,并通过密集连接来增加特征图的多样性和冗余性,密集连接中的反向瓶颈块如图 3 所示。

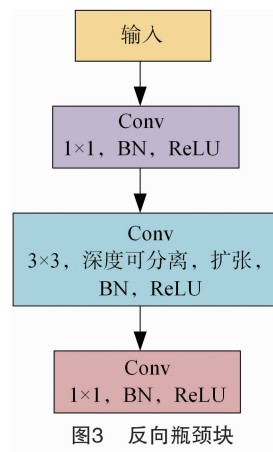


图3 反向瓶颈块

2.3 CASF 方法

CASF 方法可以有效地降低模型参数量,拼接连接会导致通道数目的增加,从而增加了模型的复杂度和计算量;而 CASF 方法则不会改变通道数目,只是对每个通道进行加权,从而减少了模型的复杂度和计算量。CASF 块细节如图 4 所示,与传统的密集网络中的拼接连接相比,CASF 方法可以增强复杂背景下的番茄叶片特征提取能力,拼接连接只是简单地将不同尺度的特征图放在一起,没有考虑到不同尺度特征之间的关系和重要性;而 CASF 方法

则可以通过学习不同尺度特征之间的关系和重要性,从而对不同尺度特征进行适当的加权,使得模型能够更好地捕捉到不同大小和形状的番茄叶片病害,并减少误分割的情况。

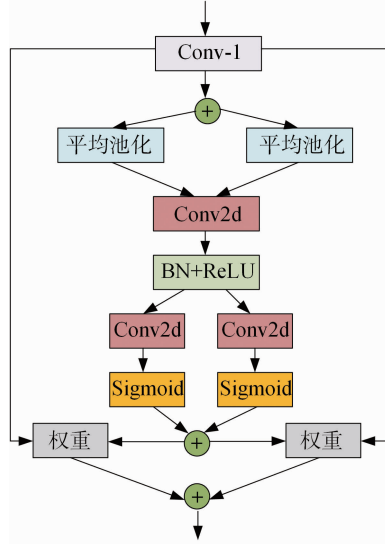


图4 CASF 方法

CASF 方法的基本思想是将输入的特征图分解为不同的尺度,并对每个尺度的特征图进行通道注意力权重的提取,然后利用 Softmax 函数对不同尺度的通道注意力权重进行归一化和协调,最后将协调后的权重和相应的特征图进行加权求和,得到融合后的特征图。CASF 方法的数学表达式如下:

$$X = \text{Conv}(X); \quad (6)$$

$$X_i = \text{Spilt}(X, i); \quad (7)$$

$$Z_i = \text{SEWeight}(X_i); \quad (8)$$

$$W_i = \text{Softmax}(Z_i); \quad (9)$$

$$Y = \sum_{i=1}^n W_i \odot X_i; \quad (10)$$

式中: X 是输入的特征图; Conv 是一个 1×1 的卷积层,用于降低通道维度; Spilt 是一个分割函数,用于将特征图按照通道维度分割为 n 个子特征图,每个子特征图的通道数为 n/C , C 表示分割因子; X_i 表示经过 Spilt 函数分割后的子特征图; SEWeight 是一个通道注意力权重提取函数,用于计算每个子特征图的全局平均池化和全连接层,得到每个子特征图的通道注意力权重向量; Z_i 表示经过 SEWeight 函数处理后的特征图; Softmax 是一个归一化和协调函数,用于对不同尺度的通道注意力权重向量进行 Softmax 操作,得到每个子特征图的协调后的权重向量; \odot 是一个点乘操作,用于将每个子特征图和相应的权重向量进行加权; Y 是输出的融合后的特征图。

2.4 模型训练

LDSNet 模型的目标是根据输入的番茄叶片图像,输出一个预测的病害类别。为了评估模型的预测性能,本研究采用交叉熵损失函数^[20],用以下公式表示:

$$L = - \sum_{i=1}^N y_i \lg(p_i). \quad (11)$$

式中: N 是类别的总数; y_i 是真实类别的标签; p_i 是预测类别的概率; \lg 表示以 10 为底的对数。当预测类别和真实类别完全一致时,损失函数为零;当预测类别和真实类别完全不同时,损失函数为无穷大。本研究采用随机梯度下降算法优化模型参数,用以下公式表示:

$$\theta_{t+1} = \theta_t - \eta \nabla L(\theta_t). \quad (12)$$

式中: θ_t 是第 t 次迭代时的模型参数; η 是学习率; $\nabla L(\theta_t)$ 是损失函数对模型参数的梯度。

为了计算损失函数对模型参数的梯度,需要使用链式法则,将复杂的函数分解为简单的函数,并逐层计算梯度。LDSNet 模型由多个层组成,每个层都有自己的输入、输出和参数。可以将 LDSNet 模型表示为一个复合函数:

$$L = L(f_n \{f_{n-1} [\dots f_1(x)]\}). \quad (13)$$

式中: x 是输入图像; f_i 是第 i 层的函数; f_n 是最后一层的全连接层。根据链式法则,可以得到:

$$\nabla L = \frac{\partial L}{\partial f_n} \frac{\partial f_n}{\partial f_{n-1}} \dots \frac{\partial f_2}{\partial f_1} \frac{\partial f_1}{\partial x}. \quad (14)$$

因此,只需要计算每个层输出对输入和参数的偏导数,并将它们相乘,就可以得到损失函数对模型参数的梯度。

3 结果与分析

3.1 试验背景

本研究的试验环境基于 Ubuntu 18.04 系统,使用单块 Nvidia RTX 2080 Ti GPU 在 PyTorch 框架下进行模型的训练和评估。试验结果于 2024 年 4 月在郑州大学信息工程学院实验室完成。服务器配备 Intel i7-8700K CPU 和 32 GB DDR4 内存,以及 512 GB 固态硬盘。主要的软件版本包括 Python 3.6、PyTorch 1.3.1、CUDA 10.1 和 cudnn 7.6.5。基于构建的番茄叶片病害图像数据集,对 LDSN 模型进行训练和测试,以实现番茄叶片病害的自动识别,模型训练参数如表 2 所示。

3.2 评价指标

为验证本研究模型的有效性,采用准确率、精

表 2 超参数设置

参数名称	值
训练批次	100
学习率	0.001
批次大小	64
优化器	Adma
衰减率	0.97

准确率、召回率和 F_1 分数作为评价指标。这些指标都是基于混淆矩阵的概念,用来衡量分类模型的性能^[21-22]。准确率(Accuracy)表示分类正确的样本占总样本个数的比例。计算公式为

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (15)$$

式中:TP(true positive)是真正例,即预测为正且真实为正的样本;TN(true negative)是真反例,即预测为负且真实为负的样本;FP(false positive)是假正例,即预测为正但真实为负的样本;FN(false negative)是假反例,即预测为负但真实为正的样本。准确率越高,说明模型越准确。但是,当数据集中不同类别的样本比例严重不平衡时,准确率就不能很好地反映模型的效果。精确率(Precision)又叫查准率,表示预测结果为正例的样本中实际为正样本的比例。计算公式为:

$$Precision = \frac{TP}{TP + FP} \quad (16)$$

精确率越高,说明模型对正例的判断越准确,假正例越少,用来衡量模型对正例(病害叶片)的预测准确性,即预测为正例的样本中实际为正例的比例。这个指标反映了模型对病害叶片的识别能力,越高越好。召回率(Recall)又叫查全率,表示实际为正样本中被预测为正样本的比例。计算公式为:

$$Recall = \frac{TP}{TP + FN} \quad (17)$$

召回率越高,说明模型对正例的覆盖程度越高,漏报越少,用来衡量模型对正例(病害叶片)的预测覆盖度,即实际为正例的样本中被预测为正例的比例。这个指标反映了模型对病害叶片的检测能力,越高越好。 F_1 分数(F_1 -score)是精确率和召回率的调和平均数,用来综合考虑两者的影响,寻找一个平衡点。计算公式为:

$$F_1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (18)$$

3.3 学习率影响分析

在训练 LDSN 模型时,设置了不同的初始学习率进行了多组对比试验,如图 5 所示。当学习率设置为 0.001 时,模型训练过程平稳,损失函数值持续下降,最终收敛到较低水平。这表明 0.001 的学习率对模型收敛性良好。当将学习率调高 10 倍到 0.01 时,模型在训练早期收敛速度更快,但后期出现较大波动,损失函数反复上升下降,并难以继续下降。这说明 0.01 的学习率太高,导致训练不稳定。此外还测试了 0.000 1 的学习率,此时模型收敛非常缓慢,需要更多的迭代才能达到相近的损失水平。综合分析,0.001 的学习率使 LDSN 模型训练收敛性最好,既保证了训练速度,也避免了过大的波动。所以选择 0.001 作为 LDSN 模型的最终学习率,以获得稳定和高效的模型收敛。




图5 不同学习率的对比

3.4 病害识别性能对比

由表 3 可知,本研究模型在番茄叶片病害识别任务上取得了最高的准确率,为 0.968,精确率为 0.964,召回率为 0.952 和 F_1 分数为 0.954。同时模型参数量仅为 0.6 M,比其他模型都要小,表现出良好的轻量化特性。AlexNet、VGG16、VGG19 由于网络结构简单,参数量大,准确率和效率较低。ResNet 通过残差结构提高了识别效果。DenseNet 使用密集连接也取得了较好的 0.94 以上准确率,但参数量也较多。ShuffleNet v2 通过 ShuffleUnit 结构实现轻量化,准确率达到 0.941,参数量只有 1.3 M。GhostNet 使用廉价操作的 Ghost module 获得较高的计算效率。本研究提出的 LDSN 网络,通过 CASF 模块提取多尺度特征,并使用局部聚合连接提高网络表示能力,使准确率和精确率达到最佳平衡。所以在番茄叶片病害识别任务上,获得了最优的整体识别效果。

表 3 不同模型的性能对比

模型架构	准确率	精确率	召回率	F_1 分数	模型参数 (M)
AlexNet	0.862	0.882	0.869	0.872	57.2
VGG16	0.891	0.893	0.871	0.885	134.3
VGG19	0.915	0.924	0.912	0.927	139.6
ResNet50	0.903	0.931	0.921	0.924	23.5
DenseNet121	0.942	0.945	0.948	0.950	7.0
GoogleNet	0.936	0.951	0.942	0.944	6.2
MobileNet	0.928	0.936	0.934	0.938	3.2
ShuffleNet v2	0.941	0.919	0.938	0.937	1.3
GhostNet	0.896	0.903	0.894	0.893	3.9
本研究模型	0.968	0.964	0.952	0.954	0.6

为验证本研究模型真实环境的优越性和鲁棒性,采用在真实场景拍摄 100 张具有不同的角度、背景和遮挡等条件的番茄病害图像作为测试,包含上述 3 种病害,部分图例如图 6 所示。从表 4 可以看出,本研究模型在真实环境数据集上的表现优于其他模型,不仅在准确率、精确率、召回率和 F_1 分数上都达到了最高,而且在模型参数量和推理时间上都达到了最低,说明本研究模型具有高效、轻量、鲁棒的特点,适合在真实环境下的番茄叶片病害图像识别应用。



表 4 不同模型在真实环境下的性能对比

模型架构	准确率	精确率	召回率	F_1 分数	模型参数 (M)	推理时间 (s)
AlexNet	0.792	0.801	0.789	0.794	57.2	12.3
VGG16	0.824	0.831	0.821	0.826	134.3	23.7
VGG19	0.836	0.842	0.834	0.838	139.6	25.4
ResNet50	0.852	0.861	0.851	0.856	23.5	14.6
DenseNet121	0.876	0.881	0.875	0.878	7.0	16.2
GoogleNet	0.864	0.869	0.863	0.866	6.2	13.8
MobileNet	0.848	0.853	0.847	0.850	3.2	9.4
ShuffleNet v2	0.832	0.837	0.831	0.834	1.3	7.1
GhostNet	0.812	0.818	0.811	0.814	3.9	8.9
本研究模型	0.904	0.908	0.903	0.906	0.6	6.7

为验证模块有效性,进行了一系列消融试验。由表 5 可知,在基准模型中加入 CASF 模块后,准确率从 0.825 提升至 0.862,精确率从 0.827 提升至 0.864,召回率从 0.824 提升至 0.861, F_1 分数从 0.826 提升至 0.859。为验证多尺度卷积的作用,使用不同尺寸的卷积核替换基准模型中的卷积模块。结果表明,使用 5×5 卷积核时,模型性能最佳,准确率达到 0.837。为了比较连接方式的影响,将 CASF 连接方式与直接特征拼接进行对比。CASF 连接方

式的准确率达到 0.862,优于直接拼接的 0.841。最后,为了验证 CASF 模块的鲁棒性,在复杂背景的番茄叶片图像数据集上评估模型准确率。结果表明,CASF 模块在复杂背景下的准确率达到 0.862,优于原模型的 0.815。综上所述,消融试验结果充分证明了 CASF 模块的有效性和鲁棒性。

3.5 效果测试

为模拟模型在真实环境下的效果,选取背景干扰、尺度变化的番茄病害图片测试,图 7 显示了对每

表 5 消融试验

试验内容	对比方法	准确率	精确率	召回率	F_1 分数
CASF 模块效果	基准模型	0.825	0.827	0.824	0.826
	基准模型 + CASF	0.862	0.864	0.861	0.859
多尺度卷积作用	3 × 3 卷积核	0.801	0.803	0.799	0.809
	5 × 5 卷积核	0.837	0.839	0.836	0.843
	7 × 7 卷积核	0.823	0.825	0.822	0.827
连接方式比较	直接拼接	0.841	0.843	0.845	0.839
	CASF 连接	0.862	0.864	0.861	0.856
CASF 鲁棒性	原模型复杂背景准确率	0.815	0.812	0.809	0.811
	CASF 复杂背景准确率	0.862	0.864	0.861	0.861




图7 病害识别可视化

一类番茄病害区域可视化的结果。本研究模型能够清楚地在感兴趣区域提取出番茄叶片的异常信息,如细菌性斑疹病和早疫病等病害区域被模型高亮显示,说明模型能够准确定位不同类型病害的特征区域。不同类型的病害区域具有不同的视觉特征,本研究模型能够捕捉到这些差异,从提取的感兴趣区域中可以清楚地区分出各类病害。这表明本研究模型学习到了有效的特征表达以辨别不同病

害。在健康番茄叶片的可视化结果中,没有高亮显示异常区域,这表明本研究模型具有判断正常样本的能力,可以减少对健康区域的误报。各类病害可视化结果呈现出类别内的视觉一致性,表明模型不仅可以区分不同病害类别,还可以推广到该类别内的各种情况。可视化分析直观展示了模型对病害区域的关注能力,有利于分析模型的识别策略、评估其有效性。不同叶片上的可视化结果表明,本研

究模型可以推广到各种形状、大小和方位的番茄叶片,而不会过度依赖某些特征。

4 讨论与结论

本研究提出了一种 LDSN 网络用于番茄叶片病害图像识别,提升了现有方法准确性,主要结论如下:(1)设计不同扩张率卷积的密集连接,增强了对不同尺度病害的感知能力,有效地适应了番茄叶片病害的尺度变化;(2)提出 CASF 方法,提高了对复杂背景下病害特征的表达能力,有效地降低了背景干扰对病害识别的影响;(3)优化网络结构和参数,降低了模型的计算量和存储空间,实现了模型的轻量化,适用于低成本的设备上运行;(4)LDSN 在番茄叶片病害识别任务上取得了优异的性能,不仅在准确率上超过了现有的重量级网络和轻量级网络,而且在速度上也具有明显的优势,为农业智能化领域提供了一种新的思路和方法。

LDSN 虽然在番茄叶片病害图像识别方面取得了较好的效果,但仍有以下几个方面可以进一步改进和完善:(1)使用的数据集是 1 个人工构建的数据集,不是真实环境下的数据集,可能存在一定的偏差和局限性,未来可以考虑使用更多的真实场景下的数据集,以提高模型的泛化能力和鲁棒性。(2)只考虑了番茄叶片的病害识别,没有涉及到番茄叶片的病斑检测和定位,未来可以考虑将本研究方法扩展到病斑检测和定位的任务中,以实现更细粒度的番茄叶片病害分析和诊断。(3)本研究只针对番茄叶片的病害进行了识别,没有考虑其他农作物的病害识别,未来可以考虑将本研究方法应用到其他农作物的病害识别中,以实现更广泛的农业智能化应用。

参考文献:

- [1] Quinet M, Angosto T, Yuste - Lisbona F J, et al. Tomato fruit development and metabolism[J]. *Frontiers in Plant Science*, 2019, 10:1554.
- [2] Bergounoux V. The history of tomato: from domestication to biopharming[J]. *Biotechnology Advances*, 2014, 32(1): 170 - 189.
- [3] 翟肇裕,曹益飞,徐焕良,等. 农作物病虫害识别关键技术研究综述[J]. *农业机械学报*, 2021, 52(7): 1 - 18.
- [4] Collins E J, Bowyer C, Tsouza A, et al. Tomatoes: an extensive review of the associated health impacts of tomatoes and factors that can affect their cultivation[J]. *Biology*, 2022, 11(2): 239.
- [5] Agarwal M, Singh A, Arjaria S, et al. ToLeD: tomato leaf disease detection using convolution neural network[J]. *Procedia Computer Science*, 2020, 167: 293 - 301.
- [6] 蒋清健,姚 勇,付志军,等. 基于改进卷积神经网络算法的番茄叶片病害识别[J]. *江苏农业科学*, 2022, 50(20): 29 - 34.
- [7] 牛学德,高丙朋,南新元,等. 基于改进 DenseNet 卷积神经网络的番茄叶片病害检测[J]. *江苏农业学报*, 2022, 38(1): 129 - 134.
- [8] Thangaraj R, Anandamurugan S, Pandiyan P, et al. Artificial intelligence in tomato leaf disease detection: a comprehensive review and discussion[J]. *Journal of Plant Diseases and Protection*, 2022, 129(3): 469 - 488.
- [9] 郑超杰,李少波,蒲睿强,等. 基于轻量化卷积神经网络的番茄叶片病害识别[J]. *江苏农业科学*, 2024, 52(11): 225 - 231.
- [10] 陈智超,汪国强,李 飞,等. 基于 Bi - LSTM 与多尺度神经网络模型的番茄病害识别[J]. *江苏农业科学*, 2023, 51(15): 194 - 203.
- [11] 马 丽,周巧黎,赵丽亚,等. 基于深度学习的番茄叶片病害分类识别研究[J]. *中国农机化学报*, 2023, 44(7): 187 - 193, 206.
- [12] 王志强,于雪莹,杨晓婧,等. 基于 WGAN 和 MCA - MobileNet 的番茄叶片病害识别[J]. *农业机械学报*, 2023, 54(5): 244 - 252.
- [13] Basavaiah J, Arlene Anthony A. Tomato leaf disease classification using multiple feature extraction techniques[J]. *Wireless Personal Communications*, 2020, 115(1): 633 - 651.
- [14] Tian X L, Meng X Y, Wu Q F, et al. Identification of tomato leaf diseases based on a deep neuro - fuzzy network[J]. *Journal of the Institution of Engineers*, 2022, 103(2): 695 - 706.
- [15] 张天骐,熊 天,吴 超,等. 基于压缩激励残差分组扩张卷积和密集线性门控 Unet 歌声分离方法[J]. *应用科学学报*, 2023, 41(5): 815 - 830.
- [16] 涂 万,于 红,张 鹏,等. 基于通道非降维与空间协调注意力的改进 YOLOv8 养殖鱼群检测[J]. *大连海洋大学学报*, 2023, 38(4): 717 - 725.
- [17] 项小东,翟 蔚,黄言志,等. 基于 Xception - CEMs 神经网络的植物病害识别[J]. *中国农机化学报*, 2021, 42(8): 177 - 186.
- [18] 李书琴,陈 聪,朱 彤,等. 基于轻量级残差网络的植物叶片病害识别[J]. *农业机械学报*, 2022, 53(3): 243 - 250.
- [19] 储 鑫,李 祥,罗 斌,等. 基于改进 YOLOv4 算法的番茄叶部病害识别方法[J]. *江苏农业学报*, 2023, 39(5): 1199 - 1208.
- [20] 章广传,李 彤,何 云,等. 基于迁移模型集成的马铃薯叶片病害识别方法[J]. *江苏农业科学*, 2023, 51(15): 216 - 224.
- [21] 惠巧娟,孙 婕. 基于多尺度特征度量元学习的玉米叶片病害识别模型研究[J]. *江苏农业科学*, 2023, 51(9): 199 - 206.
- [22] 陈 聪,于 啸,宫 琪. 基于改进残差网络的苹果叶片病害识别研究[J]. *河南农业科学*, 2023, 52(4): 152 - 161.