

多尺度 U 网络实现番茄叶部病斑分割与识别

顾兴健 朱剑峰 任守纲 熊迎军 徐焕良

南京农业大学人工智能学院 南京 210095

(guxingjian@njau.edu.cn)

摘要 随着深度学习技术的迅速发展,卷积神经网络成为研究植物叶部病害识别与病斑分割的主流方法。针对番茄叶部病斑大小不一、形状不规则、病斑分割需要大量像素级标记等问题,文中提出一种多尺度 U 网络,以同时实现番茄叶部病斑分割与病害识别。在病害特征提取阶段采用多尺度残差模块组合不同尺寸的感受野来提取病害特征,以适应病斑大小和形状的动态变化。引入 CB 模块(Classifier and Bridge)将病害特征提取阶段与病斑分割阶段连接,对病害特征进行分类,并根据分类结果反向映射出特定类的激活图,此激活图包含特定类别病斑的关键信息。在分割阶段采用上采样与卷积相结合的方法对特定类的激活图进行反卷积,利用跳跃连接方式将反卷积特征与低层特征融合,以补充更多的图像细节信息,获取病斑分割的灰度图。为了使分割的病斑定位更加精确,利用少量像素级标记,对每个像素点采用二分类交叉熵损失函数进行监督训练,同时更好地引导特征提取网络关注病斑部位。利用原始测试集与模拟噪声和光照强度的干扰测试集分别验证模型的病斑分割与病害分类性能。在原始测试样本集上多尺度 U 网络的平均像素准确率、平均交并比和频权交并比分别达到了 86.15%、75.25% 和 90.27%;在降低 30% 亮度和添加椒盐噪声的干扰测试集上,模型的识别准确率分别为 95.10% 和 99.20%。实验结果表明,所提方法可以实现番茄叶部病斑分割与识别效果的同时提升。

关键词: 多尺度; 叶部病害; 图像分割; 图像识别; 卷积神经网络

中图法分类号 TP391

Multi-scale U Network Realizes Segmentation and Recognition of Tomato Leaf Disease

GU Xing-jian, ZHU Jian-feng, REN Shou-gang, XIONG Ying-jun and XU Huan-liang

School of Artificial Intelligence, Nanjing Agricultural University, Nanjing 210095, China

Abstract With the development of deep learning technology, convolutional neural network has been the mainstream method for plant leaf disease recognition and disease spot segmentation. Aiming at the problems of different sizes and irregular shapes of tomato leaf lesions, need for a large number of pixel-level labels, a novel multi-scale U network is proposed, which realizes tomato leaf lesion segmentation and disease recognition simultaneously. For disease feature extraction, a multi-scale residual module including different sizes of receptive fields is used to extract disease features according to the different disease spot size and shape. The CB module (Classifier and Bridge) is introduced to connect the disease feature extraction stage with the lesion segmentation stage, which classifies the disease and also reversely generates an activation map of specific class according to the classification result. This activation map contains the specific type of lesions label information. In the segmentation stage, upsampling and convolution are used to deconvolve the activation map. The deconvolution feature and the low-level feature are merged by the jump connection method. In order to make lesion location segmentation more accurate, a few of pixel-level labels are used for training to minimize two-class cross-entropy loss. In the experiment, the original samples and samples with simulated noise and light intensity are used to verify the performance of disease spot segmentation and disease recognition of our method. On the original sample set, the average pixel accuracy, average intersection ratio, and frequency weight intersection ratio of our method reaches 86.15%, 75.25%, and 90.27%, respectively. In the interference sample with 30% brightness reduction, salt and pepper noise, the recognition accuracy of our method obtains 95.10% and 99.20% respectively. Experimental results show that the proposed method can achieve improvement in segmentation and recognition of tomato leaf lesions simultaneously.

Keywords Multiscale, Leaf diseases, Image segmentation, Image recognition, Convolutional neural network

1 引言

农作物病害是导致农产品产量下降的主要原因之一。及时有效地分析农作物的病斑特征,有助于迅速判断作物的病害类型和程度,能够提供相应的病害防治指导建议,从而减小经

济损失^[1]。传统的病害诊断模型主要依赖人工设计特征提取,缺乏时效性且工作量较大^[2-13],而目前深度学习可利用卷积核自动提取图像特征,为农作物病害识别提供新的解决方案。

自 AlexNet^[4] 卷积神经网络模型提出以来,卷积神经网络成为研究图像分类的主流方法。研究人员将 CNN(Convolutional Neural Network)

基金项目:国家自然科学基金(61806097)

This work was supported by the National Natural Science Foundation of China(61806097).

通信作者:任守纲(rengs@njau.edu.cn)

lutional Neural Network)应用到农作物病害识别领域,利用 PlantVillage 植物叶部病害图像数据集及其他包含植物叶部病害种类的数据集,分别训练基于 AlexNet, GoogleNet, LeNet, CaffeNet, VGG 等^[5-10]卷积神经网络模型,训练后的模型表现出了较高水平的识别性能。然而,植物叶部病斑尺度不一,不同时期的病害样本图像中病斑的大小不同,使用固定感受野的卷积结构难以提取病斑的全局和局部特征。

相关研究^[11-13]通过学习多尺度病害特征来提升农作物病害的识别性能。Sun 等^[11]设置多种尺寸的初始卷积核和全局池化层用于改进 AlexNet 模型,识别 14 种不同植物的 26 类病害,相比 AlexNet 模型识别精度有所提升。Guo 等^[12]设计了基于 AlexNet 的多感受野识别模型,使用不同尺寸的卷积核综合提取多种特征,能够适应番茄叶片病害的动态变化。Xiao 等^[13]对网络的前几层卷积结构同时使用 3×3 和 5×5 两种卷积核,在 10 类牧草图像中的识别准确率比 VGG-13 网络提高了 5.7%。相比传统网络层采用的固定的特征提取模式,以上模型改变同一特征层的感受野使得病害特征的提取更加全面,模型性能得到提高。然而,与手工设计特征相比,卷积核提取特征具有盲目性和不确定性,若模型过拟合则会响应到错误的背景像素、阴影等区域,影响模型的识别结果。

Yu 等^[14]针对复杂背景中非病斑区域的响应问题,设计了两个子网络,首先训练分割子网分割出背景、叶片和病斑区域,然后将分割的灰度图与原图送入分类子网中训练,有效避免了模型对背景和叶片正常区域的错误响应,提高了识别性能。Wei 等^[15]采用先定位虫害区域再识别病害种类的农业害虫自动检测方法,有效地避免了复杂背景对害虫识别精度的干扰,提升了害虫类别判断的准确度。Brahimi 等^[16]首先提取植物叶片,去除背景干扰,在无需使用病斑的像素级标注的情况下,利用反卷积可视化病斑部位提升模型的性能,然而模型在有背景信息的图像中效果不好。以上方法均利用病害部位引导识别模型关注真实病害特征,增强了卷积核提取特征的确定性,提升了模型的识别精度。因此,在植物叶部病害图像识别过程中,病斑区域的精准分割是影响模型识别精度的关键。

自 FCN^[17]、U-Net^[18]等全卷积神经网络模型提出以来,基于深度学习的语义分割方法取得了一定的进展^[19-20],研究人员尝试将改进后的全卷积神经网络模型应用于植物叶部病害图像的自动分割。Zhao 等^[21]对葡萄病害叶片进行分割,采用卷积、池化等操作提取输入病害图像的特征,利用跳跃连接操作融合多种特征,采用反卷积操作恢复图像分辨率,取得了较好的分割效果。Wang 等^[22]对传统 FCN 进行改进,提出的黄瓜叶部病斑图像分割方法,有效避免了病斑分割过程中易受光照和背景影响等问题。以上基于植物叶部病害的语义分割方法获得了较好的分割效果,然而模型在训练过程中需要大量的病斑标记,标记数据的减少会影响模型的分割性能。

综上所述,基于植物叶部病害识别与病斑分割的研究过程中仍存在以下挑战:1)植物叶部病斑形状不规则且具有多变性,采用固定尺寸的卷积核提取病害特征,难以适应病斑形状的动态变化;2)卷积核提取植物叶片病害特征具有盲目性和不确定性,病斑部位的错误响应会导致模型识别率下降;3)现有的基于植物病斑的语义分割方法通常需要大量的病斑标注数据作为监督信息,而植物叶部病斑分布散乱且数目较多,病斑标注数据的获取存在一定的困难。

本文针对植物叶部病害识别与病斑分割的难点,以番茄叶部病害图像为研究对象,设计多尺度 U 网络,以少量的像素级标注代价实现植物叶部病斑分割与识别一体化。采用多尺度残差块构建多尺度特征提取网络,提取番茄叶部病斑的全局信息和局部信息,挖掘更高级的语义特征,以适应番茄叶部病斑的尺寸和形状变化;利用 CB 模块获取特定病害类别的激活图,得到大量无病斑标注样本的关键信息,将其输入到分割网络,即使采用少量病斑像素级标注数据训练,也可获得较好的病斑分割效果;利用反卷积模块引导特征提取网络关注病斑的真实部位,以提升网络的识别性能。本文模型可以提升番茄叶部病害识别性能与病斑分割效果,且对噪声和光照强度具有较好的鲁棒性。

2 材料与方法

2.1 实验数据与处理

2.1.1 数据来源

实验数据取自 PlantVillage 公开数据集中的 10 类番茄叶部病害图像,共 18160 张。其中包括细菌性斑点病 2127 张、晚疫病 1909 张、斑枯病 1771 张、二斑叶螨病 1676 张、轮斑病 1404 张、早疫病 1000 张、叶霉病 952 张、花叶病 373 张、黄曲叶病 5357 张,共 9 种番茄叶部病害图像和 1 种健康叶片图像。图像分辨率大小为 256×256 像素,每张图像只包含一张叶片,每张叶片只有一种病斑,且图像均具有病害类别标注。

因为每张图像只存在一种病害,所以病斑标注时只需区分病斑像素和背景像素,不需要考虑病害的类别。健康叶片不需要病斑标注,因此从 9 类病害样本中每类选取 30 张进行像素级标注,其中 5 张用于训练分割模型,25 张用于评估模型的分割精度。图 1 给出了采用图像语义分割标注工具 LabelMe^[23]对病斑进行像素级标注的示例,其中白色部位为病斑,黑色部位为背景。




图 1 叶部病斑的像素级标注

Fig. 1 Pixel-level annotation of leaf disease

2.1.2 数据增强

获取的番茄叶片病害数据集中,病害样本分布极不均匀,花叶病和叶霉病的病害图像数量相对较少。为了避免样本过少导致模型过拟合,在 PyTorch 框架下采用在线数据增强方法对训练数据进行扩充,即在训练时对获得的每个批次的数据进行数据增强,不改变原始训练集的图像张数。采用的数据增强手段有随机翻转、添加高斯噪声和椒盐噪声、对图像添加模糊操作,以此来模拟自然条件和拍摄过程中的状况,提高模型的泛化能力。

2.2 模型设计

设计一种多尺度 U 网络,以同时实现番茄叶部病害识别与病斑分割,如图 2 所示,包括 3 个模块:多尺度特征提取模块(Multiscale Feature Encoder model)、分类与桥接(Classifier and Bridge, CB)模块和反卷积模块(Deconvolution Model),每

个子模块都详细展示了输入和输出特征图的宽度、高度和通道数目。

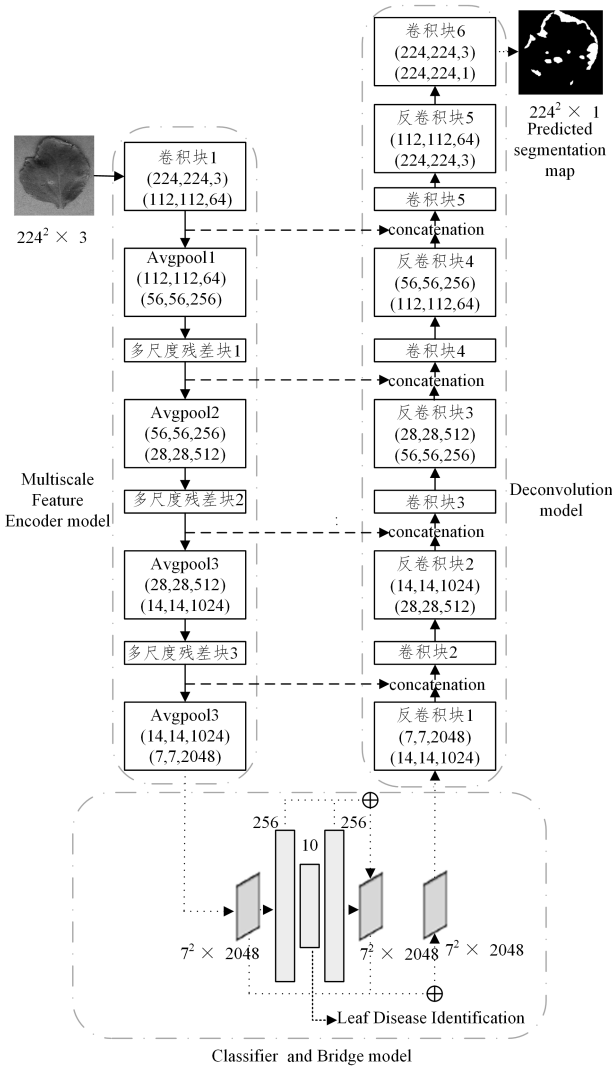


图2 模型架构

Fig. 2 Architecture of model

2.2.1 多尺度特征提取模块

多尺度操作可以综合利用多个感受野范围来提取同一像素点的特征信息,采用局部感受野可以获取某一像素点邻域像素的细节信息,增大感受野范围可以获得与更多像素的空间关系。因此,综合不同感受野可以实现图像的多尺度特征提取,提高特征对图像的表达能。

研究番茄叶部病害时,需要考虑以下问题。1)番茄叶部病斑大小不一。图3和图4分别是番茄细菌性斑点病、晚疫病、斑枯病、二斑叶螨病、轮斑病、早疫病、叶霉病早晚期发病图和健康叶片图像。发病早期,病斑微小,与健康叶片差别不大,难以捕捉图像细节信息;随着病情持续,病斑轮廓逐渐扩散,获取病害特征需要更多的空间信息。2)病斑形状复杂且具有动态变化性。由图3和图4可以看出,早疫病初期为近圆形小斑,严重时叶片干枯呈蜷缩状;叶霉病初期为水浸状、边缘不明显的小斑点,逐渐扩散连接成不规则形状,采用固定尺寸的卷积核难以表征病斑形状的动态变化。3)病斑与叶片健康部位的特征存在较大的相似性。图5为花叶病和黄曲叶病的图像,病叶呈黄绿相间,病斑轮廓不清晰,边界处的病斑像素与健康像素难以区分。

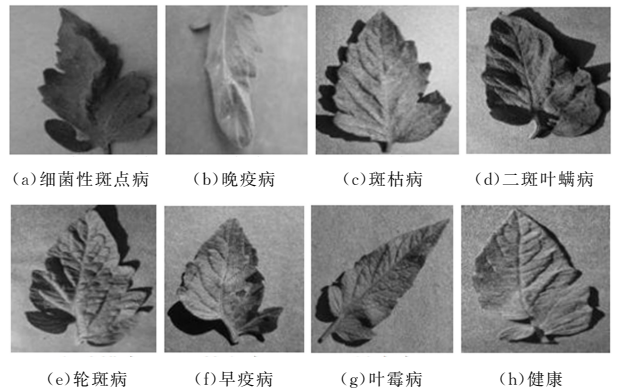


图3 番茄叶部病害早期发病图像

Fig. 3 Early onset images of tomato leaf diseases




图4 番茄叶部病害晚期发病图像

Fig. 4 Late onset images of tomato leaf diseases




图5 花叶病和黄曲叶病图像

Fig. 5 Mosaic and yellow leaf curl images

综上,识别番茄叶部病害需要综合病害图像的全局和局部信息,挖掘更深层次的病害抽象特征。因此,本文保留ResNet-50^[24]模型特征提取网络的结构设计,将其作为多尺度特征提取网络的基本骨架。ResNet-50网络包括一个卷积核尺寸为 7×7 的卷积层(步长为2, padding为3,即图2中的卷积块1)、4个Res-Net残差块和5个池化层,每层卷积采用批归一化和线性整流函数ReLU。本文将Res-Net残差块替换为多尺度残差块,以增加网络层深度和宽度的方式进一步提升模型的特征提取性能。

图6给出了多尺度残差块的结构,输入的特征图经过 1×1 卷积层得到特征图 x ,将它按通道数平均分成 s 份,得到特征子图 $x_i (i=1, 2, 3, \dots, s)$,其中 s 的值设置为4。与输入特征图相比,特征子图 x_i 拥有相同的分辨率和 $1/4$ 个通道数。其中,除 x_1 外,其余特征子图均对应着 3×3 的卷积运算 k_i, y_i 是 k_i 对应的输出。 x_i 与经过 k_{i-1} 运算得到的特征子图相加之后,将结果输入到 k_i 中。为了弥补卷积运算过程中丢失的信息,不进行 3×3 卷积操作,直接输出 y_i 。因此, y_i 的计算式为:

$$y_i = \begin{cases} x_i, & i=1 \\ k_i(x_i), & i=1 \\ k_i(x_i + y_{i-1}), & 2 \leq i \leq s \end{cases} \quad (1)$$

其中,每个 3×3 的卷积运算 k_i 都可能直接接收特征子图 x_j ($j \leq i$);每经过 k_i 运算,特征子图的感受野都有增加的可能性。最后使用 1×1 的卷积层将特征子图的输出合并为同一个张量继续向下传递。这种类残差式的多卷积组合结构使得同一特征层可以自由组合不同尺寸的感受野,以适应番茄叶部病害的动态变化。




图6 多尺度残差块

Fig. 6 Multi-scale residual block

2.2.2 CB 模块

病害识别网络中,全连接层输出的特征向量包含特定类别病害的关键信息,将它重塑成二维特征图可以得到特定类的激活图,经过上采样即可获得病斑响应区域,从而减小图像分割训练时对像素级标注样本的依赖。因此,本文设计了CB(Classifier and Bridge)模块,其包括两个阶段:分类(classifier)和桥接(bridge)。在分类阶段,根据病害种类设计输出神经元个数分别为 256 和 10 的全连接层,将特征提取网络最后一个池化层输出的特征图送入全连接层进行计算,得到 10 个神经元,输入到 SoftMax 分类器。为了获取特定类别病害的关键特征,训练时输入病害类别标注样本到分类器,计算分类损失。

在桥接阶段,分别采用输出神经元个数为 256 和 100, 352 的反向全连接层将 10 维向量重塑成特征图。为防止特征丢失,使用向量加法操作将反向全连接层前后的特征向量和特征图对应相加,完成特征融合,得到特定类的激活图,此激活图包含特定类别病害的关键特征。

图 7 给出了黄曲叶病的病害图像和经过 CB 模块计算得到的特定类的激活图,尽管外观差异很大,但同一类别的病害图像具有相似的激活模式,这表明 CB 模块可以有效地捕获特定类别病害的关键特征。将它送入分割网络中,即使采用少量病斑标注训练数据,也可以实现良好的分割泛化性能。




图7 病害叶片和特定类的激活图

Fig. 7 Activation diagram of diseased leaves and specific classes

2.2.3 反卷积模块

反卷积模块将 CB 模块获取的特定类的激活图作为输入,不断上采样至输入图像大小,同时将多尺度特征提取模块中对应大小的特征图与反卷积后的特征图进行向量拼接,实现多种特征的融合。如图 2 所示,反卷积模块由反卷积块 1-4 和卷积块 2 构成。每个反卷积块的具体结构如表 1 所列, X, Y 为特征图长度和宽度, Z 和 Z_1 为通道数。在反卷积块 1 中卷积层 1 不改变通道数,即 $Z_1 = Z$,在反卷积块 2-4 中卷积层 1 将通道数减少一半,即 $Z_1 = Z/2$ 。反卷积块包括上采样和卷积操作,采用最近邻插值法将特征图进行 2 倍上采样,之后采用 3×3 卷积平滑图像边缘;为避免跳跃连接后的数据通道数过多影响下一个反卷积块的输入,在拼接操作之后采用 3×3 卷积以减小数据维度。

经过不断的反卷积操作得到 $112 \times 112 \times 64$ 大小的特征图,将其输入到如图 2 所示的卷积块 2 中,将其上采样至原图大小,并采用 3×3 的卷积操作压缩至 3 通道,以便初步筛选病害特征。最后将筛选后的特征图通道数减少至 1,并采用 Sigmoid 函数将特征映射到 $(0, 1)$ 之间,设置阈值为 0.5、灰度值大于 0.5 的像素为病斑像素。

表1 反卷积块的结构

Table 1 Structure of deconvolution block

网络层	input size	output size
上采样	(X, Y, Z)	$(2X, 2Y, Z)$
卷积层 1	$(2X, 2Y, Z)$	$(2X, 2Y, Z_1)$
跳跃连接	$(2X, 2Y, Z_1) + (2X, 2Y, Z_1)$	$(2X, 2Y, 2Z_1)$
卷积层 2	$(2X, 2Y, 2Z_1)$	$(2X, 2Y, Z_1)$

2.3 模型损失函数

与其他语义分割网络不同,所设计的多尺度 U 网络可以同时实现病害识别和病斑分割。识别模型的优化会提升反卷积模块的分割精度;反卷积模块的优化也会引导多尺度特征提取模块关注病斑真实位置,提升识别性能。因此,本文设计交叉熵损失函数来共同优化分类和分割损失。

2.3.1 分类损失函数

模型经过 CB 模块中的分类器可预测病害的类别,选用多分类交叉熵损失函数计算类别预测损失 L_{cls} ,如式(2)所示:

$$L_{cls} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C t_j^i \log(y_j^i) \quad (2)$$

其中, i 为训练样本, j 为训练样本的病害类别。 y_j^i 表示第 i 个训练样本预测为第 j 个类别的概率值; t_j^i 表示第 i 个训练样本标注的真实病害类别; c 为病害类别总数,设置为 10; N 为训练样本总数。

2.3.2 分割损失函数

模型经过反卷积模块的分类器可输出预测的病斑二值分割图。通过计算预测的病斑分割图像与像素级标注图像的交叉熵值,可以评定分割模型的训练效果,交叉熵值越小,模型的训练效果越好。选用二分类交叉熵损失函数对分割图中的每个像素点计算损失 L_{seg} 。损失函数如下:

$$L_{seg} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^P [t_j^i \log(y_j^i) + (1-t_j^i) \log(1-y_j^i)] \quad (3)$$

其中, N 为训练样本个数; P 为分割图中的像素点总数; i 是

训练样本; j 代表分割图中第 j 个像素点; y_j^i 为第 i 个训练样本经过反卷积模块输出的二值图中第 j 个像素的预测值, y_j^i 为 0 表示背景像素, y_j^i 为 1 表示病斑像素; t_j^i 为第 i 个训练样本中第 j 个像素的真实值。

2.3.3 模型损失函数

与语义分割网络不同, 本文分别计算分类与分割损失, 模型的训练需要共同优化分类损失和分割损失, 损失函数如下:

$$L = k * L_{cls} + (1 - k) * L_{seg} \quad (4)$$

其中, L_{cls} 为第一个分类器输出的病害类别分类损失, L_{seg} 为第二个分类器输出的病斑分割损失。在训练有病斑标注的样本时, 模型更加关注病斑像素的位置信息, k 的值为 0.3; 在训练无病斑标注的样本时, 模型只关注图像类别信息, k 的值为 1。

2.4 模型训练

2.4.1 实验环境

实验软件环境为 Ubuntu 16.04 LTS, 使用 pycharm 编程。硬件环境为 Intel(R) Xeon(R) CPU E5-2620 v4 @ 2.10 GHz 处理器, 运行内存为 32 GB, 使用 NVIDIA 1080 Ti GPU 加速。深度学习框架为 Python3.7 和 Pytorch1.0。

2.4.2 参数设置

采用 ImageNet 预训练的参数对多尺度特征提取网络进行参数初始化, 其他模块使用 Kaiming 初始化^[25], 以此加快模型的收敛速度。实验过程中采用批量训练方式, 训练集包含 5430 幅图像, 每 8 幅图像为一个批次, 完成一个遍历共需要 679 个批次。遍历 (Epoch) 次数为 99, 迭代次数设置为 67221 次。采用 Adam^[26] 优化器, 模型初始学习率为 5×10^{-4} , 为了避免发生过拟合现象, 设置动量因子为 0.9, 权值衰减为 2×10^{-4} 。

2.4.3 训练过程

训练集包括病害类别标注和病斑标注两种类型的样本。训练第一个分类器时, 使用 5430 张病害类别标注图像做训练集, 使用 12730 张病害图像作为测试集。训练第二个分类器时, 使用 45 张病斑标注图像做训练集, 将剩余的 225 张做测试集。模型训练时, 使用式(4)对 45 张图像训练一轮后, 训练 50 批病害类别标注的样本, 再使用病斑标注的训练集训练一次, 如此交替迭代训练, 直到病害类别标注的训练样本全部训练结束即完成一个 epoch 训练。使用少量病斑标注样本训练模型, 可以鼓励特征提取模块关注某一特定病害的真实位置, 减少模型对错误区域的响应, 提升模型的识别性能。

2.5 模型评价指标

采用语义分割的 4 个常用指标: 像素准确率 (Pixel Accu-

racy, PA)、平均像素准确率 (Mean Pixel Accuracy, MPA)、平均交并比 (Mean Intersection over Union, MIOU) 和频权交并比 (Frequency Weighted Intersection over Union, FWIOU) 来衡量实际分割结果与人工标注的差异。

(1) 像素分类准确值, 是分类正确像素占总体像素的比例, 计算式如下:

$$R_{PA} = \frac{\sum_{i=0}^k p_{ii}}{\sum_{i=0}^k \sum_{j=0}^k p_{ij}} \quad (5)$$

其中, 包含背景共有 $k+1$ 类分割目标, 本文 k 值为 1, 即只有背景和病斑两类标签; i 和 j 表示像素类别; p_{ii} 和 p_{ij} 分别表示不同正类和反类的数量, p_{ii} 表示原本属于第 i 类的分割目标被正确分割为第 i 类的像素数目, p_{ij} 表示原本属于第 j 类的分割目标被错误分为第 i 类的像素数目。

(2) 平均像素分类准确值。首先计算每种类别分类正确像素的比例, 然后除以类别取平均值, 计算式如下:

$$R_{MPA} = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij}} \quad (6)$$

(3) 平均交并比。首先计算每种类别图像分割的真实值与预测值的交集与并集的重叠比例, 然后除以类别求平均值, 计算式如下:

$$R_{MIOU} = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (7)$$

其中, p_{ji} 表示类别为 j 的像素被预测为类别 i 的数量。

(4) 频权交并比。对每个分割类别按照它出现的频率进行加权计算, 计算式如下:

$$R_{FWIOU} = \frac{1}{\sum_{i=0}^k \sum_{j=0}^k p_{ij}} \sum_{i=0}^k \frac{\sum_{j=0}^k p_{ij} p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (8)$$

3 结果与分析

3.1 病斑分割结果分析

采用 45 张番茄叶片病斑标注样本训练模型, 将剩下的 225 张测试模型的分割性能, 病斑标注数据只区分病斑像素与背景像素, 不考虑病害类别, 实验结果取 225 张图像测试结果的平均值。采用消融实验依次验证残差块、多尺度残差块、CB 模块对分割模型的价值, 相应的验证模型分别为 U-Net, U-ResNet-50, U-Res2Net-50。采用 2.5 节叙述的 4 项评价指标、模型复杂度 GFLOPs 和单幅图像在 GPU 上的运行时间分别评估 FCN-8s, Attention U-Net, U-Net++, 多尺度 U 网络和 3 个验证模型对病斑区域的分割精度。表 2 和图 8 分别给出了不同分割方法在测试集上的分割性能和病斑分割效果。

表 2 不同分割方法在测试集上的分割性能

Table 2 Segmentation performance of different segmentation methods on the test set

Evaluation index	PA/%	MPA/%	MIOU/%	FWIOU/%	GFLOPs/M	Run time on GPU/ms
FCN-8s	92.65	81.51	71.11	87.45	62.79	22
U-Net	93.41	81.92	72.90	88.49	50.17	13
U-Net++	93.87	80.98	74.07	89.01	105.70	23
Attention U-Net	93.90	82.68	74.10	89.03	51.02	15
U-ResNet-50	93.66	82.75	73.78	88.88	31.05	23
U-Res2Net-50	93.64	83.48	74.02	88.91	31.22	24
Our Method	94.37	86.15	75.25	90.27	31.27	26




图 8 不同方法对测试数据的病斑分割效果

Fig. 8 Effect of different methods on the test data

FCN-8s 作为最经典的植物叶部病斑分割网络之一,在番茄叶部病害图像上计算得到的像素准确率为 92.65%,平均交并比达到 71.11%,分割预测的结果图中病斑分割不完整。这是因为 FCN-8s 只对特征提取网络的高层输出的特征图采用跳跃连接操作,忽略了低级语义特征。U-Net 在对低层特征采取跳跃连接操作之后,预测的病斑区域相对完整,且获取更多分割细节,分割评价也优于 FCN-8s,平均交并比提升了将近 1.8%。U-Net++ 方法的平均交并比达到 74.07%,然而存在分割缺失的现象。Attention U-Net 方法的分割精度较高,平均交并比达到 74.10%,然而无法获得清晰准确的病斑分割边缘。

本文提出的多尺度 U 网络模型的分割效果明显优于 FCN-8s, U-Net, Attention U-Net, U-Net++ 这 4 种深度学习分割算法,主要原因是多尺度残差模块和 CB 模块的引入。首先,利用残差块可以加深网络层数,挖掘到更加抽象的病害特征,使得病斑区域和背景区域更具判别性。其次,通过多尺度信息表征病斑大小和形状的动态变化,提高病害图像中病斑边缘的细化特征学习能力,进一步提升分割效果。最后,利用大量病害类别标注样本学习病斑区域的关键特征,经过 CB 模块获取特定病害类别的激活图,将它上采样之后预测的分割图可以再次减少模型对背景区域的响应。病斑分割效果图(见图 8)进一步体现了多尺度 U 网络模型的优势,与其他分割方法相比,本文算法能够相对完整地分割出病斑结构,有效地区分出病斑像素与背景像素,避免错误分割。

首先,与验证模型 U-ResNet-50 的病斑分割预测结果相比, U-Net++ 未能分割出完整的病斑,且存在明显的锯齿现象。相比之下, U-ResNet-50 不仅可以相对完整地分割出边缘平滑的真实病斑区域,而且属于背景的相似特征得到区分,如花叶病的分割图中的病斑,发病边缘的病斑像素与背景像素相似度较高,分割困难。U-ResNet-50 可以有效地判别病斑像素和背景像素,分割的边缘更加清晰平滑,而 U-Net++ 无法获得清晰准确的病斑分割边界。因此,尽管 U-ResNet-50 的平均交并比的值略低于 U-Net++,但是分割效果明显得到改善。这是因为平均交并比只追求最大化分割图像的真实值与预测值的交集与并集的重叠比例,并未精细化病斑分割边界,而 U-ResNet-50 引入 Res-Net 残差块可以获取更加高级的语义特征,增加背景和病斑区域的判别性,提高边缘像

素的区分度。当采用多尺度残差块代替 U-ResNet-50 中的 Res-Net 残差块时,平均像素准确率达到 83.48%,分割效果得到了进一步改善。与 U-ResNet-50 相比, U-Res2Net-50 能够更加完整地分割出病斑的形状,如早疫病的病斑分割图,引入多尺度残差块后,预测的病斑形状更加接近人工标注。相比之下, Attention U-Net 虽然减少了部分误分割现象,但是病斑分割边界不平滑且未能完整分割出不规则形状的病斑,主要原因是多尺度残差块利用不同大小的感受野将全局和局部信息融合,有效增强了网络对空间和细节信息的提取。最后,引入 CB 模块和少量病斑标注样本监督,增强网络对目标类别像素的特征学习和对病斑分割的敏感度,平均交并比提升达到 75.25%。如图 8 所示,多尺度 U 网络不仅可以完整地分割病斑,而且去掉了 U-Res2Net-50 中多余的非病斑像素,病斑像素与背景像素得到有效区分。且预测的病斑分割效果更加接近人工标注,进一步证明采用 CB 模块可以减小网络对像素级标注样本的依赖。

模型复杂度是评价算法性能的重要指标,采用 GFLOPs 衡量模型复杂度, GFLOPs 值越高,占用的计算资源越大,模型越复杂。由表 1 可知,本文的多尺度 U 网络模型的复杂度相对较低, GFLOPs 值为 31.27×10^6 。在同样的 GPU 上进行单幅图像运行时间的测试,多尺度 U 网络达到每张 26 ms,与其他模型相差不大,能够满足实时检测的要求。

3.2 病害识别结果分析

分别采用 ResNet-50、Res2Net-50^[27]、Sun 等^[11]以及 SE-ResNet50^[28]研究的识别算法与本文的多尺度 U 网络作识别性能对比。实验中保证参数设置相同,测试样本的数据增强方式相同。为了模拟实际拍摄过程中的误差以及自然条件下的光照强度变化,对 12730 张测试图像随机添加椒盐噪声并将降亮度低 30%。此操作可以模拟模型在实际应用中的识别率,从而检验多尺度 U 网络对噪声和光照强度的鲁棒性。

表 3 列出了各个模型在测试集和添加干扰的测试集上的识别准确率。其中, Sun 等^[11]研究的模型识别率最低,原因在于没有使用预训练的参数参与模型的训练,在训练样本相对较少的情况下,模型无法充分学习病害特征。而 ResNet-50 的识别率明显提升,如在降低 30%亮度的测试集上, ResNet-50 的识别率提升了近 7%。这主要是因为 ResNet-50 利用残差块增加网络深度,可以挖掘到隐含在干扰测试图像中

更加抽象的病害特征,模型的泛化能力增强,识别准确率提到提升。番茄病斑在发病过程中由小到大逐渐蔓延,由于 ResNet-50 和 SE_ResNet50^[28]采用拥有固定尺寸感受野的 ResNet 残差块,因此识别准确率低于采用多尺度残差块的 Res2Net-50,这表明增加多种尺度感受野可以适应病斑大小的动态变化。在有噪声干扰时多尺度 U 网络表现出了更好的识别性能,识别率达到 99.20%。在亮度较暗的情况下多尺度 U 网络的优势更加明显,识别率仅降低 4%(其他方法降低至少 8%以上),这是因为随着光照强度的改变,其他模型对叶部病斑的敏感度降低,而本文方法利用反卷积模块引导特征提取网络更加关注病斑的真实位置,增强了模型在光照不足条件下的识别能力。本文方法的 GFLOPs 值为 31.27×10^6 ,主要原因是反卷积模块增加了模型的复杂度,如表 2 所列,本文方法的测试运行时间为 26 ms,具有较强的实时性。

表 3 不同模型的识别结果的分析

Table 3 Analysis of recognition results of different models

模型	不同数据增强方法下的识别率			GFLOPs
	原始图像/%	降低 30% 亮度/%	添加 0.98 椒盐噪声/%	
Sun et al ^[11]	97.69	84.51	97.81	0.43×10^6
ResNet-50	99.29	91.17	98.95	4.12×10^6
SE_ResNet50 ^[28]	99.30	92.07	98.99	4.44×10^6
Res2Net-50 ^[27]	99.32	92.10	99.13	4.29×10^6
Our Method	99.35	95.10	99.20	31.27×10^6

结束语 本文受目前流行的深度学习研究方法的启发,针对番茄叶部病斑尺度不一、形状分割困难且病斑分割需要大量的像素级标注的问题,提出了一种多尺度 U 网络,以同时提升番茄叶部病斑的分割与识别精度。

本文利用多尺度残差块组合不同尺寸的感受野,可以增强模型的多尺度表征能力,分割出相对完整的病斑形状和清晰的病斑边缘;为弥补病斑标注数据的不足,构建 CB 模块获取特定类别病害图像的激活图,利用大量病害类别标注样本的关键信息辅助模型进行病斑分割训练,只需采用少量像素级标注作为监督就可以获得精确的分割效果,MPA,MIoU 和 FWIoU 分别达到了 86.15%,75.25%和 90.27%;为解决卷积核提取特征的不透明性和不确定性问题,设计反卷积模块引导特征提取网络关注病斑的正确位置,进一步优化模型病害识别性能,模型在亮度较暗的情况下优势明显。

经过实验分析,多尺度 U 网络的分割和识别性能均优于其他方法。但仍然需要进一步的研究。

(1) 现有的植物病害识别与分割方法限定在简单背景的情况下才能有较高的识别率,需要对自然场景的植物病害识别方法进行进一步的探索。

(2) 目前建立的模型需要大量的病害类别标注样本进行训练,今后在如何减少病害类别标注样本训练模型方面还需要进一步研究。

(3) 叶片轮廓对病害种类的研究具有一定的价值,如何同时分割出病斑和叶片轮廓将是今后研究的一个方面。

参考文献

[1] WANG X Y, WEN H J, LI X X, et al. Analysis of research progress in detection and early warning technologies for major agricultural diseases[J]. Journal of Agricultural Machinery, 2016, 47(9):266-277.

[2] PUJARI J D, YAKKUNDIMAT H. SVM and ANN Based Classification of Plant Diseases Using Feature Reduction Technique [J]. INT J Interact Multi, 2016, 3(7):6-14.

[3] WANG D, CHAI X J. Application of machine learning in plant diseases recognition[J]. Journal of Chinese Agricultural Mechanization, 2019, 40(9):171-180.

[4] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 2:1097-1105.

[5] MOHANTY S P, HUGHES D P, MARCEL S. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science, 2016, 7:1-10.

[6] SRDJAN S, MARKO A, ANDRAS A, et al. Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification [J]. Computational Intelligence and Neuroscience, 2016, 2016:1-11.

[7] AMARA J, BOUAZIZ B, ALGERGAWY A. A deep learning-based approach for banana leaf diseases classification[J]. Lecture Notes in Informatics (LNI), Proceedings- Series of the Gesellschaft fur Informatik (GI), 2017, 266:79-88.

[8] BRAHIMI M, BOUKHALFA K, MOUSSAOUI A. Deep Learning for Tomato Diseases; Classification and Symptoms Visualization[J]. Applied Artificial Intelligence, 2017, 31 (4/5/6):1-17.

[9] FERENTINOS K. Deep learning models for plant disease detection and diagnosis[J]. Computers and Electronics in Agriculture, 2018(145):311-318.

[10] LIANG Q, XIANG S, HU Y, et al. PD2SE-Net: Computer-assisted plant disease diagnosis and severity estimation network[J]. Computers and Electronics in Agriculture, 2019, 157:518-529.

[11] SUN J, TAN W J, MAO H P, et al. Recognition of multiple plant leaf diseases based on improved convolutional neural network[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33(19):209-215.

[12] GUO X Q, FAN T J, SHU X. Image recognition of tomato leaf diseases based on improved Multi-Scale AlexNet[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(13):162-169.

[13] XIAO Z Y, ZHAO X C. Recognition of typical pasture based on dual pooling and multi-scale kernel feature weighted CNN[J]. Journal of Agricultural Machinery, 2020, 51(5):182-191.

[14] YU H J, SON C H. Apple Leaf Disease Identification through Region-of-Interest-Aware Deep Convolutional Neural Network [J]. Journal of Imaging ence and Technology, 2020, 64 (2): 20507-1-20507-10.

[15] YANG W, BI X L, XIAO B. Agricultural pests detection method based on regional convolutional neural network[J]. Computer Science, 2018, 45(S2):226-229, 233.

[16] BRAHIMI M, MAHMOUDI S, BOUKHALFA K, et al. Deep interpretable architecture for plant diseases classification[C]// Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA). New Mexico, USA, 2019:111-116.

[17] LONG J, SHELHAMER E, DARRELL T. Fully Convolutional Networks for Semantic Segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4):640-651.

- Features in SAR Image Change Detection[J]. Remote Sensing Technology and Application, 2002, 17(3):162-166.
- [17] CHEN S, WANG H. SAR target recognition based on deep learning[C] // 2014 International Conference on Data Science and Advanced Analytics. 2014.
- [18] GONG M, LI Y, JIAO L, et al. SAR change detection based on intensity and texture changes[J]. Isprs Journal of Photogrammetry & Remote Sensing, 2014, 93(93):123-135.
- [19] WEI G, GUO H, AN J B, et al. SAR sea surface oil spill image segmentation method based on fully convolutional neural network[J]. Journal of Computer Applications, 2019(S1).
- [20] GUO X. Water change detection based on pixel-level fusion of optics and SAR image[D]. Xuzhou, China University of Mining and Technology.
- [21] EMEK R A, DEMIR N. Building detection from sar images using unet deep learning method [J/OL]. ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020: 215-218. https://www.researchgate.net/publication/347118757_BUILDING_DETECTION_FROM_SAR_IMAGES_USING_UNET_DEEP_LEARNING_METHOD.
- [22] YANG D H, MA D B. Optimization Algorithm of Polarization Lee Filter Based on Polarization Vector Similarity Coefficients [J]. Journal of Information Engineering University, 2010, 11(6):737-740.
- [23] ZHANG H, LING C. Multichannel simultaneous dual-band fully polarimetric airborne synthetic aperture radar: System features and experimental results[J]. Journal of Applied Remote Sensing, 2018, 12(3):1.
- [24] WU B, LIN S S, ZHOU G J. Object-oriented high-resolution remote sensing image segmentation and classification evaluation index[J]. Journal of Geo-Information Science, 2013, 15(4):567-573.
- (上接第 366 页)
- [18] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C] // International Conference on Medical Image Computing and Computer-Assisted Intervention. 2015:234-241.
- [19] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention u-net: Learning where to look for the pancreas[J]. arXiv, 2018.
- [20] ZHOU Z, SIDDIQUEE M M R, TAJBAKHSH N, et al. Net++: A Nested U-Net Architecture for Medical Image Segmentation[J]. Lecture Notes in Computer Science, 2018, 11045 LNCS:3-11.
- [21] ZHAO B, FENG Q. Segmentation of grape diseases leaf based on full convolution network[J]. Journal of Nanjing Agricultural University, 2018, 41(4):752-759.
- [22] WANG Z, ZHANG S W, WANG X F. Cucumber leaf lesion segmentation method based on improved fully convolutional neural network[J]. Jiangsu Journal of Agriculture, 2019, 35(5):1054-1060.
- [23] RUSSELL B C, TORRALBA A, MURPHY K P, et al. LabelMe: a database and web-based tool for image annotation[J]. International Journal of Computer Vision, 2008, 77(1/2/3):157-173.
- [24] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016:770-778.
- [25] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification [C] // Proceedings of the IEEE International Conference on Computer Vision, 2015, 2015 International Conference on Computer Vision. 2015:1026-1034.
- [26] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. arXiv, 2014.
- [27] GAO S, CHENG M M, ZHAO K, et al. Res2net: A new multi-scale backbone architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(2):652-662.
- [28] HU J, LI S, GANG S, et al. Squeeze-and-Excitation Networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42(8):2011-2023.



WANG Xin, born in 1994, postgraduate. His main research interests include semantic segmentation of remote sensing images.



LING Cheng, born in 1987, Ph.D, associate professor. His main research interests include high-performance GPU computing on computational biology and bioinformatics.



GU Xing-jian, born in 1985, Ph.D, lecturer, is a member of China Computer Federation. His main research interests include machine learning and pattern recognition.



REN Shou-gang, born in 1977, Ph.D, associate professor, is a member of China Computer Federation. His main research interests include big data analysis and agricultural information.