

齐国红, 许新华, 师晓丽. 基于多尺度注意力 U-Net 的结球甘蓝青虫检测方法[J]. 江苏农业学报, 2023, 39(6): 1349-1357.
doi:10.3969/j.issn.1000-4440.2023.06.010

基于多尺度注意力 U-Net 的结球甘蓝青虫检测方法

齐国红, 许新华, 师晓丽

(郑州西亚斯学院电子信息工程学院, 河南 郑州 451150)

摘要: 针对结球甘蓝青虫姿态多样、形状不规则以及传统 U-Net 对多尺度图像检测的鲁棒性较差等问题, 本研究提出一种基于多尺度注意力 U-Net(MSAU-Net)的结球甘蓝青虫检测方法。该方法将多尺度空洞 Inception 和注意力引入到 U-Net, 通过设置不同膨胀率的初始卷积层卷积核和全局池化层类型, 提取多尺度深层次的结球甘蓝青虫检测特征。首先, 对原始图像进行超像素聚类, 极大减少结球甘蓝青虫图像的基元数量; 其次, 利用多尺度空洞 U-Net 提取不同大小的结球甘蓝青虫特征; 最后, 通过注意力连接将 MSAU-Net 同层的浅层、深层特征拼接, 得到结球甘蓝青虫图像的关键特征, 加快网络训练。MSAU-Net 方法在结球甘蓝青虫数据集上的平均检测精度为 95.26%, 较 U-Net 方法提高了约 6 个百分点。MSAU-Net 方法能较好地检测到大小不同的结球甘蓝青虫, 能够应用于结球甘蓝青虫自动检测系统。

关键词: 结球甘蓝青虫检测; 超像素聚类; U-Net; 多尺度注意力 U-Net

中图分类号: TP391.41; S432 **文献标识码:** A **文章编号:** 1000-4440(2023)06-1349-09

Detection of cabbage worms based on multi-scale attention U-Net

QI Guo-hong, XU Xin-hua, SHI Xiao-li

(School of Electronic Information Engineering, Zhengzhou SIAS University, Zhengzhou 451150, China)

Abstract: Aiming at the problems of diverse postures, irregular shapes, and the low robustness of traditional U-Net to multi-scale image detection, a detection method of cabbage worms based on multi-scale attention U-Net (MSAU-Net) was proposed. This method introduced multi-scale dilated Inception and attention into U-Net, and extracted multi-scale high-level worm detection features by setting initial convolution layer convolution core and global pooling layer types with different expansion rates. First, the original image was clustered by superpixel cluster algorithm to greatly reduce the number of primitives of worm images. Then, the multi-scale dilated U-Net was used to extract the features of different sizes of worms. Finally, the shallow and deep features of the same layer of MSAU-Net were spliced through attention connection to obtain the key features of worm images and speed up network training. The average detection accuracy on the cabbageworm dataset was 95.26%, which was about six percentage points higher than that of U-Net. The MSAU-Net method can detect cabbageworms with different sizes, and can be applied to the automatic detection system of cabbage worms.

Key words: cabbageworm detection; superpixel clustering; U-Net; multiscale attention U-Net

收稿日期: 2022-09-17

基金项目: 国家自然科学基金项目(62172338); 河南省科技厅项目(232102110274, 222102210122); 河南省高等学校重点科研项目(23B510004, 22B520049); 河南省教育厅 2022 年民办普通高等学校学科专业建设资助项目[教办政法(2022)219 号]

作者简介: 齐国红(1987-), 女, 河南郑州人, 硕士, 讲师, 主要从事模糊模式识别及其应用研究。(E-mail)919728600@qq.com

结球甘蓝青虫检测是青虫防治的前提, 但由于田间青虫的形状、姿态变化多样, 青虫与环境背景差异较小, 使得田间青虫准确检测成为现阶段一个重要的研究课题^[1-2]。很多特征提取方法能够应用于害虫识别^[3]。Martineau 等^[4]探讨了关于昆虫分类的 44 项研究, 包括害虫图像采集、图像特征提取与选择以及害虫分类与识别等处理方法。Ebrahimi 等^[5]提出了

一种基于改进支持向量机(Support vector machine, SVM)的害虫分类方法,该方法利用害虫图像的大直径与小直径之比,以及颜色特征构建 SVM 结构,取得了较高的识别率。传统的基于图像预处理和特征提取的害虫检测与识别方法的准确性、泛化能力较低,主要原因是田间害虫在不同时期具有不同的表象,以及害虫形状、大小、姿态、位置变化很大。

深度学习被广泛应用于复杂图像的分割、检测和识别等方面^[6]。Li 等^[7]介绍了一种基于改进 GoogLeNet 模型的作物害虫识别方法,该方法对农田背景下害虫的分类结果优于原始的 GoogLeNet 模型。Xia 等^[8]利用卷积神经网络(CNN)进行昆虫多分类研究。Liu 等^[9]将模块通道-空间注意、区域建议网络和位置敏感评分图结合,提出了一种基于改进卷积神经网络(Improved convolutional neural network, ICNN)的多类害虫检测分类算法。Wang 等^[10]建立了一个大规模标准化农业害虫数据集 Pest24,包含 24 种害虫,25 378 幅野外害虫标注图像,并采用快速区域卷积神经网络(Faster RCNN)、单次多目标检测器(SSD)、YOLOv3、级联卷积神经网络(Cascade R-CNN)等深度学习模型进行作物害虫检测。张博等^[11]提出了一种基于空间金字塔池化和改进 YOLOv3 相结合的作物害虫识别方法,该方法结合上采样和卷积实现反卷积,使 YOLOv3 能够有效检测农作物中的小害虫。

以上基于 CNN 及其改进网络模型的检测方法需要大量训练样本,并且训练时间很长。U-Net 是一种改进的 CNN 结构,在医学图像检测和分割任务中取得了明显效果^[12]。空洞 Inception 可以在不增

加网络参数和不损失空间分辨率的情况下扩大卷积层的感受野,能够减少 CNN 中池化操作造成的特征损失^[13],被应用于图像识别以及作物病害检测中^[14]。将注意力引入到深度学习模型中,能够加快深度学习网络训练并且克服梯度消失问题^[15-16]。超像素聚类方法利用图像的灰度、颜色、纹理和形状等特征将图像划分为几个区域,以使每个点到聚类中心的平均值最小化,为后续的图像特征提取及其检测、识别任务提供一种紧凑的图像数据表示,能够极大降低后续图像处理的复杂度^[17-19]。本研究拟构建基于多尺度注意力 U-Net(MSAU-Net)的结球甘蓝青虫网络检测模型,在 U-Net 中引入多尺度空洞 Inception 提取多尺度特征,并通过注意力将 MSAU-Net 同层的浅层、深层特征进行拼接,得到结球甘蓝青虫图像的关键特征,减少计算量,加速网络训练,最后在结球甘蓝青虫图像数据集上进行试验,以期能够有效检测大小不同的结球甘蓝青虫。

1 材料与方法

1.1 图像采集与扩充

结球甘蓝青虫是一种比较常见的对结球甘蓝质量、产量影响较大的害虫。在中国陕西省宝鸡市农业科学研究所结球甘蓝试验基地采集结球甘蓝青虫图像 250 幅,包含不同尺度、不同场景、不同背景、不同图像分辨率下的结球甘蓝青虫图像,部分青虫图像如图 1 所示。图像的分辨率约为 4 928×3 264 像素,利用物联网得到的视频图像每帧 1 920×1 080 像素。图 1 显示,结球甘蓝青虫的形状、颜色、大小、姿态和方向随机变化,图像中青虫的尺寸相对较小。




图 1 姿态、颜色、形状、大小和背景等不同的结球甘蓝青虫

Fig.1 Cabbageworms with different postures, colors, shapes, sizes and backgrounds

由于所收集的青虫图像有限,只有 250 幅,对每幅图像进行图像扩充以增加样本数量。考虑到图像变形、图像含噪声以及图像的拍摄角度不确定等常见问题,通过以下方法对图像进行扩充:(1)分别将每幅图像旋转 45° ,得到 4 幅扩充图像;(2)将盐和胡椒噪声添加到图像,得到 10 幅扩充图像;(3)采

用裁剪操作将每幅青虫图像裁剪成不同的尺度,得到 6 幅扩充图像。经过图像扩充后,每幅原始图像均生成 20 幅扩充图像,共得到 5 000 幅扩充图像,由此构建一个包含 5 250 幅青虫图像的扩展数据集。1 幅图像的 20 幅扩充图像如图 2 所示。



图 2 1 幅结球甘蓝青虫图像的 20 幅扩充图

Fig.2 The 20 augmented images of a cabbageworm image

1.2 试验方法

1.2.1 超像素聚类方法 超像素聚类方法 (SLIC) 是一种简单、实用的超像素聚类算法。假设超像素大小大致相等,给定有 n 个像素和 K 个超像素的图像,每个超像素的近似大小为 n/K ,则每个网格区间都有一个超像素中心 $C_k = (L_k, a_k, b_k, x_k, y_k)$, $k = 1, 2, \dots, K$ 。设 K 个超像素聚类中心为 $S = \sqrt{n/K}$, $(L_1, a_1, b_1, x_1, y_1)$ 和 $(L_2, a_2, b_2, x_2, y_2)$ 为 2 个随机聚类中心,计算像素间色彩差异 (d_{lab})、像素间的空间间隔 (d_{xy}) 和聚类中心之间的类似度距离 (D_s):

$$d_{lab} = \sqrt{(L_1 - L_2)^2 + (a_1 - a_2)^2 + (b_1 - b_2)^2} \quad (1)$$

$$d_{xy} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (2)$$

$$D_s = d_{lab} + (\beta/S) \cdot d_{xy} \quad (3)$$

式中, $1 \leq \beta \leq 20$ 用于控制超像素的紧致性, β 越大说明生成的超像素形状越规则,则空间邻近性集群越紧凑; D_s 越大则类似度越低。

SLIC 的具体步骤如下:

步骤一:通过在规则网格 S 上采样像素来初始化聚类中心 $C_k = (L_k, a_k, b_k, x_k, y_k)$;

步骤二: K 个超像素聚类中心被移动到 3×3 邻域的最低梯度位置,以避免将它们放置在边缘或有噪声的像素上。图像梯度计算如下:

$$G(x, y) = \|I(x+1, y) - I(x-1, y)\| + \|I(x, y+1) - I(x, y-1)\| \quad (4)$$

式中, $I(x, y)$ 为点 (x, y) 的标签向量。

步骤三:根据距离度量,图像中的每个像素与搜索区域中最近的聚类相关联;

步骤四:计算一个新的中心作为属于该簇的所有像素的参数平均向量;

步骤五:返回步骤三,将像素与最近的聚类中心关联并重新计算聚类中心的过程,不断迭代,直到收敛。

1.2.2 U-Net U-Net 的结构图 (图 3) 显示,图中左半部分为编码网络,右半部分为解码网络。编码网络包含 4 个模块,每个模块包含 3 个卷积和 1 个最大池化降采样,每次降采样后特征图个数增加 1 倍。解码网络包含 4 个模块,每个模块通过反卷积将特征图的尺寸乘以 2,通过上采样将特征图放大 1 倍,再将特征图个数减半。将压缩路径的编码网络特征图裁剪到与解码网络特征图的尺寸相同,然后通过跳跃连接将编码网络和解码网络之间对应的特征图合并拼接,还原下采样过程中的信息损失。每次卷积后通过 ReLU 激活函数,加快收敛速度并避免梯度消失。

U-Net 的损失表示为:

$$E = \sum_{x \in Q} \bar{\omega}(x) \lg \{p_{l(x)}[x]\} \quad (5)$$

式中, $p_{l(x)}[x]$ 为 Softmax 函数; Q 为像素点的标值集; $\bar{\omega}$ 为像素点的权值,表示为:

$$\bar{\omega}(x) = \bar{\omega}_c(x) \cdot \exp\{-[d_1(x) + d_2(x)]^2 / (2\delta^2)\} \quad (6)$$

式中, $\bar{\omega}(x)$ 为权值; $d_1(x)$ 和 $d_2(x)$ 分别表示像素点与其最近细胞的距离和像素点与其第二近细胞的距离。

由于结球甘蓝青虫的形状多样、多变,仅利用传统的 U-Net 检测不能满足实际工作对精准度和速度的要求。





图3 U-Net 结构

Fig.3 U-Net structure

1.2.3 空洞卷积 空洞卷积通过在卷积核的中间填充 0 来扩展感受野,图 4A 表示膨胀率为 1,即传统的卷积核为 3×3 ,卷积后感受野为 3×3 ;图 4B 表示膨胀率为 2,虽然卷积核大小仍为 3×3 ,但卷积后感受野扩大为 5×5 ;图 4C 表示膨胀率为 3,卷积后感受

野扩大为 7×7 。结果(图 4)表明,随着膨胀率的增加,感受野增大,而计算量不增加。因此,使用不同膨胀率空洞卷积代替传统卷积,可以在不增加计算量的情况下获得具有更强分类能力的特征。



A:膨胀率为 1;B:膨胀率为 2;C:膨胀率为 3。

图4 3个不同膨胀率空洞卷积核

Fig.4 Dilated convolution kernels with three dilation rates

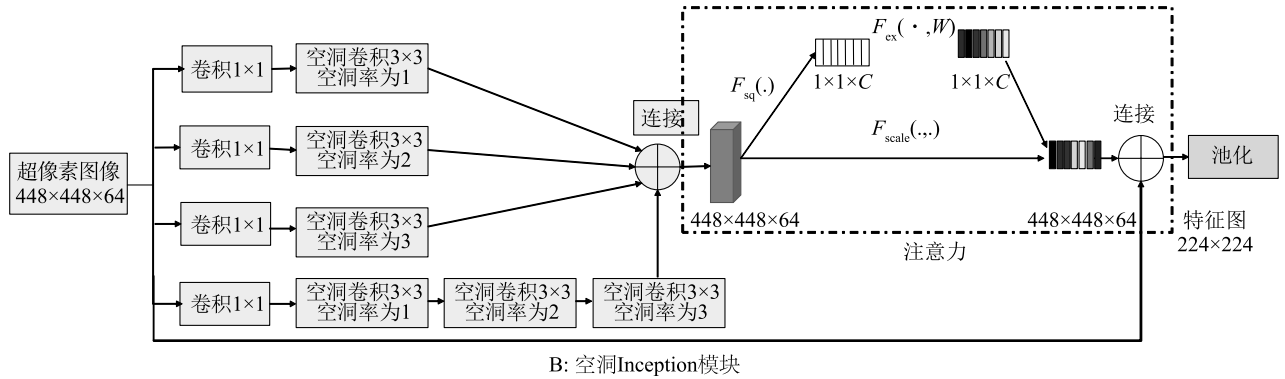

1.2.4 多尺度注意力 U-Net 模型 为了能够准确检测不同大小、形态等的结球甘蓝青虫,本研究构建一种基于多尺度注意力 U-Net(MSAU-Net)的结球甘蓝青虫检测方法。图 5 显示,MSAU-Net 的结构主要包括超像素聚类、空洞 Inception 和 U-Net。比较图 5A 与图 3,可以看出 MSAU-Net 为 U-Net 的一个轻量级模型。

图 5B 为空洞 Inception 模块,先将超像素聚类

后的图像输入到 4 个 1×1 卷积,再经过 4 个 3×3 空洞 Inception,然后拼接分别得到的结果,其中 4 个空洞 Inception 的空洞率分别为 1、2、3、1,获取不同的感受野,从而提取多尺度特征。使用 1×1 卷积可以控制卷积核数量,实现降维或升维,也可以恢复为原图大小,最后为一个池化层。空洞 Inception 后连接一个注意力模块,如图 5B 所示,其中 $F_{sq}(\cdot)$ 表示对

输出特征图进行全局平均池化; $F_{ex}(\cdot, W)$ 表示通过全连接层和非线性学习得到特征图各通道的权重值; $F_{scale}(\cdot, \cdot)$ 表示将各通道的权重信息融合到特征图中。设输入注意力模块的卷积图为 $X \in \mathbb{R}^{H \times W \times C}$, 其长度、宽度和通道数分别为 H 、 W 和 C , 则全局平

均池化和最大池化后的输出分别表示为 $Att_{avg} \in \mathbb{R}^{1 \times 1 \times C}$ 和 $Att_{max} \in \mathbb{R}^{1 \times 1 \times C}$, 其中 Att_{max} 可以滤掉目标对象的全局背景信息, 同时显著突出目标对象。令 $X = [x_1, x_2, \dots, x_c]$, x_c 为第 c 个卷积核的参数集, 则 Att_{avg} 和 Att_{max} 计算如下:



$F_{sq}(\cdot)$ 表示对输出特征图进行全局平均池化; $F_{ex}(\cdot, W)$ 表示通过全连接层和非线性学习得到特征图各通道的权重值; $F_{scale}(\cdot, \cdot)$ 表示将各通道的权重信息融合到特征图中; C 表示通道数。

图5 基于MSAU-Net的青虫检测方法

Fig.5 Worm detection based on MSAU-Net

$$Att_{avg} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (7)$$

$$Att_{max} = \operatorname{argmax} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (8)$$

设2个完全连接层为 $FC_3 \in \mathbb{R}^{\frac{C}{r} \times C}$ 和 $FC_4 \in \mathbb{R}^{\frac{C}{r} \times C}$, 其中 r 为2个完全连接的层间降维比率; C 为通道数。训练时2个分支的输入共享全连通层的参数。2个分支的输出如下:

$$output_{avg} = \operatorname{Sigmoid}[FC_4 \times \operatorname{ReLU}(FC_3 \times Att_{avg})] \quad (9)$$

$$output_{max} = \operatorname{Sigmoid}[FC_4 \times \operatorname{ReLU}(FC_3 \times Att_{max})] \quad (10)$$

计算通道注意模块的输出如下:

$$output_{ch} = output_{avg} + output_{max} \quad (11)$$

通过矩阵乘法执行以下特征加权操作:

$$W = (x_c, output_{ch}) = x_c \times output_{ch} \quad (12)$$

通过通道特征选择后, 输入 W 到新的空间注意力模块中, 输出特征图的尺寸与输入的尺寸一致, 不需要

对网络结构进行重大改变。考虑到注意模块产生的过滤后的特征更有分类性,为了增加整个结构的非线性程度,在网络的残差连接上增加二阶项和偏置项。设输入特征向量为 X ,卷积操作后的输出向量为 X' ,最终融合输出的结果为 $f=X+X'$,则融合后的结果如下:

$$f=X+X'+F'' \quad (13)$$

式中, $F''=F(X \odot X'+\xi)$, \odot 表示矩阵元素相乘, ξ 表示调优偏移参数, $F(\cdot)$ 是一个可微函数。

采用平方根形式, $F(\cdot)$ 取偏移量 $\xi=0.0001$ 用于保持反向传播过程中的梯度稳定性。改进后的残差连接计算如下:

$$f=X+X'+\sqrt{\text{ReLU}(X) \odot \text{ReLU}(X')+\xi} \quad (14)$$


2 结果与分析

为了验证 MSAU-Net 的有效性,在构建的结球甘

蓝青虫图像数据集上进行试验,并与 ICNN 方法^[9]以及基于空间金字塔池化的作物害虫识别(PPDCNN)方法^[11]进行比较。在试验参数设置中,批处理数为 32,迭代次数为 3 000,动量为 0.9,权重衰减为 0.0001,初始学习率为 0.01,且每迭代 200 次下降 10 倍。试验环境为 Python 3.5.2、Tensorflow-GPU 1.8.0,以及 Intel Xeon E5-2643v3@3.40 GHz CPU、64 GB 内存、Win 10 64 bit、NVIDIA Quadro M4000 GPU、CUDA Toolkit 9.0、8 GB 显存、CUDNN V7.0^[2]。

将结球甘蓝青虫图像中的 3 000 幅用于模型训练,剩余的 2 250 幅用于模型测试。本试验重复 50 次,得到稳定可靠的平均检测结果。

图 6 为一个小结球甘蓝青虫图像的超像素分割图,当超像素数为 500 时,经过超像素处理的青虫图像比较清晰。为此,试验设置超像素数为 500。



m 表示超像素数。

图 6 青虫图像及其超像素图像

Fig.6 A cabbageworm image and its superpixel images

将训练图像的超像素图像输入 MSAU-Net 中,提取图像的分类特征。图 7 展示了得到的部分卷积图和池化图,MSAU-Net 能够提取图像的细节,浅层的卷积图为图像中青虫的轮廓,深层的卷积图显示图像中青虫的纹理、细节特征。


为了说明超像素聚类以及本研究构建的 MSAU-Net 模型的有效性,分析了 MSAU-Net 模型和传统的 U-Net 模型在超像素聚类前后模型的损失值与迭代次数的关系^[20]。图 8 显示,超像素聚类依赖于模型收敛,而且 MSAU-Net 模型的收敛结果优于

U-Net 模型,说明超像素图像作为输入能够加速网络收敛,提高检测率;超像素聚类后的 MSAU-Net 模型在 1 000 次迭代后相对稳定,在 1 500 次迭代后趋于收敛,主要是因为 MSAU-Net 模型为 U-Net 的轻量级模型,训练参数少,训练时间短,MSAU-Net 模型中包含空洞 Inception 和注意力;U-Net 模型的收敛速度较慢,是因为 U-Net 模型含有大量训练参数。

为了测试本研究构建的 MSAU-Net 模型的有效性,从数据集中随机选择 8 幅图像,将检测结果可视化并与 2 种广泛使用的图像分割模型[全卷积网络

(FCN)^[21]和 U-Net^[12]的结果进行比较,结果(图9)表明,MSAU-Net 模型优于 FCN 模型和 U-Net 模

型,能够在复杂的背景中检测出结球甘蓝青虫,且青虫图像完整,边缘清晰。



A:原始结球甘蓝青虫图像的超像素图像;B:空洞 Inception 的特征图;C:U-Net 第一卷积层的特征图;D:U-Net 第二卷积层的特征图。

图7 空洞 Inception 和 U-Net 的特征图

Fig.7 Feature maps of dilated Inception and U-Net




图8 MSAU-Net 模型和 U-Net 模型在超像素聚类前后的损失值

Fig.8 The loss of MSAU-Net and U-Net before and after superpixel clustering

图9显示,MSAU-Net 模型的检测效果最好,能够有效检测到复杂背景下大小不同的青虫,而 FCN 模型和 U-Net 模型对于复杂背景下小尺度青虫的检测效果不理想,检测图像的边界模糊、形状不规则。为了合理、有效地比较青虫检测方法的性能,选择迭代次数为3 000的模型为训练好的网络模型。分析 ICNN 模型^[9]、PPDCNN 模型^[11]和本研究构建的 MSAU-Net 模型对青虫图像的检测结果(表1),为了进一步说明超像素聚类与空洞 Inception 相结合的优势,将 MSAU-Net 与 U-Net、Superpixel+U-Net(超像素聚类 and U-Net 相结合的检测方法)的检测结果(表2)进行比较,综合表1和表2的结果,可以看出,MSAU-Net 模型取得了较好的检测结果。

3 结论

在大田中及时、准确地检测结球甘蓝青虫,对防

治结球甘蓝青虫具有重要作用。由于野外青虫的姿态、形态各异,背景复杂,对其进行检测是一项艰巨的任务。本研究基于超像素聚类、空洞 Inception、U-Net 和注意力,提出了一种基于 MSAU-Net 的结球甘蓝青虫检测方法,该方法利用多尺度 U-Net 提取青虫的多尺度特征,并通过注意力提取重要特征,加快网络收敛。将本研究构建的 MSAU-Net 模型与 FCN、ICNN、PPDCNN、U-Net、Superpixel+U-Net 模型的试验结果进行对比,发现 MSAU-Net 模型整体优于 FCN、ICNN、PPDCNN、U-Net、Superpixel+U-Net 模型,MSAU-Net 模型分割的青虫图像非常接近标注的青虫图像,并且可以提取微小青虫图像。主要原因是引入了空洞 Inception,这是一种多尺度 CNN 模块。U-Net 模型优于 FCN 模型,因为 FCN 模型是在不考虑图像像素之间关系的情况下对每个像素进行分类,而 U-Net 模型在通道维度上将编码、解码特征连接在一起,以形成更丰富的特征。U-Net 模型可以完整地分割青虫图像,对于小青虫的分割效果优于 FCN 模型。FCN 模型和 U-Net 模型分割的青虫图像中存在一些假阳性区域,即 FCN 模型和 U-Net 模型不能很好地区分青虫与背景。MSAU-Net 模型整体优于 ICNN 模型和 PPDCNN 模型,具有最高的精度和最少的训练时间、测试时间。其原因是 MSAU-Net 模型引入空洞 Inception 和注意力,并使用超像素图像作为模型输入,在特征提取阶段用滤波后的加权特征向量代替原始特征向量进行残差融合,使用二值分类方法减少信息丢失,加快网络训练速度。在青虫图像数据集上的试验结果验证了 MSAU-Net 是一种有效的青虫检测算法,其精度达到 95% 以上,该方法能够应用于农业害虫管理中的青虫自动检测系统。

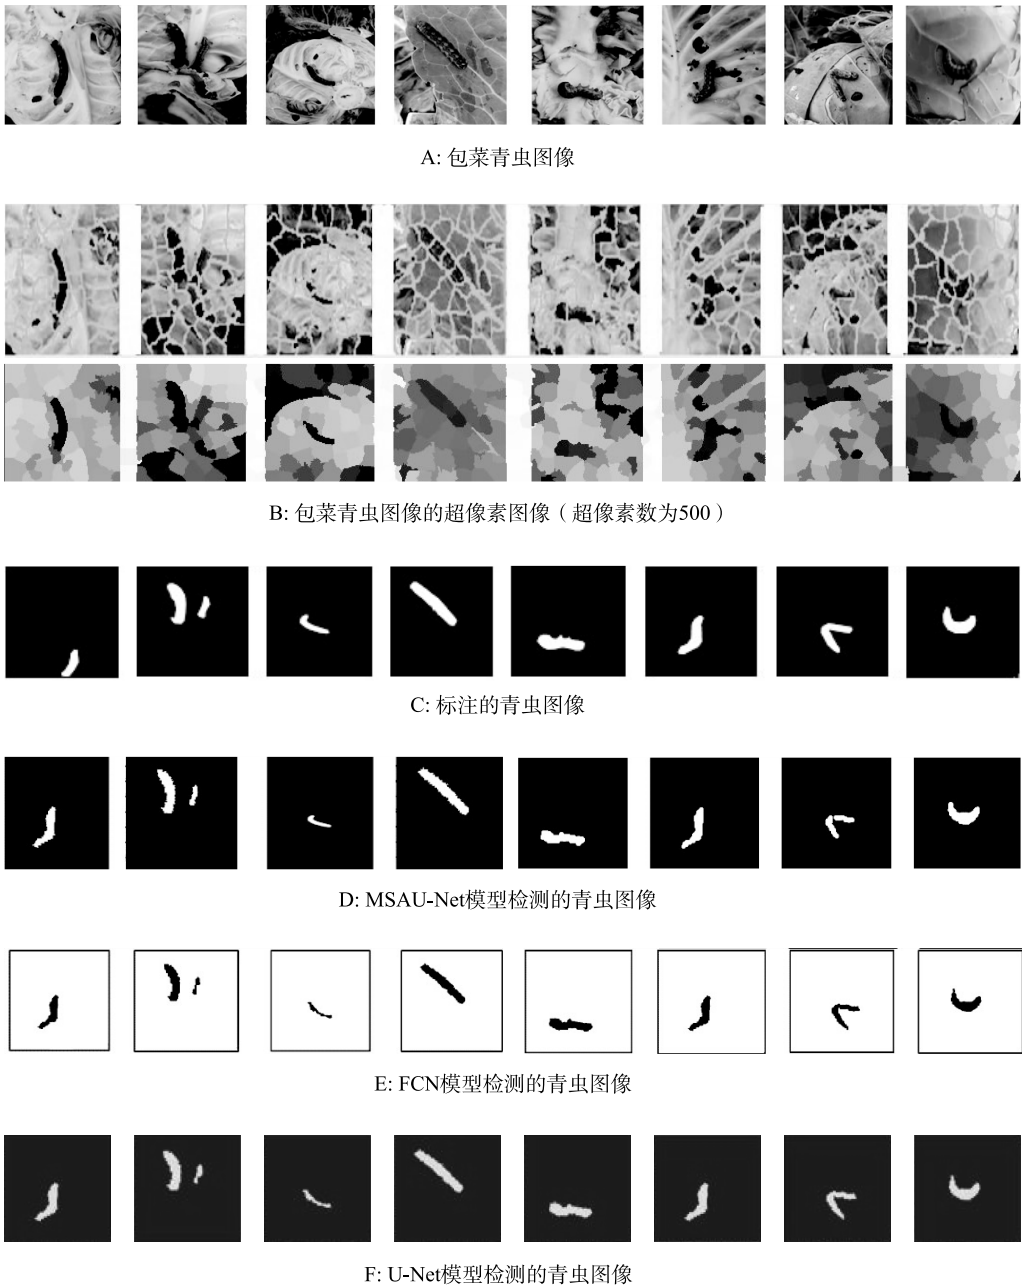


图 9 结球甘蓝青虫检测
Fig.9 Cabbageworm detection

表 1 4 种模型对结球甘蓝青虫的检测精度

模型	精度 (%)	训练时间 (h)	测试时间 (s)
FCN	87.13	19.13	0.36
ICNN	91.34	10.86	0.34
PPDCNN	91.82	14.54	0.42
MSAU-Net	95.26	6.12	0.28

表 2 U-Net 及其改进模型对结球甘蓝青虫的检测精度

modified models			
模型	精度 (%)	训练时间 (h)	测试时间 (s)
U-Net	89.15	12.66	0.34
Superpixel+U-Net	91.25	11.18	0.32
MSAU-Net	95.26	6.12	0.28

参考文献:

- [1] 康飞龙,李 佳,刘 涛,等. 多类农作物病虫害的图像识别应用技术研究综述[J]. 江苏农业科学, 2020, 48(22): 22-27.
- [2] 张善文,邵 斌,齐国红,等. 基于多尺度注意力卷积网络的作物害虫检测[J]. 江苏农业学报, 2021, 37(3): 579-588.
- [3] YAAKOB S N, JAIN L. An insect classification analysis based on shape features using quality threshold ARTMAP and moment invariant[J]. Applied Intelligence, 2012, 37: 12-30.
- [4] MARTINEAU M, CONTE D, RAVEAUX R, et al. A survey on image-based insect classification [J]. Pattern Recognition, 2017, 65: 273-284.
- [5] EBRAHIMI M A, KHOSHTAGHAZA M H, MINAEI S, et al. Vision-based pest detection based on SVM classification method[J]. Computers and Electronics in Agriculture, 2017, 137: 52-58.
- [6] RAWAT W, WANG Z. Deep convolutional neural networks for image classification: a comprehensive review[J]. Neural Computation, 2017, 29(9): 2352-2449.
- [7] LI Y, WANG H, DANG L M, et al. Crop pest recognition in natural scenes using convolutional neural networks[J]. Computers and Electronics in Agriculture, 2020, 169. DOI: 10.1016/j.compag.2019.105174.
- [8] XIA D, CHEN P, WANG B, et al. Insect detection and classification based on an improved convolutional neural network[J]. Sensors, 2018, 18(12). DOI: 10.3390/s18124169.
- [9] LIU L, WANG R, XIE C, et al. PestNet: an end-to-end deep learning approach for large-scale multi-class pest detection and classification[J]. IEEE Access, 2019, 7: 45301-45312.
- [10] WANG Q J, ZHANG S Y, DONG S F, et al. Pest24: a large-scale very small object data set of agricultural pests for multi-target detection[J]. Computers and Electronics in Agriculture, 2020, 175. DOI: 10.1016/j.compag.2020.105585.
- [11] 张 博,张苗辉,陈运忠. 基于空间金字塔池化和深度卷积神经网络的作物害虫识别[J]. 农业工程学报, 2019, 35(19): 209-215.
- [12] LIU X, ZHANG Y, JING H, et al. Ore image segmentation method using U-Net and Res-Unet convolutional networks[J]. RSC Advances, 2020, 10(16): 9396-9406.
- [13] SEVASTOPOLSKY A. Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network [J]. Pattern Recognition and Image Analysis, 2017, 27(3): 618-624.
- [14] 孙 俊,何小飞,谭文军,等. 空洞卷积结合全局池化的卷积神经网络识别作物幼苗与杂草[J]. 农业工程学报, 2018, 34(11): 159-165.
- [15] YANG X. An overview of the attention mechanisms in computer vision[C]. Inner Mongolia: IOP Publishing, 2020.
- [16] LI A, CHEN J, KANG B, et al. Adaptive multi-attention convolutional neural network for fine-grained image recognition [C]. Waikoloa: IEEE, 2019.
- [17] WANG M, LIU X, GAO Y, et al. Superpixel segmentation: a benchmark[J]. Signal Processing: Image Communication, 2017, 56: 28-39.
- [18] QIN F, GUO J, LANG F. Superpixel segmentation for polarimetric SAR imagery using local iterative clustering[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(1): 13-17.
- [19] ACHANTA R, SHAJI A, SMITH K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274-2282.
- [20] YANG F, SUN Q, JIN H, et al. Superpixel segmentation with fully convolutional networks[C]. Virtual: IEEE, 2020.
- [21] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Boston: IEEE, 2015.

(责任编辑:王 妮)