

王 振, 张善文, 王献锋. 基于改进全卷积神经网络的黄瓜叶部病斑分割方法[J]. 江苏农业学报, 2019, 35(5): 1054-1060.
doi: 10.3969/j.issn.1000-4440.2019.05.008

基于改进全卷积神经网络的黄瓜叶部病斑分割方法

王 振, 张善文, 王献锋

(西京学院信息工程学院, 陕西 西安 710123)

摘要: 为了解决传统卷积神经网络在黄瓜叶部病斑图像分割中存在模型训练时间长、分割效果差以及分割过程中易受光照和背景影响等问题, 提出了一种基于改进全卷积神经网络的黄瓜叶部病斑分割方法。首先在模型训练的初始阶段使用传统的卷积神经网络得到病斑图像的轮廓特征, 在训练过程中将传统的修正性单元(ReLU)激活函数替换为指数线性单元(ELU)激活函数; 然后对传统的卷积神经网络得到的病斑图像轮廓特征进行二次模型训练, 训练过程中使用批归一化(Batch normalization)函数稳定模型训练过程; 最后将原始卷积神经网络的多项逻辑回归(Soft max)分类器更换为支持向量机(SVM)分类器, 对分类器输出的像素分类结果进行反卷积操作, 恢复图像分辨率, 得到分割结果。使用本研究方法与改进 OTSU、SVM、CRF 和传统 FCN 等 4 种方法在黄瓜叶部病斑数据集上进行分割试验, 结果表明本研究方法的平均像素分割准确率为 80.46%, 平均交并比为 70.43%, 具有较高的分割精度。

关键词: 黄瓜病斑图像; 卷积神经网络; 激活函数; 图像分割

中图分类号: S126 **文献标识码:** A **文章编号:** 1000-4440(2019)05-1054-07

Method for segmentation of cucumber leaf lesions based on improved full convolution neural network

WANG Zhen, ZHANG Shan-wen, WANG Xian-feng

(College of Information Engineering, Xijing University, Xi'an 710123, China)

Abstract: To solve the problems of the traditional convolutional neural network(CNN) in the process of cucumber leaf diseases image segmentation, such as long model training time, poor segmentation effect and easy to be affected by light and background in the process of segmentation, a method for segmentation of cucumber leaf diseases based on improved fully convolutional neural network was proposed. Firstly, in the initial stage of model training, traditional CNN was used to obtain the contour features of the diseases image. In the process of training, activation function of rectified linear units (RELU) was replaced by the exponential linear unit (ELU). Secondly, the disease contour features obtained by the traditional CNN were trained twice, and the batch normalization function was used to stabilize the model training process. Finally, the SoftMax of the original CNN was replaced with support vector machine(SVM), and the pixel classification result outputs by the classifier were deconvolution operation to restore the image resolution and obtain the segmentation results. The segmentation experiment was carried out on the cucumber leaf image by using this research algorithm and others four algorithms including improved OTSU, SVM, CRF and traditional FCN. The results showed that the average pixel segmentation accuracy of this algorithm was 80.46%, and the average intersection ratio was 70.43%, which could accurately segment the diseased parts in the leaves.

Key words: cucumber lesion image; convolution neural network; activation function; image segmentation

收稿日期: 2019-02-14

基金项目: 国家自然科学基金项目(61473237)

作者简介: 王 振(1994-), 男, 河南周口人, 硕士研究生, 研究方向为模式识别技术在农业领域的应用。(E-mail) wangzhen4013@163.com

病害是导致农作物产量减少和品质下降的主要

因素之一,在日常黄瓜的生长过程中靶斑病、白粉病和炭疽病等病害严重影响着黄瓜的正常生长。黄瓜病害主要发生在叶部,通过对叶部病斑的观察,可以直观地判断病害的发生程度。传统的植物病害判断方式主要通过人工检测,这种方法需要耗费大量的人力资源,随着计算机视觉和模式识别等技术的发展,研究人员利用计算机开发出了许多植物病害识别系统,但识别效率较低且精度较差。计算机在识别的过程中影响识别率的关键因素是图像分割,在分割的问题上许多研究人员提出了很多新方法。刘国奇等^[1]提出了一种改进的双凸模糊变分图像分割方法,由于极大地抑制了复杂背景下图像中所产生的噪声,所以对烟草植物叶片病害平均分割准确率达到 94%。关强等^[2]根据田间植物与耕地的颜色特征差别,利用二维最大类间方差法对不同的农田作物进行病斑分割,由于该方法将叶片的病害部分与正常部分区别最大化,所以得到较好的分割效果。赵金阳等^[3]利用高斯混合模型估计葡萄叶片中病斑区域和正常区域的概率密度分布,利用马尔科夫随机场建立像素特征的能量函数,通过求解能量函数实现对葡萄叶片病斑的自动分割,在 6 种不同葡萄病害叶片上进行分割试验,分割精确度达到 93.7%。张会敏等^[4]通过小波变换提取作物病斑图像的边缘特征,使用最大类间方差法对提取后的边缘特征进行图像分割,在辣椒叶片的图像分割中取得了较高的分割精度。张善文等^[5]提出了一种改进的 K 均值聚类的苹果病害叶片图像分割方法,以图像的颜色特征为聚类空间,使用欧式距离度量像素间的相似度,利用 K 均值聚类算法对病斑图像进行分割,在 3 种苹果病害叶片上进行分割试验,平均分割准确率为 94%。以上方法虽然在病斑图像的分割中取得了一定的效果,但算法复杂度较高,且只能用于一种或少数几种植物叶片病斑图像的分割。

随着人工智能技术的不断发展,许多研究人员将深度学习用于图像的分类和识别中,大量试验结果表明使用深度学习得到的图像特征相比于传统的底层视觉特征在图像的分割与识别中具有更高的精确度。由于卷积神经网络具有自动提取图像特征的优势,研究人员将卷积神经网络运用到植物叶部病斑图像的分割也取得了较好的效果。刘立波等^[6]将条件随机场与卷积神经网络相结合实现了对棉花病斑图像的分割,首先利用卷积神经网络初步提取

病斑图像的轮廓特征,然后结合轮廓特征像素间的相对关系构建条件随机场能量函数,最后使用不同卷积层得到的轮廓特征能量函数对条件随机场进行最优化训练,在棉花病害数据库上进行试验,平均分割精度达到 97%。段凌凤等^[7]利用水稻病斑图像数据集训练了基于全卷积神经网络的水稻病斑图像分割模型,该模型在复杂背景下可以准确地分割出水稻病斑区域。通过改进原始卷积神经网络,在卷积神经网络上增加反卷积过程解决了上采样导致图像分辨率降低的问题,在葡萄病害叶片的分割中比传统 CRF 分割算法具有更高的分割精度。马俊诚等^[8]针对黄瓜病斑图像分割问题提出了一种复合特征与卷积神经网络相结合的方法,首先提取病斑图像的颜色特征和纹理特征,然后将提取后的特征使用马尔科夫随机场进行特征融合,最后利用融合后的特征对卷积神经网络进行训练,在黄瓜病害数据集上得到了较高的分割精度。基于现有的卷积神经网络图像分割方法,本研究构建一种基于改进全卷积神经网络(FCN)的黄瓜叶部病斑图像分割方法,以期解决传统卷积神经网络在黄瓜叶部病斑图像的分割中存在模型训练时间长、分割效果差以及分割过程中易受光照和背景影响等问题。

1 材料与方法

1.1 材料

黄瓜叶部病斑图像均采集于陕西杨凌果蔬实验基地,相机为 Canon EOS 650D,有效像素值为 2.800×10^7 。为了适应不同光照条件下病斑图像的分割,采集时光照分别为强光和弱光。采集的图像主要包括黄瓜靶斑病、白粉病、褐斑病、灰霉病、炭疽病和真菌病等 6 种黄瓜叶部病害的病斑,每种病害采集 255 幅图像。为了方便后期图像的预处理操作,把采集的图像大小统一压缩为 256×256 像素(pixel),并以 JPEG 的格式进行存储。部分黄瓜叶部病斑图像如图 1 所示。

由于目前大多数深度学习技术的应用仍属于有监督的学习范围^[9],因此需要对采集的图像进行预处理。在深度学习的图像分割领域,预处理过程主要是对图像进行人工标注,本研究中使用 Label ME 图像标注工具对统一大小后的图像进行人工标注。为了防止卷积神经网络模型训练过程中出现过拟合问题,对人工标注后的图像数据集进行数据扩充



图 1 6 种黄瓜叶部病斑图像

Fig.1 Six kinds of cucumber diseased leaf images

(包括平移、旋转、缩放和颜色抖动)。平移:将经过预处理的每幅训练样本向左上、右上、左下、右下共 4 个方向平移 8 个像素,以圆心为中心,裁剪出中心 256×256 区域,由此将一幅图像扩展为 5 幅不同样本,其中包含未平移的一幅图像。旋转:将经过预处理的每幅训练样本在旋转角度 $[-5^\circ, 5^\circ]$ 范围内随机旋转 5 次,以圆心为中心,裁剪出中心 256×256 区域,由此将一幅图像扩展为 5 幅不同样本。缩放:将经过预处理的每幅训练样本在比例因子为 $[0.85, 1.00]$ 范围内随机缩小 5 次,以圆心为中心,裁剪出中心 256×256 区域,由此将一幅图像扩展为 5 幅不同样本。颜色抖动:将经过预处理的每幅训练样本 RGB 颜色的 3 个颜色分量 R、G 和 B 分别统一用因子在 $[0.8, 1.2]$ 范围内随机相乘 5 次,并将超过 255 的值设置为 255 以避免溢出失真,然后再由 3 个 R、G 和 B 分量图像整合为彩色 RGB 图像,以圆心为中心,裁剪出中心 256×256 区域,由此将一幅图像扩展为 5 幅不同样本。

经过数据扩充后,将黄瓜叶部病斑图像数据集按照 3:1 比例分配数据集,其中 5 737 幅为训练集,1 913 幅为测试集。

1.2 基于改进全卷积神经网络的图像分割方法

在深度学习的研究过程中,许多研究人员选用全卷积神经网络(FCN)作为图像分割的基础模型架构^[10]。由于传统的全卷积神经网络在初始训练阶段训练时间长、易产生过拟合问题,本研究采用模型二阶训练方法压缩训练时间,减轻过拟合问题。在全卷积神经网络模型训练的过程中传统的修正线性

单元(RELU)激活函数对病斑图像的细节部分利用不充分且易受噪声的影响,因此本研究使用指数线性单元(ELU)激活函数对全卷积神经网络模型进行优化。采用批归一化(Batch normalization, BN)函数稳定模型训练过程。在网络模型的最后像素分类阶段,传统的全卷积神经网络使用 Soft Max 分类器,但在黄瓜叶部病斑图像的分割中效果较差,因此本研究使用支持向量机(SVM)作为像素分类器。为了解决原始卷积神经网络在池化层阶段导致图像分辨率降低的问题,通过反卷积过程恢复图像分辨率,提高病斑图像分割精度。

1.2.1 黄瓜叶部病斑图像分割的全卷积神经网络结构 利用传统的全卷积神经网络模型对黄瓜叶部病斑图像进行分割,得到的分割结果较为粗糙,分割物体的边缘细节较为模糊。为了提高分割结果图像分辨率,研究人员在原始全卷积神经网络中将不同卷积层提取的图像特征按照特定形式进行组合^[11],有效地增强了分割结果的边缘细节。利用以上研究方法,分别以不同采样倍数进行区分,出现了 FCN-32s、FCN-16s、FCN-8s 等 3 种改进的 FCN 模型^[12]。由于黄瓜叶部病斑区域的图像分割需要较为精细的分割结果,本研究分别使用上述 3 种改进的 FCN 模型在黄瓜叶部病斑图像上进行分割试验,通过平均交并比值、计算时间、卷积层数、参数数量等对分割效果进行评价。评价结果表明 FCN-8s 模型平均交并比值最高,计算时间最短,因此选用 FCN-8s 作为黄瓜叶部病斑图像分割模型。

由于 VGG-16 网络模型较深,可以更加详细地提取图像细节信息,提升图像分割效果^[12],因此本研究在 VGG-16 的基础上提出一种基于改进全卷积神经网络的黄瓜叶部病斑图像分割方法。首先将原始 VGG-16 网络模型的全连接层替换为卷积层,即将原有的全连接层 6(FC6)和全连接层 7(FC7)替换为卷积层 6(Conv6)和卷积层 7(Conv7)。由于卷积神经网络中池化层操作会降低图像分辨率,因此在原始 VGG-16 的网络末端增加反卷积操作,反卷积的过程主要是通过双线性插值的方法来实现,通过填充池化层得到原始图像的大小。改进的全卷积神经网络模型如图 2 所示,反卷积操作过程如图 3 所示。

1.2.2 黄瓜叶部病斑图像分割的全卷积神经网络模型改进 由于黄瓜叶部病斑图像中病斑区域在整




图2 改进的全卷积神经网络模型

Fig.2 Improved full convolution neural network model

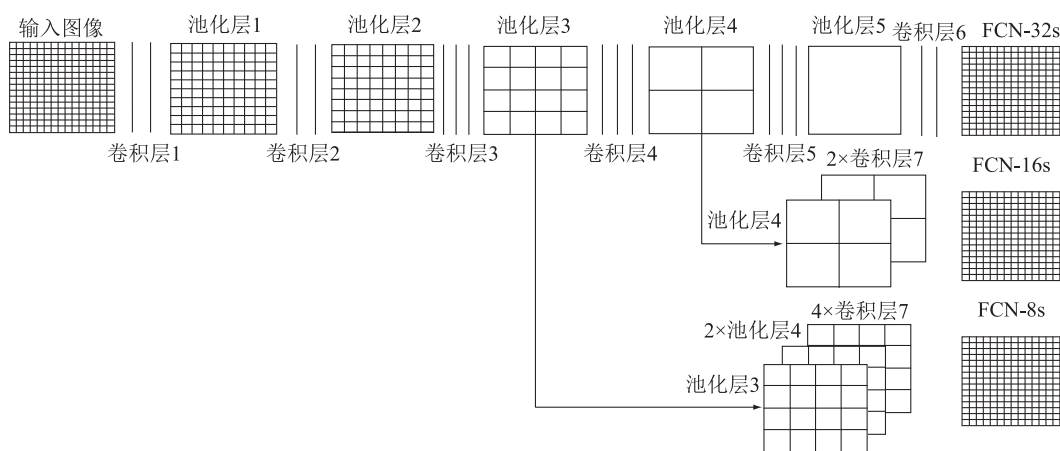


图3 反卷积操作过程

Fig.3 Deconvolution operation process

个叶片中所占面积较小且病斑形状不规则,因此传统全卷积神经网络模型中的修正性单元(ReLU)激活函数不能有效地提取叶片中的病斑区域。在本研究中使用指数线性单元(ELU)激活函数,ELU 激活函数可以加快模型收敛速度,而且具有较强的抗噪能力,计算公式如下:

$$f(x) = \begin{cases} x & x > 0 \\ \alpha(e^x - 1) & x \leq 0 \end{cases} \quad (1)$$

由公式(1)得出,ELU 激活函数可以将函数负部修正为指数函数,总体均值输出接近于0,具有更快的收敛速度。

在原始 FCN 网络模型中分类层中通常使用 Soft max 分类器^[13],在本研究中分别对 Soft max 分类器、SVM 分类器和 K 近邻分类器在黄瓜叶部病斑数据集上进行试验。试验结果表明 SVM 分类器的像素分类准确率最高(91.52%),平均交并比达到80.32%。

为了解决原始全卷积神经网络模型训练时间长,容易出现过拟合问题^[14],通过模型二阶段训练

的方法,减少模型训练时间。模型二阶段训练主要是首先利用较少的训练样本初始化网络模型参数,然后利用这些参数初始化训练模型,最后再进行正式的模型训练。基于改进全卷积神经网络模型的二阶段训练具体步骤如下:第1步,在黄瓜叶部病斑图像数据集中随机选择1 000张预训练图像,使用这些图像对模型进行预训练,直到模型收敛为止,将训练好的模型参数保存;第2步,将所有训练集图像输入网络模型中进行训练,训练的初始化参数选择第1步训练好的模型参数,由于两个步骤的权重和参数都可以共享,因此会减少模型训练时间,提升收敛速度。模型二阶段训练过程如图4所示。

1.2.3 改进的全卷积神经网络分割模型训练 为了提高网络模型的性能,要对模型进行迭代训练,不断更新网络模型参数直到模型收敛为止^[15]。为了使改进的全卷积神经网络在黄瓜叶部病斑的分割中达到较好的效果,使该模型的输出具有较高的分割精度,使用交叉熵函数来表征模型分割结果与标准结果的差异。交叉熵函数主要是用来衡量模型中输




图4 模型二阶段训练过程

Fig.4 Model two-stage training process

入图像与分割图像之间的差异。交叉熵函数越小,表示模型的分割精度越高。在黄瓜叶部病斑的分割中,交叉熵函数代表全卷积神经网络的病斑分割结果与手工标注后分割结果的差异。在本研究中将交叉熵函数平均值作为衡量全卷积神经网络的损失函数值,计算公式如下:

$$\text{loss}(p, q) = \sum_N \left[- \sum_X p(x) \lg q(x) \right] \quad (2)$$

式中 N 表示图像像素点数量, x 表示输入图像 X 中每个像素的特征向量, $p(x)$ 为像素分类向量, $q(x)$ 为全卷积神经网络输出结果的分类向量。

通过损失函数的计算得到全卷积神经网络的损失值,然后使用反向传播算法减小损失值。通过梯度下降算法的不断迭代运算更新网络模型参数,假设 $\delta^{(l+1)}$ 为公式(2)中计算得出的 $l+1$ 层的损失值,该层的权重和偏置分别为 W 和 b 。由此可得第 l 层损失值计算公式:

$$\delta^l = \left[(W^l)^T \delta^{(l+1)} \right] * f(z^l) \quad (3)$$

相对应的梯度下降公式为:

$$\nabla_w J(W, b; x, y) = \delta^{(l+1)} (\alpha^l)^T \quad (4)$$

$$\nabla_b J(W, b; x, y) = \delta^{(l+1)} \quad (5)$$

$$\text{式中激活函数 } f(x) = \begin{cases} x, & x > 0 \\ \alpha(e^x - 1), & x \leq 0 \end{cases}, \delta^{(l+1)}$$

为第 $l+1$ 层的损失值, δ^l 为第 l 层损失值。

2 结果与分析

2.1 试验环境及参数设置

使用 Python3.5 作为编程开发语言,系统操作环境为 Ubuntu16.72LTS,硬件开发环境为 Intel i7 处理器,32 GB 运行内存,GPU 为 GTX1080 16 GB 显存,使用 Caffe2 作为深度学习开发框架。

在基于改进卷积神经网络的黄瓜叶部病斑图像

分割中,设置初始化学学习率为 1×10^{-4} ,权重衰减系数设置为 0.000 5,将模型进行 3 500 次迭代后设置学习率为 1×10^{-5} 。在进行网络模型训练时,将训练集图像分为 10 个批次依次送入网络模型中。为了提高模型的分割效果,将数据集在模型中训练 1 200 轮,每一轮的迭代次数为 3 000 次。为了减轻过拟合现象,将动量因子设定为 0.99,同时使用验证集对训练好的网络模型进行评估。

为了更好地监视模型的训练效果,及时调整卷积层的设置参数,在输出卷积层(Conv1 ~ Conv6)中可以及时看到模型在每一层中通过卷积操作所得到的特征提取效果,不但能够对比网络模型中每一层所学到的输入图像特征,而且特征图输出过程体现了卷积神经网络中的权值共享技术,为进一步精细化分割打下基础。部分卷积层输出结果如图 5 所示。




图5 不同卷积层的输出特征图

Fig.5 Output feature map of different convolution layers

2.2 不同分割方法的分割效果对比

为了测试改进的全卷积神经网络在黄瓜叶部病

斑图像数据集中分割效果,分别使用本研究分割方法、传统的 FCN 分割方法^[16]、改进的最大类间方差(OTSU)分割方法^[17]、SVM 分割方法^[18]以及改进的马尔科夫条件随机场(CRF)分割方法^[19]在测试集图像上进行分割效果对比,分割结果见图 6。


在分割效果指标的量化过程中,使用平均像素准确率(acc_{mean})和平均交并比(IOU_{mean})进行评价。计算公式如下:

$$acc_{mean} = \frac{1}{n_{cl}} \sum_p \frac{n_{pp}}{t_p} \quad (6)$$

$$IOU_{mean} = \frac{1}{n_{cl}} \sum_p \frac{n_{pp}}{t_p + \sum_q n_{pq} - n_{pp}} \quad (7)$$

式中 n_{cl} 为分割图像像素所属类别, p 表示图像中像素正确对应的像素类别, q 表示图像中像素错误分类后所属像素类别, t_p 为分割结果中 p 类别的像素总数, n_{pp} 为分割结果中正确分割为类别 p 的像素总数, n_{pq} 为分割结果中本属于类别 p 但被误分为 q 的像素数量。

由于在实际的分割应用中,分割时间在评估分割方法性能时是一个较为重要的指标,因此使用单幅图像分割时间作为评估标准。



a:原始图像;b:改进 OTSU 方法;c:SVM 分割方法;d:CRF 分割方法;e:传统 FCN 方法;f:本研究方法。

图 6 不同分割方法分割效果对比

Fig.6 Comparison of segmentation effect of different segmentation methods

通过表 1 可以看出本研究方法在平均像素准确率和平均交并比 2 个评价性能指标上均高于其他 4 个分割方法。由于网络模型需要对输入图像的局部细节进行分割,而且本研究方法是在 GPU 环境下进行分割试验,因此在单幅图像的分割时间上较长,但

相比于改进前的全卷积神经网络模型仍然具有一定的时间优势。

表 1 不同方法分割黄瓜叶部病斑图像的性能对比

Table 1 Performance comparison of different methods for segmentation of cucumber leaf lesions

| 分割方法 | 平均像素准确率 (%) | 平均交并比 (%) | 单幅图像分割时间 (s) |
|------------|-------------|-----------|--------------|
| 改进 OTSU 方法 | 68.61 | 60.52 | 0.21 |
| SVM 方法 | 71.32 | 63.57 | 0.43 |
| CRF 方法 | 72.56 | 65.83 | 0.52 |
| 传统 FCN 方法 | 78.51 | 66.76 | 0.77 |
| 本研究方法 | 80.46 | 70.43 | 0.63 |

3 讨论

针对黄瓜叶部病斑图像分割问题,提出了一种基于改进全卷积神经网络的黄瓜叶部病斑图像分割方法,首先采用卷积神经网络对黄瓜叶部病斑图像进行预训练得到网络模型训练的初步参数,然后将预训练结果输入到全卷积神经网络中进行模型二阶训练,在训练的过程中将传统的 RELU 激活函数替换为 ELU 激活函数,使用 SVM 分类器和 Soft Max 分类器在黄瓜叶部病斑图像数据库中进行效果对比,通过试验验证选用 SVM 分类器作为像素的分类层具有较好的分割效果。由于传统的卷积神经网络中降采样操作会降低图像分辨率,影响分割效果,因此在本研究中增加反卷积操作过程恢复图像分辨率,得到更精细的分割结果。

在用本研究方法与其他分割方法进行分割效果的对比中,利用平均像素准确率和平均交并比作为评价指标。由于改进 OTSU 方法只是单一地使用阈值对图像进行分割,所以在复杂背景下难以分割出叶片的病害部分,因此其评价指标较低。SVM 和 CRF 方法的分割结果尽管优于改进 OTSU 方法,但是这 2 种方法是对像素点进行分割,而病害区域的像素特点与正常区域较为相似,因此这 2 种方法的评价指标低于本研究方法。传统 FCN 分割方法,使用 CNN 模型对图像进行分割,但是下采样网络中下采样操作降低了输入图像的分辨率,尽管分割效果优于传统分割方法,但其评价指标低于本研究方法。本研究方法对传统 FCN 进行改进,不仅对 CNN 模

型进行二次训练,而且在传统 FCN 网络的基础上增加反卷积操作恢复图像分辨率,所以在分割评价指标上优于其他 4 种分割方法。

本研究提出的黄瓜叶部病斑图像分割方法可以对不同黄瓜叶部病斑做到精细化分割,为黄瓜叶部病害的识别打下基础,而且网络模型不仅分割精度高,而且处理速度快,可以进一步满足现代化农业的需求。

参考文献:

- [1] 刘国奇,邓 铭,李晨静.融合 RGB 颜色空间的植物图像分割模型[J].郑州大学学报(理学版),2019,51(1):21-26.
- [2] 关 强,薛河儒,姜新华.基于二维 OTSU 的田间植物图像分割方法[J].江苏农业科学,2015,43(12):437-440.
- [3] 赵金阳,冯 全,王书志,等.一种改进的葡萄叶片自动分割算法[J].中国农业大学学报,2017,22(11):140-147.
- [4] 张会敏,谢泽奇,张善文,等.基于 WT-OTSU 算法的植物病害叶片图像分割方法[J].江苏农业科学,2017,45(18):194-196.
- [5] 张善文,张晴晴,齐国红,等.基于改进 K 中值聚类的苹果病害叶片分割方法[J].江苏农业科学,2017,45(18):205-208.
- [6] 刘立波,程晓龙,赖军臣.基于改进全卷积网络的棉田冠层图像分割方法[J].农业工程学报,2018,34(12):193-201.
- [7] 段凌凤,熊 雄,刘 谦,等.基于深度全卷积神经网络的大田稻穗分割[J].农业工程学报,2018,34(12):202-209.
- [8] 马凌诚,杜克明,郑飞翔,等.基于卷积神经网络的温室黄瓜病害识别系统[J].农业工程学报,2018,34(12):186-192.
- [9] FERREIRA A D S, FREITAS D M, SILVA G G D, et al. Weed detection in soybean crops using ConvNets [J]. Computers and Electronics in Agriculture, 2017, 143: 314-324.
- [10] DECHANT C, WIESNER-HANKS T, CHEN S, et al. Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning [J]. Phytopathology, 2017, 107: 1426-1432.
- [11] DING W, TAYLOR G. Automatic moth detection from trap images for pest management [J]. Computers and Electronics in Agriculture, 2016, 123: 17-28.
- [12] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4):640-651.
- [13] ALEX K, ILYA S, GEOFFREY E H. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 1097-1105.
- [14] GHOSAL S, BLYSTONE D, SINGH A K, et al. An explainable deep machine vision framework for plant stress phenotyping [J]. Proceedings of the National Academy of Sciences, 2018, 115(18):4613-4618.
- [15] BAI X, LI X, FU Z, et al. A fuzzy clustering segmentation method based on neighborhood grayscale information for defining cucumber leaf spot disease images [J]. Computers and Electronics in Agriculture, 2017, 136: 157-165.
- [16] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2018, 40(4):834-848.
- [17] 于洪涛,袁明新,谢 丰,等.一种融合动态 OTSU 和几何特征的苹果视觉分割算法[J].信息技术,2018,42(8):39-43.
- [18] 杨信廷,刘蒙蒙,许建平,等.自动监测装置用温室粉虱和蓟马成虫图像分割识别算法[J].农业工程学报,2018,34(1):164-170.
- [19] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6):1137-1149.

(责任编辑:张震林)