第42卷 第3期
2023年 5月

华 中 农 业 大 学 学 报
Journal of Huazhong Agricultural University

Vol.42 No.3
May 2023,152～160

满超,饶元,张敬尧,等.基于改进Inception网络的复杂环境下小样本黄瓜叶片病害识别[J].华中农业大学学报,2023,42(3):152-160.
DOI:10.13300/j.cnki.hnlkxb.2023.03.018

基于改进Inception网络的复杂环境下小样本黄瓜叶片病害识别

满超[1,2],饶元[1],张敬尧[3],乔焰[3],王胜和[2]

1.安徽农业大学信息与计算机学院,合肥 230036; 2.安徽省公安教育研究院,合肥 230031;
3.合肥工业大学计算机与信息学院,合肥 230601

摘要 为解决田间复杂环境下小样本黄瓜叶片病害识别中模型泛化能力差、识别准确率不高的问题,将自注意力机制模块引入激活重建生成对抗网络(activation reconstruction GAN,AR-GAN),采用Smooth L_1正则化作为损失函数,设计改进激活重建生成对抗网络IAR-GAN(improved AR-GAN)增广黄瓜叶片病害图像。通过在Inception网络基础上加入空洞卷积和形变卷积,设计空洞和形变卷积神经网络(dilated and deformable convolutional neural network,DDCNN)用于黄瓜叶片病害识别。试验结果显示,提出的IAR-GAN有效缓解了过拟合现象,丰富了生成样本的多样性;所提出的DDCNN对黄瓜炭疽病、斑靶病和霜霉病的平均识别准确率均达到96%以上,比Inception-V3模型提高了9个百分点。以上结果表明,本研究提出的数据增广方法和病害识别模型可为复杂环境下小样本的作物叶部病害的准确识别提供新思路。

关键词 病害识别; 小样本; 生成对抗网络; 深度卷积神经网络

中图分类号 TP391.4; S435 **文献标识码** A **文章编号** 1000-2421(2023)03-0152-09

黄瓜在其生长周期中会受到多种病害的影响,其中炭疽病、斑靶病和霜霉病较为常见。我国的黄瓜种植趋于密集型和集约化[1],一旦出现病害,极易影响或感染其他黄瓜植株,给农民带来巨大的经济损失。因此,快速准确地识别黄瓜病害种类并及时采取科学的防治措施,对提高黄瓜种植的产量和品质至关重要。近年来,结合计算机视觉的机器学习方法在黄瓜病害识别领域得到了广泛应用[2-5]。

深度神经网络在作物病害识别方面取得了良好的效果,但也存在以下问题:神经网络对病害识别需要成千上万张样本图像,小样本会导致模型泛化能力下降。对病害图像进行翻转、放缩等传统的几何变换类扩充方法,仅增加样本图像数量,并没有实质性丰富样本多样性,网络容易发生过拟合现象。生成对抗网络(generative adversarial networks, GAN)[6]的出现给样本数据增广提出了新的方法。Hu等[7]利用SVM对茶叶病害图像进行叶片病斑分割,将分割后的病斑图像利用一种改进的条件深度卷积生成对抗网络(C-DCGAN)进行数据增广,试验结果表明,使用VGG16网络对扩充后的茶叶病害数据集识别平均准确率达到90%。Cap等[8]提出了对多种叶片图像背景区域进行转换的LeafGAN,丰富了训练集图像样本多样性。为了提高在小样本数据集下植物病害识别准确率,Madsen等[9]通过监督调节方案设计了WacGAN获得大量的植物幼苗图像,扩充了数据集样本数量。Purbaya等[10]改进了GAN网络模型并增加L_1和L_2正则化的组合来增加植物叶片图像生成的多样性。Zhang等[11]利用deep convolutional GAN (DCGAN),将CNN与GAN相结合生成柑橘溃疡病图像,提高分类网络的准确性。虽然GAN在数据扩充方面得到了一定程度的应用,但模型在实际训练中不稳定,容易出现模式崩溃[12]现象,使生成图像样本多样性降低。

收稿日期: 2022-12-02
基金项目:安徽省自然科学基金项目(2008085MF203);安徽省重点研究和开发计划面上攻关项目(201904A06020056);安徽省高校自然科学研究重点项目(2022AH053088)
满超, E-mail:935528860@qq.com
通信作者: 饶元, E-mail:raoyuan@ahau.edu.cn

现有许多研究学者使用实验室环境下采集或者用背景单一的作物病害图像作为数据集训练识别模型。黄瓜种植生长环境复杂，受到不同光照强度等因素的影响，如何针对复杂背景图像有效地进行黄瓜叶片病害识别始终面临着挑战。现有研究表明采用分割后的叶片病斑图像训练深度卷积神经网络以及进行病害识别时仍可有效提高叶片病害识别的准确率[13-14]。

针对黄瓜叶片病害识别问题，本研究先进行病斑区域分割获得黄瓜叶片病害图像，再通过改进激活重建生成对抗网络（activation reconstruction GAN，AR-GAN）的损失函数，引入自注意力机制模块，设计了改进的激活重建生成对抗网络对小样本的黄瓜叶片病害图像进行数据增广，并提出了空洞和形变卷积神经网络（dilated and deformable convolutional neural network，DDCNN），旨在提高田间复杂环境下黄瓜叶片病害识别效果。

1　材料与方法

1.1　数据来源

本试验数据集采集于2019年6—9月份安徽农业大学农萃园，对田间黄瓜叶片进行多角度拍摄，黄瓜叶片图像背景为田间复杂环境，能真实反映黄瓜在自然环境下生长的情况。采集到的数据包含斑靶病、霜霉病和炭疽病黄瓜叶片病害，采集图像如图1所示，每种病害选取200个图像样本，构成600张原始叶片病害图像数据集，将图像大小调整为1 024像素×682像素，提高处理效率。

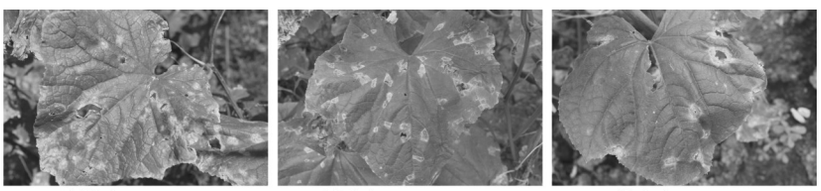

图1　黄瓜叶片病害类型

Fig.1　Types of cucumber leaf diseases

1.2　数据预处理

本研究采用基于GrabCut和SVM的两阶段分割方法[15]进行病斑区域分割。与许多现有的作物病害图像分割方法相比，该两阶段分割方法根据病害图像的纹理和颜色特征对田间复杂环境下拍摄的黄瓜病害叶片图像病斑分割能取得较好的效果。具体病斑分割过程如图2所示。在第一阶段，GrabCut算法可以将图像分为前景像素集和背景像素集，综合黄瓜叶片图像的纹理和边缘特征，利用GrabCut算法从获取到的复杂背景图像中分割出黄瓜叶片。第二阶段，根据黄瓜叶片的纹理特征和颜色特征，利用支持向量机分割出叶片中的病斑。其中，以黄瓜叶片的病斑、健康黄瓜叶片的颜色和纹理特征向量作为SVM的训练样本。从RGB空间的颜色直方图中提取颜色特征得到颜色特征向量，用Gabor滤波器代替灰度共生矩阵提取纹理特征。

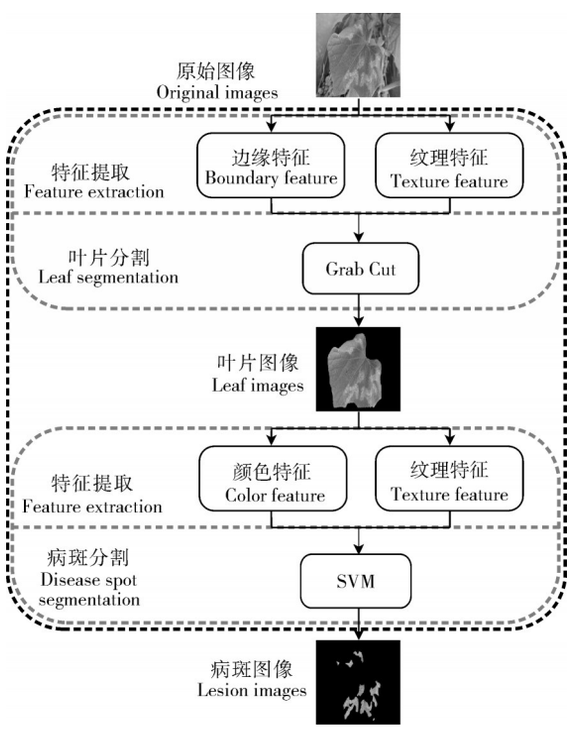

图2　两阶段病斑图像分割过程

Fig.2　Two-stage image segmentation method

1.3　激活重建生成对抗网络（AR-GAN）

深度卷积神经网络在黄瓜叶片病害识别时面临样本数量有限，模型在训练过程中易出现过拟合问题。而缩放、翻转等传统扩充方法并不改变图像的特征，仍然存在数据样本多样性不足的问题。使用生成对抗网络GAN进行数据增广，可有效提高样本多样性。与许多现有GAN及其变体网络相比，Nazki等[16]提出的AR-GAN模型在GAN的基础上对原始

目标函数进行循环一致性改进，并引入激活重建损失函数，对自然图像的特征激活进行优化，能够使生成图像在视觉上更真实自然，AR-GAN中的对抗损失函数定义为：

$$f_{\mathrm{GAN}}(G_{\mathrm{AB}},D_{\mathrm{B}})=E_{\mathrm{b}}[\log D_{\mathrm{B}}(b)]+E_{\mathrm{a}}[\log(1-D_{\mathrm{B}}(G_{\mathrm{AB}}(a))] \tag{1}$$

网络中生成器G_{AB}和G_{BA}被定义在域A和域B 2个不同的域中，当用A中的样本“a”进行初始化时，重构的$a'=G_{\mathrm{BA}}(G_{\mathrm{AB}}(a))$仍然接近于原始的“$a$”，当网络使用$L_1$正则化时，循环一致性的公式定义为：

$$f_{\mathrm{cyc}}(G_{\mathrm{AB}},G_{\mathrm{BA}})=\|E_{\mathrm{a}}G_{\mathrm{BA}}(G_{\mathrm{AB}}(a))-a\|+\|E_{\mathrm{b}}G_{\mathrm{AB}}(G_{\mathrm{BA}}(b))-b\| \tag{2}$$

激活重建损失函数f_{ARL}的引入，目的是使生成图像与真实图像更加相似，加强模型的稳定性。激活重建损失函数f_{ARL}公式为：

$$f_{\mathrm{ARL}}=\frac{1}{m}\|\mathrm{A}_{\mathrm{a}}^{n}-\mathrm{A}_{\mathrm{b}}^{n}\|_{\mathrm{F}}^{2} \tag{3}$$

式(3)中，A_{F}表示矩阵范数，m为特征图的形状，a、b表示样本A来源的域，n表示样本从卷积神经网络中的第n层输出。根据式(1)、式(2)和式(3)可以总结得出AR-GAN的目标函数为：

$$f_{\mathrm{total}}=f_{\mathrm{GAN}}(G_{\mathrm{AB}},D_{\mathrm{B}})+f_{\mathrm{GAN}}(G_{\mathrm{BA}},D_{\mathrm{A}})+\theta f_{\mathrm{cyc}}(G_{\mathrm{AB}},G_{\mathrm{BA}})+\lambda f_{\mathrm{ARL}} \tag{4}$$

其中，θ和λ为分别调节$f_{\mathrm{cyc}}(G_{\mathrm{AB}},G_{\mathrm{BA}})$和$f_{\mathrm{ARL}}$项的超参数。

1.4 IAR-GAN数据增广网络

与其他生成对抗网络相比，使用AR-GAN生成的图像与真实图像更相似，但通过试验发现，当训练样本数量有限时，AR-GAN生成的图像病斑边缘模糊且生成图像不够真实。为提高生成图像的质量，有效提升病害识别模型训练效果，本研究在AR-GAN的基础上引入了自注意力机制模块，并将AR-GAN的目标检测回归损失函数L_1 Loss替换为Smooth L_1 Loss，设计了改进的激活重建生成对抗网络IAR-GAN (improved activation reconstruction GAN)。

1)自注意力机制。IAR-GAN中的自注意力机制(self-attention)能够引导模型中的重建损失函数对病害图像中的关键特征进行提取，生成的病斑图像更加真实。自注意力机制由Google提出并用于自然语言处理任务[17]。自注意力机制通过设置权重参数使卷积神经网络对特征图像进行下采样时，重点提取图像关键区域特征，减少干扰因素影响。自注意力机制的引入使IAR-GAN生成对抗模型能准确提取黄瓜叶片病害图像中的病斑特征，提升了生成病斑图像的真实度。自注意力机制特征提取公式：

$$h_{\mathrm{self-attention}}=\sum_{t'=1}^{T}\alpha(x_{\mathrm{t}},x_{\mathrm{t'}})f_{\mathrm{ARL}}(x_{\mathrm{t}},x_{\mathrm{t'}}) \tag{5}$$

其中，$x=[x_1,x_2,\cdots,x_t]$表示网络中输入的特征信息，自注意力机制会对t个输入特征进行加权计算，并且通过引入权重向量α突出关键特征的提取。

2) Smooth L_1正则化。IAR-GAN将AR-GAN结构中的L_1正则化替换为Smooth L_1正则化，缓解梯度消失或梯度爆炸等问题。AR-GAN中采用的L_1正则化的导数为常量，在0点处不可导，导致神经网络模型在损失值较小时梯度也很大，往往造成AR-GAN收敛困难。而Smooth L_1正则化提高了神经网络的稳定性的同时也加快了模型训练的收敛速度。Smooth L_1正则化采用分段表示的方法，能够解决L_1正则化的不足。Smooth L_1正则化及其导数如式(6)、(7)所示：

$$\mathrm{Smooth\ L_1}(x)=\begin{cases}0.5x^2, & |x|<1\\ |x|-0.5, & |x|\geqslant 1\end{cases} \tag{6}$$

$$\frac{\mathrm{d\ Smooth\ L_1}}{\mathrm{d}x}=\begin{cases}x, & |x|<1\\ \pm 1, & |x|\geqslant 1\end{cases} \tag{7}$$

3)IAR-GAN网络结构。IAR-GAN网络结构如图3所示，域A和域B是2个不重合的域，生成器将图像从一个域转换到另一个域，每个域的鉴别器负责判断图像是否属于该域。如图中箭头所示，IAR-GAN通过在图像数据a与$G_{\mathrm{A\to B}}(a)$和b与$G_{\mathrm{B\to A}}(b)$间引入自注意力机制，使得卷积采样过程中病害图像的重点位置和关键特征得到关注，减少图像中田间复杂信息的干扰，提高了网络对病斑特征的提取能力。IAR-GAN采用Smooth L_1正则化，缓解了生成对抗网络训练过程中的梯度消失与梯度爆炸现象，增加了网络的收敛能力。IAR-GAN通过包含特征提取网络的激活重构模块来计算网络中的激活重构损失、周期性损失和对抗损失。根据式(5)、式(6)和式(7)可以总结得出IAR-GAN的总目标函数为：

$$f_{\mathrm{IAR\text{-}GAN}}=f_{\mathrm{GAN}}(G_{\mathrm{A\to B}},D_{\mathrm{A}})+f_{\mathrm{GAN}}(G_{\mathrm{B\to A}},D_{\mathrm{A}})+\lambda[f_{\mathrm{cyc}}(G_{\mathrm{A\to B}},G_{\mathrm{B\to A}})+h_{\mathrm{self-attention}}(f_{\mathrm{ARL}})] \tag{8}$$

其中，λ为调节$f_{\mathrm{cyc}}(G_{\mathrm{A\to B}},G_{\mathrm{B\to A}})$和$h_{\mathrm{self\text{-}attention}}(f_{\mathrm{ARL}})$项的超参数。

1.5 空洞和形变卷积神经网络DDCNN

深度卷积神经网络在作物病害的识别中发挥着重要作用，设计一种有效的卷积神经网络是实现准确识别的关键。为实现在田间复杂环境下黄瓜叶片病害的识别，许多研究人员通过增加卷积神经网络

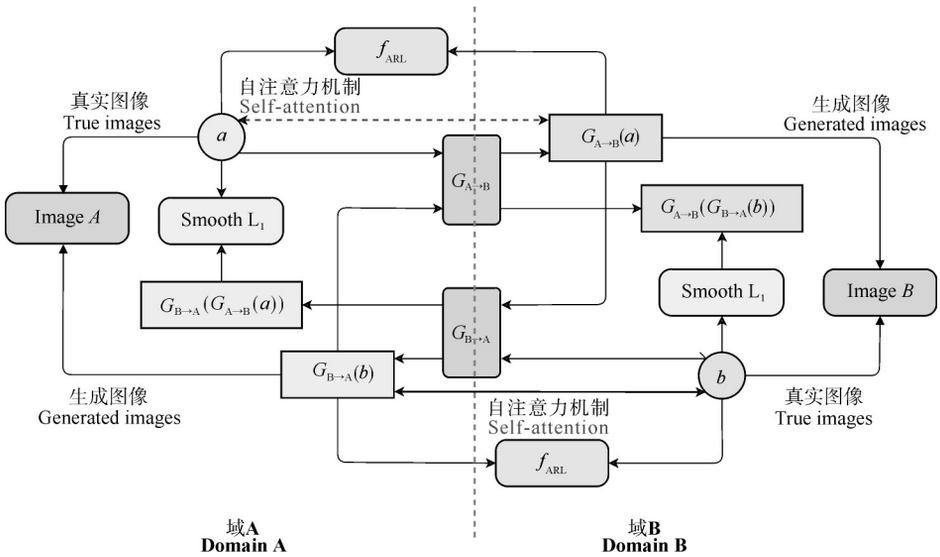

图3　IAR-GAN 网络架构

Fig.3　The framework IAR-GAN

的深度来提取病害图像特征，但增加网络的深度会导致模型出现过拟合或梯度消失等问题，影响病害识别的准确率[18-20]。DICNN（dilated and inception convolutional neural network）深度卷积神经网络[15]通过在 Inception 网络中加入空洞卷积克服网络的过拟合现象，加快网络的训练速度。

尽管 DICNN 在黄瓜病害识别方面取得了优于 VGG16 等方法的效果，但在田间复杂环境下获取的黄瓜叶片病害图像病斑呈现的位置、尺度各异，导致黄瓜病害的识别精度下降。本研究在 DICNN 基础上设计引入形变卷积，提出空洞和形变卷积神经网络 DDCNN（dilated and deformable convolutional neural network），通过将卷积核的采样位置引导到叶片上的病斑位置，充分提取病斑区域的特征，从而提高模型对黄瓜叶片病害的识别精度。

1）空洞卷积。采用小尺寸卷积核替换大尺寸卷积核能够减少网络中的参数数量，且增加了网络空间特征提取能力[21]。但卷积层频繁地下采样操作必然会导致图像内部数据结构丢失和空间层级化信息丢失等问题。空洞卷积[22]即在标准的卷积核中加入空洞，从而增加特征图的感受野，在减少网络参数数量的同时也能够提高模型的精度。如图 4A 表示 3×3 卷积核，图 4B、4C 分别表示空洞为 2、空洞为 3 的 3×3 卷积核可以等效替代 7×7 和 11×11 的卷积核，能够在保留内部数据结构的同时避免频繁地使用下采样操作[23]。

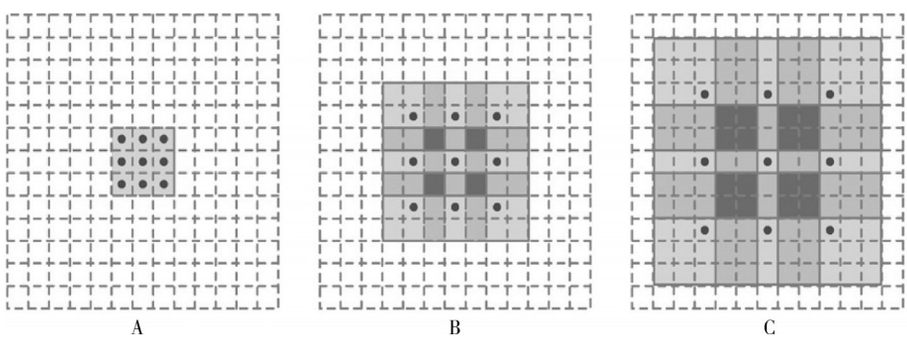

图4　标准卷积（A）与空洞卷积（B、C）采样位置

Fig.4　Sampling position of standard convolution（A）and dilated convolution（B，C）

2）形变卷积。受环境地形和黄瓜植株生长位置的影响，相机对黄瓜叶片进行拍摄时因位置角度不同，叶片病斑在图像中呈现出的位置、尺度各异。2017 年微软亚洲研究院提出了形变卷积（deformable CNN），形变卷积在对输入的特征图进行下采样时，可以按照 X 轴方向和 Y 轴方向的偏移量变换卷积位置进行采样[24]。偏移量的引入使输入特征图上不同卷积采样点的位置能随着图像上的内容发生

自适应的变化，形变卷积核根据图像的内容自适应地调整位置，适应图像中物体的不同尺度、形变等问题。图5是标准卷积和形变卷积的采样位置，图5A所示为标准卷积操作的采样位置，图5B～D所示为可形变卷积操作中具有偏移量的形变采样位置。

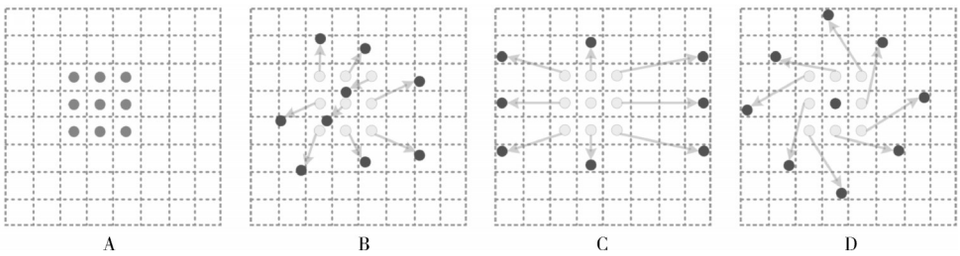

图5 标准卷积(A)和形变卷积(B~D)采样位置

Fig.5 Sampling position of standard convolution(A) and deformable convolution(B-D)

3)DDCNN网络结构。DDCNN结构如图6所示，网络中有3个卷积模块(卷积1～3)，3个池化模块(池化1～3)，1个Inception结构，1个空洞卷积，2个形变卷积和1个Softmax分类器层。DDCNN网络中第1层为空洞卷积，减少了卷积核下采样过程中的图像空间层次信息和内部数据结构的损失。DDCNN网络在第4层和第5层增加了形变卷积模块(deformable CNN)，使卷积核对特征图进行采样时可以根据图像上的内容进行自适应调整，可以准确地对黄瓜叶片病害特征进行提取。DDCNN中的Inception结构通过1×1小型卷积核缩减网络的深度，从而减少了网络的计算量并提高了训练速度，且多尺度卷积核的使用可有效提取图像中的多尺度特征，提高了模型的识别精度。此外，DDCNN网络中，通过在网络结构中的卷积层后增加非线性激活函数ReLU和Batch Normalization，缓解了网络的过拟合问题，且提高了DDCNN网络的训练效率。

1.6 试验环境及参数设置

本试验所使用的硬件配置为16 GB RAM、Intel (R) Core (TM) i5-8400 2.81 GHz和NVIDIA GeForce GTX 2080 Ti GPU的台式计算机，采用基于CUDA 9.0和CUDNN 7.1的TensorFlow框架。采用分批梯度下降算法对网络权值进行优化。IAR-GAN和DDCNN的批处理大小分别设置为8和16，初始学习率设为0.001，IAR-GAN和DDCNN在训练中每20轮Epoch均以0.1的概率执行1次Dropout操作。

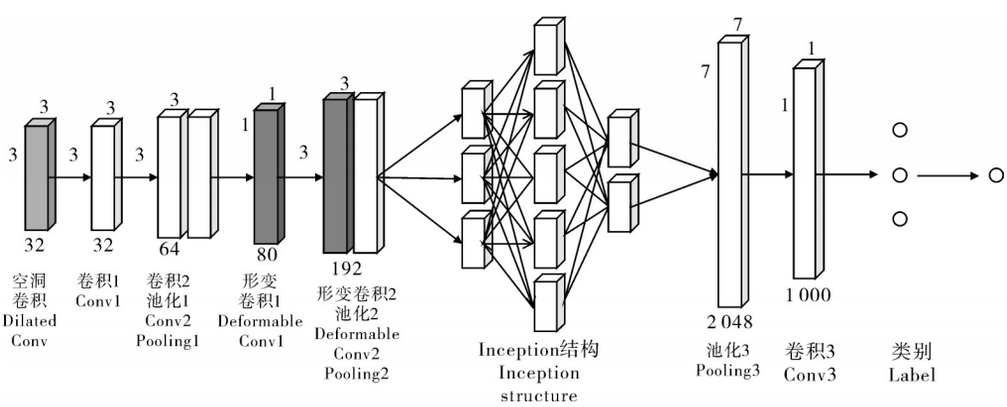

空洞卷积为32个3×3的卷积核，卷积1为32个3×3的卷积核，卷积2为64个3×3的卷积核，形变卷积1为80个1×1的卷积核，形变卷积2为192个3×3的卷积核，Inception结构中的卷积核大小为1×1，卷积3是1 000个1×1的卷积核，池化模块1～3均为最大池化。Dilated convolution has 32 kernels with 3×3 pixels; the convolution 1 has 32 kernels with 3×3 pixels; the convolution 2 has 64 kernels with 3×3 pixels; the deformable convolution 1 has 80 kernels with 1×1 pixels; the deformable convolution 2 has 192 kernels with 3×3 pixels; the Inception structure kernels with 1×1 pixels; the convolution 3 has 1 000 kernels with 1×1 pixels; the pooling 1-3 are max pooling.

图6 DDCNN结构

Fig.6 The structure of DDCNN

2　结果与分析

2.1　两阶段分割方法

为研究提出的基于GrabCut和SVM的两阶段病斑分割方法对于提高病斑识别准确率的影响，将包含霜霉病、炭疽病和斑靶病原始叶片图像各200张，按照8∶2的比例分为训练集和测试集。接着将上述600张原始叶片病害图像数据集进行两阶段分割后，最后采用C-DCGAN进行数据增广操作，为每类病斑生成4 000张新的病斑图像。表1为在原始数据集和两阶段病斑分割数据集上使用VGG16和传统机器学习方法SVM、K近邻和自适应Adaboost对3种黄瓜叶片病害的平均识别准确率。

表1　两阶段图像分割方法的识别准确率

Table 1　Accuracy rate of disease recognition results with two-stage image segmentation methods　%

模型 Model	原始图像数据集 Raw diseased leaf images	两阶段分割数据集 Two-stage segmented lesion images
C-DCGAN+VGG16	72.66	84.67
SVM	53.11	73.21
kNN	46.82	77.81
Adaboost	41.98	62.98

从表1可看出，无论采用深度学习方法和传统机器学习方法，在进行两阶段分割后图像数据集上的病害识别效果均优于在原始叶片病害图像数据集上的病害识别效果，平均识别准确度提高了约20%，表明对黄瓜叶片病害图像进行两阶段分割能有效提升复杂背景下黄瓜叶片病害识别准确率。如表1所示，传统机器学习方法在两阶段分割数据集上的识别精度显著提高。相比之下，深度学习方法在两阶段分割数据集识别精度提高有限。深度学习方法具有较强的病害特征提取能力，而机器学习识别精度的提升过度依赖于图像分割算法，从而导致了机器学习算法在原始病叶图像数据集上识别率较低。

2.2　不同数据增广方法

为提高黄瓜叶片病害图像处理效率，将包含炭疽病、斑靶病和霜霉病原始叶片图像各200张的病害数据集图像大小统一调整像素为1 024×682，并将上述600张原始叶片病害图像数据集进行病斑分割后按照8∶2的比例将每类病害图像划分为训练集和测试集。为研究不同数据增广方法对识别模型准确率的提升效果，共比较了5种数据增广方法(表2)。通过旋转和平移操作，每种类型的黄瓜叶片病害扩充到300个病斑图像样本。而IAR-GAN、AR-GAN和C-DCGAN为每种病害生成了6 000张新的病斑图像样本。采用VGG16网络作为病害识别模型，识别结果如表2所示。

表2　不同数据增广方法下病害识别结果

Table 2　Disease recognition results with different data augmentation methods　%

数据增广 Dataset augmentation	准确率 Accuracy			平均识别准确率 Average accuracy
	炭疽病 Anthracnose	斑靶病 Spot target	霜霉病 Downy mlidew	
原始数据集 Raw dataset	78.33	72.89	75.67	75.63
AB	78.17	76.59	74.69	76.48
RT	79.67	76.33	80.97	78.99
C-DCGAN	82.67	81.13	83.67	82.49
AR-GAN	84.98	85.31	84.67	84.99
IAR-GAN	90.67	87.67	86.67	88.34

注：AB表示调节图像亮度(adjust brightness)，RT表示旋转和平移(rotation and translation)，C-DCGAN表示条件卷积生成对抗网络。Note: AB represents adjust brightness, RT represents rotation and translation, and C-DCGAN represents conditional convolution to generate confrontation network.

从试验结果可以看出，对样本图像进行亮度调节或旋转平移的数据扩充方式虽然操作简单，但并没有增加样本图像特征信息，对黄瓜病害识别的提升作用十分有限，与传统数据增广方法相比，生成对抗网络采用图像生成的方式得到与原始样本数据分布一致的图像数据集。使用生成对抗网络对样本数据集进行增广，丰富了样本数据的多样性，对提升病害识别模型性能有明显促进作用。IAR-GAN生成对抗网络的数据增广方法比使用C-DCGAN在3种黄瓜叶片病害的识别精度上平均高出了6个百分点，比AR-GAN生成对抗网络的数据增广方法在3种黄瓜叶片病害的识别精度上平均高出了3个百分点，表明IAR-GAN网络模型通过引入了自注意力机制模块和Smooth L_1正则化后，缓解了模型梯度消失或梯度爆炸等问题，提高了网络的稳定性。

如表3所示，对图像进行亮度调节后用IAR-GAN生成对抗网络比直接使用IAR-GAN进行数据增广在3种黄瓜叶片病害的识别精度上平均高出了2个百分点。同样，对图像进行平移和旋转后用IAR-GAN生成对抗网络比直接使用IAR-GAN进行数据增广提高了3个百分点。表明在对样本图像使用生成对抗网络进行数据增广前进行亮度调节或者平移

表3 IAR-GAN结合传统数据增广方法下的识别结果

Table 3 Disease recognition results with combination of IAR-GAN and traditional data augmentation methods %

数据增广 Dataset augmentation	准确率Accuracy			平均识别准确率 Average accuracy
	炭疽病 Anthracnose	斑靶病 Spot target	霜霉病 Downy mlidew	
AB+IAR-GAN	93.59	89.95	90.31	91.28
RT+IAR-GAN	95.66	92.21	92.57	93.48

旋转的操作能有效地提高生成对抗网络的鲁棒性，提升了生成训练样本图像的质量，其中平移和旋转操作后用IAR-GAN生成对抗网络模型进行图像数据集增广方法比调节图像亮度的效果要好。由试验结果可知采用对数据集图像进行旋转、平移操作和IAR-GAN相结合的方法能有效实现样本数据增广。

2.3 不同病害识别方法

为更全面分析所提出的DDCNN网络性能，选取在农业病害图像识别中效果较好的AlexNet、ResNet、VGG16、Inception-V3、DICNN等深度学习方法进行对比分析。在验证不同深度学习方法的病害识别试验中，利用RT+IAR-GAN方法对数据集进行增广，为每种病害生成6 000张新的病斑图像作为训练样本。表4为不同深度学习方法对黄瓜叶片病害的识别结果。

表4 不同深度学习方法的病害识别结果

Table 4 Disease recognition results of different deep learning methods %

模型 Model	准确率Accuracy			平均识别准确率 Average accuracy
	炭疽病 Anthrac-nose	斑靶病 Spot target	霜霉病 Downy mlidew	
AlexNet	85.17	82.68	81.93	83.26
ResNet	85.88	83.02	82.14	83.68
VGG16	87.81	84.76	85.41	85.99
Inception-V3	88.82	85.68	88.24	87.58
DICNN	91.97	90.64	90.57	91.05
DDCNN	97.51	96.38	96.16	96.68

如表4所示，DDCNN对炭疽病、斑靶病和霜霉病的平均识别精度均为96%以上，明显优于其他深度学习模型。与AlexNet、ResNet和VGG16相比，DDCNN中Inception结构利用并行的小卷积核替代大卷积核，减少网络的参数量，并且采用多尺度卷积核提取黄瓜病害图像特征，丰富病害特征信息的多样性。DDCNN对黄瓜叶片病害的平均识别准确率比Inception-V3提高了9个百分点，DDCNN第一层采用空洞卷积，增强特征图的局部感受野，减少图像信息在池化过程中的损失，提升了模型对病害图像的特征提取能力；通过引入形变卷积，使卷积核能够对特征图中具有偏移量的形变采样位置进行采样，有效缓解了田间复杂环境下获取的黄瓜叶片图像因病斑形状扭曲、尺度不一致对模型识别准确率的影响，提升了模型的识别精度和泛化能力。

3 讨 论

本研究对田间复杂环境下小样本的黄瓜叶片病害识别进行研究，在AR-GAN基础上引入自注意力机制和Smooth L_1正则化，设计改进激活重建生成对抗网络IAR-GAN对分割后的病斑图像进行数据增广，并提出了空洞和形变卷积神经网络DDCNN进行复杂环境下黄瓜叶片病害识别。在黄瓜叶片病害图像数据量较少的情况下，采用传统GAN网络进行数据增广，生成图像质量低，容易产生过拟合现象。IAR-GAN通过引入自注意力机制和Smooth L_1正则化，缓解梯度消失与梯度爆炸现象，提高了收敛能力。试验结果表明，使用IAR-GAN生成增广图像的质量提升明显、丰富了样本的多样性，有效提升了病害识别模型的训练效果。受田间地形和植株生长位置影响，自然环境下获取的黄瓜叶片病害图像存在病斑形状扭曲、大小尺度不一致的情况，导致黄瓜病害的识别精度下降。DDCNN通过集成Inception、空洞卷积、形变卷积能对病斑特征进行准确提取，提高了模型识别精度。试验结果表明，DDCNN网络模型对3种黄瓜叶片病害的平均识别精度达到96%以上，病害识别的准确率较AlexNet、ResNet、VGG16、Inception-V3等深度学习方法得到了较大提升。

本研究提出的数据增广方法和病害识别模型能够有效提高田间复杂环境下小样本的黄瓜叶片病害识别效果，为病害科学防治提供支撑。后续将在以下方面进一步完善和探索：(1)增加黄瓜叶片病害种类，提高更多类病害情况下黄瓜叶片病害的识别准确率；(2)探索轻量级的病害识别模型结构，减少对于计算资源的需求，便于移动端部署。

参考文献 References

[1] 毋海梅，闫浩芳，张川，等.温室滴灌黄瓜产量和水分利用效率

对水分胁迫的响应[J].农业工程学报,2020,36(9):84-93.WU H M,YAN H F,ZHANG C,et al.Responses of yield and water use efficiency of drip-irrigated cucumber in greenhouse to water stress[J].Transactions of the CSAE,2020,36(9):84-93 (in Chinese with English abstract).

[2] 贾建楠,吉海彦.基于病斑形状和神经网络的黄瓜病害识别[J].农业工程学报,2013,29(S1):115-121.JIA J N,JI H Y.Recognition for cucumber disease based on leaf spot shape and neural network[J].Transactions of the CSAE,2013,29(S1):115-121 (in Chinese with English abstract).

[3] 李颀,赵洁,杨柳,等.基于GA-BP神经网络和特征向量优化组合的黄瓜叶片病斑识别[J].浙江农业学报,2019,31(3):487-495.LI Q,ZHAO J,YANG L,et al.Cucumber leaf lesion identification based on GA-BP neural network and feature vector optimization combination[J].Acta agriculturae Zhejiangensis,2019,31(3):487-495 (in Chinese with English abstract).

[4] 马浚诚,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.MA J C,DU K M,ZHENG F X,et al.Disease recognition system for greenhouse cucumbers based on deep convolutional neural network[J].Transactions of the CSAE,2018,34(12):186-192 (in Chinese with English abstract).

[5] 张善文,谢泽奇,张晴晴.卷积神经网络在黄瓜叶部病害识别中的应用[J].江苏农业学报,2018,34(1):56-61.ZHANG S W,XIE Z Q,ZHANG Q Q.Application research on convolutional neural network for cucumber leaf disease recognition[J].Jiangsu journal of agricultural sciences,2018,34(1):56-61 (in Chinese with English abstract).

[6] GOODFELLOW I J,POUGET-ABADIE J,MIRZA M,et al.Generative adversarial networks[DB/OL].arXiv,2014:1406.2661[2022-12-02].https://doi.org/10.48550/arXiv.1406.2661.

[7] HU G S,WU H Y,ZHANG Y,et al.A low shot learning method for tea leaf's disease identification[J/OL].Computers and electronics in agriculture,2019,163:104852[2022-12-02].https://doi.org/10.1016/j.compag.2019.104852.

[8] CAP Q H,UGA H,KAGIWADA S,et al.LeafGAN:an effective data augmentation method for practical plant disease diagnosis[J].IEEE transactions on automation science and engineering,2022,19(2):1258-1267.

[9] MADSEN S L,DYRMANN M,JØRGENSEN R N,et al.Generating artificial images of plant seedlings using generative adversarial networks[J].Biosystems engineering,2019,187:147-159.

[10] PURBAYA M E,SETIAWAN N A,ADJI T B.Leaves image synthesis using generative adversarial networks with regularization improvement[C]//Proceedings of 2018 International Conference on Information and Communications Technology (ICOIACT).Yogyakarta:IEEE,2018:360-365.

[11] ZHANG M,LIU S H,YANG F Y,et al.Classification of canker on small datasets using improved deep convolutional generative adversarial networks[J].IEEE access,2019,7:49680-49690.

[12] 陈佛计,朱枫,吴清潇,等.生成对抗网络及其在图像生成中的应用研究综述[J].计算机学报,2021,44(2):347-369.CHEN F J,ZHU F,WU Q X,et al.A survey about image generation with generative adversarial nets[J].Chinese journal of computers,2021,44(2):347-369 (in Chinese with English abstract).

[13] SHARMA P,BERWAL Y P S,GHAI W.Performance analysis of deep learning CNN models for disease detection in plants using image segmentation[J].Information processing in agriculture,2020,7(4):566-574.

[14] MA J C,DU K M,ZHENG F X,et al.A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network[J].Computers and electronics in agriculture,2018,154:18-24.

[15] ZHANG J Y,RAO Y,MAN C,et al.Identification of cucumber leaf diseases using deep learning and small sample size for agricultural Internet of Things[J/OL].International journal of distributed sensor networks,2021,17(4):155014772110074[2022-12-02].https://doi.org/10.1177/15501477211007407.

[16] NAZKI H,YOON S,FUENTES A,et al.Unsupervised image translation using adversarial networks for improved plant disease recognition[J/OL].Computers and electronics in agriculture,2020,168:105117[2022-12-02].https://doi.org/10.1016/j.compag.2019.105117.

[17] LI P,TANG C,XU X H.Video summarization with a graph convolutional attention network[J].Frontiers of information technology & electronic engineering,2021,22(6):902-913.

[18] 樊湘鹏,周建平,许燕,等.基于改进卷积神经网络的复杂背景下玉米病害识别[J].农业机械学报,2021,52(3):210-217.FAN X P,ZHOU J P,XU Y,et al.Corn disease recognition under complicated background based on improved convolutional neural network[J].Transactions of the CSAM,2021,52(3):210-217 (in Chinese with English abstract).

[19] 温德圣,许燕,周建平,等.自然光照影响下基于深度卷积神经网络和颜色迁移的杂草识别方法[J].中国科技论文,2020,15(3):287-292.WEN D S,XU Y,ZHOU J P,et al.Weed identification method based on deep convolutional neural network and color migration under the influence of natural illumination[J].China sciencepaper,2020,15(3):287-292 (in Chinese with English abstract).

[20] 王璨,武新慧,李志伟.基于卷积神经网络提取多尺度分层特征识别玉米杂草[J].农业工程学报,2018,34(5):144-151.WANG C,WU X H,LI Z W.Recognition of maize and weed based on multi-scale hierarchical features extracted by convolutional neural network[J].Transactions of the CSAE,2018,34(5):144-151 (in Chinese with English abstract).

[21] 王春山,周冀,吴华瑞,等.改进Multi-scale ResNet的蔬菜叶部病害识别[J].农业工程学报,2020,36(20):209-217.WANG C S,ZHOU J,WU H R,et al.Identification of vegetable leaf diseases based on improved Multi-scale ResNet[J].Transactions of the CSAE,2020,36(20):209-217 (in Chinese with English abstract).

[22] ZHANG S W,ZHANG S B,ZHANG C L,et al.Cucumber leaf disease identification with global pooling dilated convolutional

neural network [J]. Computers and electronics in agriculture, 2019, 162: 422-430.

[23] 鲍文霞,黄雪峰,胡根生,等.基于改进卷积神经网络模型的玉米叶部病害识别[J].农业工程学报,2021,37(6):160-167. BAO W X, HUANG X F, HU G S, et al. Identification of maize leaf diseases using improved convolutional neural network [J]. Transactions of the CSAE, 2021, 37(6): 160-167 (in Chinese with English abstract).

[24] 吉训生,王昊.基于优化可形变区域全卷积神经网络的人头检测方法[J].激光与光电子学进展,2019,56(14):129-139. JI X S, WANG H. Head detection method based on optimized deformable regional fully convolutional neutral networks[J]. Laser & optoelectronics progress, 2019, 56(14): 129-139 (in Chinese with English abstract).

Recognition of cucumber leaf disease with small samples in complex environment based on improved Inception network

MAN Chao[1,2], RAO Yuan[1], ZHANG Jingyao[3], QIAO Yan[3], WANG Shenghe[2]

1. *School of Information and Computer, Anhui Agricultural University, Hefei* 230036, *China*;
2. *Anhui Academy of Public Security Education, Hefei* 230031, *China*;
3. *School of Computer Science and Information Engineering, Hefei University of Technology, Hefei* 230601, *China*

Abstract In order to solve the problems of poor generalization ability and low recognition accuracy in the identification of cucumber leaf disease with small samples under complex field environment, the self-attention mechanism module was introduced into the activation reconstruction network AR-GAN (activation reconstruction GAN), and the smooth L_1 regularization was used as the loss function to design and improve the activation reconstruction network IAR-GAN (improved AR-GAN) to expand the cucumber leaf disease image. By adding void convolution and deformation convolution on the basis of the Inception network, the void and deformation convolution neural network (DDCNN) was designed for cucumber leaf disease identification. The test results showed that the proposed IAR-GAN effectively alleviated the over-fitting phenomenon and enriched the diversity of generated samples. The average recognition accuracy of the proposed DDCNN for cucumber anthracnose, spot target disease and downy mildew was more than 96%, which is 9% higher than the Inrception-V3 model. The above results showed that the data expansion method and disease identification model proposed in this paper can provide new ideas for the accurate identification of crop leaf diseases with small samples in complex environments.

Keywords disease recognition; small sample; generated adversarial network; deep convolutional neural network

(责任编辑:边书京)